أطلس العلوم التأسيسية والمتقدمة
للذكاء العام والنماذج الاستدلالية

AGI X Reasoning Models

كتاب عربي تقني موسوعي بمصطلحات إنجليزية مضبوطة الاتجاه

مراجعة معرفية: 15 يونيو 2026

ملاحظة منهجية: هذا الملف نسخة أولى موسعة على هيئة أطلس منظم. يهدف إلى الإحاطة بالبنية العلمية: الرياضيات، الإحصاء، الخوارزميات، النماذج، الاستدلال، الوكلاء، الوعي العملي، الواجهات العصبية، الذكاء الكمي، السلامة، والهندسة. المصطلحات الإنجليزية موضوعة داخل أوامر اتجاه يسار-إلى-يمين لمنع انقلاب الكتابة داخل السياق العربي.

تمهيد صارم

هذا الكتاب ليس ملخصا سطحيا، بل خريطة هجومية منظمة للعلوم التي يحتاجها مشروع AGI X Reasoning Models: من الأساس الرياضي إلى أحدث هندسة النماذج المفكرة والوكلاء والذاكرة والتحقق والسلامة. المقصود بكلمة state of art هنا ليس ادعاء امتلاك كل سر صناعي مغلق، فالبنى الداخلية التفصيلية للنماذج الحدودية ليست منشورة بالكامل. المقصود هو بناء معرفة أكاديمية وعملية تغطي: ما هو ثابت، ما هو مرجح، ما هو مثار نزاع، وما يمكن تحويله إلى فرضيات قابلة للاختبار.

ل مصطلح إنجليزي مهم يظهر داخل سياق عربي مضبوط الاتجاه، مثل Transformer وChain-of-Thought وProcess Reward Model وRetrieval-Augmented Generation. هذه ليست زينة لغوية، بل ضرورة لأن أدبيات المجال تتحرك بالإنجليزية، بينما يظل البناء المفاهيمي هنا عربيا.

كيف تقرأ هذا الكتاب

اقرأه على ثلاث طبقات. الطبقة الأولى: المفاهيم الأولية والمعادلات. الطبقة الثانية: الخوارزميات والهندسة. الطبقة الثالثة: الأسئلة والحدود والفرضيات. لا تحاول حفظ كل شيء دفعة واحدة؛ حوّل كل صفحة إلى بطاقة بحث: ما التعريف؟ ما المعادلة؟ ما الخوارزمية؟ ما القياس؟ ما الفشل؟ وما التجربة التي تكذب الفكرة؟

خريطة كبرى للعلوم الداخلة

العلم	وظيفته داخل المشروع
الرياضيات والإحصاء	لغة القياس، التعميم، الاستدلال، عدم اليقين، والتحسين.
الذكاء الاصطناعي الكلاسيكي	جذور البحث والتخطيط والتمثيل الرمزي والقرار.
التعلم العميق	بنية التمثيلات، التدريب، التوليد، والانتباه.
النماذج اللغوية والاستدلالية	التدريب القبلي، الضبط، التفكير، التحقق، البحث وقت الاختبار، والوكلاء.
الهندسة النظامية	تحويل النموذج إلى نظام يعمل تحت قيود العالم الحقيقي.
علوم الدماغ والوعي والإدراك	نماذج الانتباه، الذاكرة، الميتا-إدراك، والواجهات العصبية.
الذكاء الكمي والتعقيد	حدود الحساب، الضجيج، التعقيد، والمحاكاة المتقدمة.
السلامة والحوكمة	منع سوء الاستخدام، الانحراف، الفشل، وغياب المساءلة.

المحتويات

1 الإطار النظري العام **1**

1.1 تمييز الحقيقة عن الفرضية 1

2.1 النموذج التفسيري المقترح 1

2 المبادئ الأولية التي لا يجوز القفز فوقها **2**

1.2 المبدأ الأول: التمثيل 2

2.2 المبدأ الثاني: الخطأ 2

3.2 المبدأ الثالث: الموارد 2

4.2 المبدأ الرابع: القياس 2

3 الجزء الأول: الأساس الرياضي والمنطقي **3**

1.3 الجبر الخطي للنماذج 3

2.3 حساب التفاضل والتدرج 5

3.3 الاحتمال البايزي 6

4.3 نظرية المعلومات 7

5.3 التحسين العددي 8

6.3 الإحصاء الاستدلالي 9

7.3 العمليات العشوائية 10

8.3 الطوبولوجيا والفضاءات 11

9.3 المنطق الرسمي 12

10.3 نظرية القياس 13

11.3 نظرية الألعاب 14

12.3 الهندسة التفاضلية 15

13.3 البحث في فضاء الحالات 16

14.3 خوارزمية النجمة 17

15.3 التخطيط الرمزي 18

16.3 البرمجة القيدية 19

17.3 الشبكات البايزية 20

18.3 نماذج ماركوف المخفية 21

19.3 عمليات القرار الماركوفي 22
20.3 البحث الشجري 23
21.3 تمثيل المعرفة 24
22.3 الأنطولوجيات 25
23.3 الاستدلال غير الرتيب 26
24.3 حل المسائل العامة 27
25.3 الانحدار الخطي 28
26.3 الانحدار اللوجستي 29
27.3 آلات المتجهات الداعمة 30
28.3 الأشجار العشوائية 31
29.3 التعزيز التدرجي 32
30.3 تحليل المكونات الرئيسية 33
31.3 العناقيد 34
32.3 النماذج الخليطية 35
33.3 التحقق المتقاطع 36
34.3 اختبار الفرضيات 37
35.3 السببية العملية 38
36.3 التعلم شبه المراقب 39
37.3 الشبكات متعددة الطبقات 40
38.3 الانتشار العكسي 41
39.3 الشبكات الالتفافية 42
40.3 الشبكات المتكررة 43
41.3 آليات الانتباه 44
42.3 المحول 45
43.3 النماذج الانتشارية 46
44.3 المرمزات الذاتية 47
45.3 النماذج التوليدية الخصمية 48
46.3 خليط الخبراء 49
47.3 نماذج فضاء الحالة 50

4 الجزء الثاني: الذكاء الاصطناعي الكلاسيكي والبحث والتخطيط 51

1.4 التعلم الذاتي الإشراف 51
2.4 التقسيم إلى رموز 53
3.4 التدريب القبلي 54
4.4 الضبط الدقيق 55
5.4 التعلم من تفضيلات البشر 56

6.4 التحسين بالتفضيل المباشر 57
7.4 سلسلة التفكير 58
8.4 التصويت الذاتي 59
9.4 نماذج مكافأة العملية 60
10.4 نماذج مكافأة النتيجة 61
11.4 التحقق الآلي 62
12.4 التوسع وقت الاختبار 63
13.4 التفكير المتكيف 64
14.4 الاسترجاع المعزز 65
15.4 الوكلاء 66
16.4 استخدام الأدوات 67
17.4 الذاكرة الطويلة 68
18.4 النماذج متعددة الوسائط 69
19.4 التقييم المعياري 70
20.4 تعريف الذكاء العام 71
21.4 نظرية الحلقات المعرفية 72
22.4 النظام الوكيلي 73
23.4 هندسة الأهداف 74
24.4 تقسيم المهمة 75
25.4 التحكم المعرفي 76
26.4 المراقبة الذاتية 77
27.4 التعلم المستمر 78
28.4 الذاكرة العاملة 79
29.4 الحوسبة المتوازية وقت الاختبار 80
30.4 الاستدلال العلمي 81
31.4 النمذجة العالمية 82
32.4 الروبوتات الإدراكية 83
33.4 الإنسان في الحلقة 84
34.4 حوكمة الوكلاء 85
35.4 علم الإدراك 86
36.4 علم الأعصاب الحسابي 87
37.4 الانتباه العصبي 88
38.4 الوعي العملي 89
39.4 الميتا-إدراك 90
40.4 نظرية التراكب الوعائي 91

41.4 واجهة الدماغ والحاسوب 92
42.4 تخطيط الدماغ الكهربائي 93
43.4 نماذج الحالة المعرفية 94
44.4 التحكم المشترك 95
45.4 الخصوصية العصبية 96
46.4 النفس العصبية الحسابية 97
47.4 التعلم والنوم 98

5 الجزء الثالث: التعلم الآلي والإحصاء التطبيقي 99

1.5 الإدراك المتجسد 99
2.5 الحوسبة الكمية 100
3.5 مرحلة نيسك 101
4.5 التعلم الآلي الكمي 102
5.5 التصحيح الكمي للأخطاء 103
6.5 معلومات كمية 104
7.5 التعقيد الحسابي 105
8.5 نظرية الفوضى 106
9.5 الأنظمة المعقدة 107
10.5 نظرية التحكم 108
11.5 الفيزياء الإحصائية 109
12.5 علم الكون المعلوماتي 110
13.5 الرياضيات الفلسفية للزمن 111
14.5 هندسة الأنظمة 112
15.5 عمليات التعلم الآلي 113
16.5 هندسة البيانات 114
17.5 الأمن السيبراني للذكاء الاصطناعي 115
18.5 التقييم المستمر 116
19.5 السلامة والمحاذاة 117
20.5 إدارة المخاطر 118
21.5 التفسيرية 119
22.5 الخصوصية 120
23.5 الحوسبة الموزعة 121
24.5 هندسة المعالجات 122
25.5 القياس الاقتصادي 123
26.5 القانون والتنظيم 124
27.5 الأخلاق التطبيقية 125

28.5 الجبر الخطي للنماذج في التدريب 126
29.5 الجبر الخطي للنماذج في التقييم 127
30.5 الجبر الخطي للنماذج في الذاكرة 128
31.5 الجبر الخطي للنماذج في البحث العلمي 129
32.5 حساب التفاضل والتدرج وقت الاستدلال 130
33.5 حساب التفاضل والتدرج في السلامة 131
34.5 حساب التفاضل والتدرج في الوكلاء 132
35.5 حساب التفاضل والتدرج في الأنظمة الحقيقية 133
36.5 الاحتمال البايزي في التدريب 134
37.5 الاحتمال البايزي في التقييم 135
38.5 الاحتمال البايزي في الذاكرة 136
39.5 الاحتمال البايزي في البحث العلمي 137
40.5 نظرية المعلومات وقت الاستدلال 138
41.5 نظرية المعلومات في السلامة 139
42.5 نظرية المعلومات في الوكلاء 140
43.5 نظرية المعلومات في الأنظمة الحقيقية 141
44.5 التحسين العددي في التدريب 142
45.5 التحسين العددي في التقييم 143
46.5 التحسين العددي في الذاكرة 144
47.5 التحسين العددي في البحث العلمي 145

6 الجزء الرابع: التعلم العميق وبنى النماذج الحديثة 146

1.6 الإحصاء الاستدلالي وقت الاستدلال 146
2.6 الإحصاء الاستدلالي في السلامة 148
3.6 الإحصاء الاستدلالي في الوكلاء 149
4.6 الإحصاء الاستدلالي في الأنظمة الحقيقية 150
5.6 العمليات العشوائية في التدريب 151
6.6 العمليات العشوائية في التقييم 152
7.6 العمليات العشوائية في الذاكرة 153
8.6 العمليات العشوائية في البحث العلمي 154
9.6 الطوبولوجيا والفضاءات وقت الاستدلال 155
10.6 الطوبولوجيا والفضاءات في السلامة 156
11.6 الطوبولوجيا والفضاءات في الوكلاء 157
12.6 الطوبولوجيا والفضاءات في الأنظمة الحقيقية 158
13.6 المنطق الرسمي في التدريب 159

14.6 المنطق الرسمي في التقييم 160
15.6 المنطق الرسمي في الذاكرة 161
16.6 المنطق الرسمي في البحث العلمي 162
17.6 نظرية القياس وقت الاستدلال 163
18.6 نظرية القياس في السلامة 164
19.6 نظرية القياس في الوكلاء 165
20.6 نظرية القياس في الأنظمة الحقيقية 166
21.6 نظرية الألعاب في التدريب 167
22.6 نظرية الألعاب في التقييم 168
23.6 نظرية الألعاب في الذاكرة 169
24.6 نظرية الألعاب في البحث العلمي 170
25.6 الهندسة التفاضلية وقت الاستدلال 171
26.6 الهندسة التفاضلية في السلامة 172
27.6 الهندسة التفاضلية في الوكلاء 173
28.6 الهندسة التفاضلية في الأنظمة الحقيقية 174
29.6 البحث في فضاء الحالات في التدريب 175
30.6 البحث في فضاء الحالات في التقييم 176
31.6 البحث في فضاء الحالات في الذاكرة 177
32.6 البحث في فضاء الحالات في البحث العلمي 178
33.6 خوارزمية النجمة وقت الاستدلال 179
34.6 خوارزمية النجمة في السلامة 180
35.6 خوارزمية النجمة في الوكلاء 181
36.6 خوارزمية النجمة في الأنظمة الحقيقية 182
37.6 التخطيط الرمزي في التدريب 183
38.6 التخطيط الرمزي في التقييم 184
39.6 التخطيط الرمزي في الذاكرة 185
40.6 التخطيط الرمزي في البحث العلمي 186
41.6 البرمجة القيدية وقت الاستدلال 187
42.6 البرمجة القيدية في السلامة 188
43.6 البرمجة القيدية في الوكلاء 189
44.6 البرمجة القيدية في الأنظمة الحقيقية 190
45.6 الشبكات البايزية في التدريب 191
46.6 الشبكات البايزية في التقييم 192
47.6 الشبكات البايزية في الذاكرة 193

7 الجزء الخامس: النماذج اللغوية الكبيرة ونماذج الاستدلال 194
1.7 الشبكات البايزية في البحث العلمي 194
2.7 نماذج ماركوف المخفية وقت الاستدلال 195
3.7 نماذج ماركوف المخفية في السلامة 196
4.7 نماذج ماركوف المخفية في الوكلاء 197
5.7 نماذج ماركوف المخفية في الأنظمة الحقيقية 198
6.7 عمليات القرار الماركوفي في التدريب 199
7.7 عمليات القرار الماركوفي في التقييم 200
8.7 عمليات القرار الماركوفي في الذاكرة 201
9.7 عمليات القرار الماركوفي في البحث العلمي 202
10.7 البحث الشجري وقت الاستدلال 203
11.7 البحث الشجري في السلامة 204
12.7 البحث الشجري في الوكلاء 205
13.7 البحث الشجري في الأنظمة الحقيقية 206
14.7 تمثيل المعرفة في التدريب 207
15.7 تمثيل المعرفة في التقييم 208
16.7 تمثيل المعرفة في الذاكرة 209
17.7 تمثيل المعرفة في البحث العلمي 210
18.7 الأنطولوجيات وقت الاستدلال 211
19.7 الأنطولوجيات في السلامة 212
20.7 الأنطولوجيات في الوكلاء 213
21.7 الأنطولوجيات في الأنظمة الحقيقية 214
22.7 الاستدلال غير الرتيب في التدريب 215
23.7 الاستدلال غير الرتيب في التقييم 216
24.7 الاستدلال غير الرتيب في الذاكرة 217
25.7 الاستدلال غير الرتيب في البحث العلمي 218
26.7 حل المسائل العامة وقت الاستدلال 219
27.7 حل المسائل العامة في السلامة 220
28.7 حل المسائل العامة في الوكلاء 221
29.7 حل المسائل العامة في الأنظمة الحقيقية 222
30.7 الانحدار الخطي في التدريب 223
31.7 الانحدار الخطي في التقييم 224
32.7 الانحدار الخطي في الذاكرة 225
33.7 الانحدار الخطي في البحث العلمي 226
34.7 الانحدار اللوجستي وقت الاستدلال 227

35.7 الانحدار اللوجستي في السلامة 228
36.7 الانحدار اللوجستي في الوكلاء 229
37.7 الانحدار اللوجستي في الأنظمة الحقيقية 230
38.7 آلات المتجهات الداعمة في التدريب 231
39.7 آلات المتجهات الداعمة في التقييم 232
40.7 آلات المتجهات الداعمة في الذاكرة 233
41.7 آلات المتجهات الداعمة في البحث العلمي 234
42.7 الأشجار العشوائية وقت الاستدلال 235
43.7 الأشجار العشوائية في السلامة 236
44.7 الأشجار العشوائية في الوكلاء 237
45.7 الأشجار العشوائية في الأنظمة الحقيقية 238
46.7 التعزيز التدرجي في التدريب 239
47.7 التعزيز التدرجي في التقييم 240

8 الجزء السادس: الذكاء العام الاصطناعي والهندسة الوكيلية 241

1.8 التعزيز التدرجي في الذاكرة 241
2.8 التعزيز التدرجي في البحث العلمي 243
3.8 تحليل المكونات الرئيسية وقت الاستدلال 244
4.8 تحليل المكونات الرئيسية في السلامة 245
5.8 تحليل المكونات الرئيسية في الوكلاء 246
6.8 تحليل المكونات الرئيسية في الأنظمة الحقيقية 247
7.8 العناقيد في التدريب 248
8.8 العناقيد في التقييم 249
9.8 العناقيد في الذاكرة 250
10.8 العناقيد في البحث العلمي 251
11.8 النماذج الخليطية وقت الاستدلال 252
12.8 النماذج الخليطية في السلامة 253
13.8 النماذج الخليطية في الوكلاء 254
14.8 النماذج الخليطية في الأنظمة الحقيقية 255
15.8 التحقق المتقاطع في التدريب 256
16.8 التحقق المتقاطع في التقييم 257
17.8 التحقق المتقاطع في الذاكرة 258
18.8 التحقق المتقاطع في البحث العلمي 259
19.8 اختبار الفرضيات وقت الاستدلال 260

20.8 اختبار الفرضيات في السلامة 261
21.8 اختبار الفرضيات في الوكلاء 262
22.8 اختبار الفرضيات في الأنظمة الحقيقية 263
23.8 السببية العملية في التدريب 264
24.8 السببية العملية في التقييم 265
25.8 السببية العملية في الذاكرة 266
26.8 السببية العملية في البحث العلمي 267
27.8 التعلم شبه المراقب وقت الاستدلال 268
28.8 التعلم شبه المراقب في السلامة 269
29.8 التعلم شبه المراقب في الوكلاء 270
30.8 التعلم شبه المراقب في الأنظمة الحقيقية 271
31.8 الشبكات متعددة الطبقات في التدريب 272
32.8 الشبكات متعددة الطبقات في التقييم 273
33.8 الشبكات متعددة الطبقات في الذاكرة 274
34.8 الشبكات متعددة الطبقات في البحث العلمي 275
35.8 الانتشار العكسي وقت الاستدلال 276
36.8 الانتشار العكسي في السلامة 277
37.8 الانتشار العكسي في الوكلاء 278
38.8 الانتشار العكسي في الأنظمة الحقيقية 279
39.8 الشبكات الالتفافية في التدريب 280
40.8 الشبكات الالتفافية في التقييم 281
41.8 الشبكات الالتفافية في الذاكرة 282
42.8 الشبكات الالتفافية في البحث العلمي 283
43.8 الشبكات المتكررة وقت الاستدلال 284
44.8 الشبكات المتكررة في السلامة 285
45.8 الشبكات المتكررة في الوكلاء 286
46.8 الشبكات المتكررة في الأنظمة الحقيقية 287
47.8 آليات الانتباه في التدريب 288

9 الجزء السابع: الإدراك، الوعي، الدماغ، وواجهة الدماغ والحاسوب 289

1.9 آليات الانتباه في التقييم 289
2.9 آليات الانتباه في الذاكرة 291
3.9 آليات الانتباه في البحث العلمي 292
4.9 المحول وقت الاستدلال 293

5.9 المحول في السلامة 294
6.9 المحول في الوكلاء 295
7.9 المحول في الأنظمة الحقيقية 296
8.9 النماذج الانتشارية في التدريب 297
9.9 النماذج الانتشارية في التقييم 298
10.9 النماذج الانتشارية في الذاكرة 299
11.9 النماذج الانتشارية في البحث العلمي 300
12.9 المرمزات الذاتية وقت الاستدلال 301
13.9 المرمزات الذاتية في السلامة 302
14.9 المرمزات الذاتية في الوكلاء 303
15.9 المرمزات الذاتية في الأنظمة الحقيقية 304
16.9 النماذج التوليدية الخصمية في التدريب 305
17.9 النماذج التوليدية الخصمية في التقييم 306
18.9 النماذج التوليدية الخصمية في الذاكرة 307
19.9 النماذج التوليدية الخصمية في البحث العلمي 308
20.9 خليط الخبراء وقت الاستدلال 309
21.9 خليط الخبراء في السلامة 310
22.9 خليط الخبراء في الوكلاء 311
23.9 خليط الخبراء في الأنظمة الحقيقية 312
24.9 نماذج فضاء الحالة في التدريب 313
25.9 نماذج فضاء الحالة في التقييم 314
26.9 نماذج فضاء الحالة في الذاكرة 315
27.9 نماذج فضاء الحالة في البحث العلمي 316
28.9 التعلم الذاتي الإشراف وقت الاستدلال 317
29.9 التعلم الذاتي الإشراف في السلامة 318
30.9 التعلم الذاتي الإشراف في الوكلاء 319
31.9 التعلم الذاتي الإشراف في الأنظمة الحقيقية 320
32.9 التقسيم إلى رموز في التدريب 321
33.9 التقسيم إلى رموز في التقييم 322
34.9 التقسيم إلى رموز في الذاكرة 323
35.9 التقسيم إلى رموز في البحث العلمي 324
36.9 التدريب القبلي وقت الاستدلال 325
37.9 التدريب القبلي في السلامة 326
38.9 التدريب القبلي في الوكلاء 327

39.9 التدريب القبلي في الأنظمة الحقيقية 328
40.9 الضبط الدقيق في التدريب 329
41.9 الضبط الدقيق في التقييم 330
42.9 الضبط الدقيق في الذاكرة 331
43.9 الضبط الدقيق في البحث العلمي 332
44.9 التعلم من تفضيلات البشر وقت الاستدلال 333
45.9 التعلم من تفضيلات البشر في السلامة 334
46.9 التعلم من تفضيلات البشر في الوكلاء 335
47.9 التعلم من تفضيلات البشر في الأنظمة الحقيقية 336

10 الجزء الثامن: الذكاء الكمي، التعقيد، والعلوم الحدودية 337
1.10 التحسين بالتفضيل المباشر في التدريب 337
2.10 التحسين بالتفضيل المباشر في التقييم 339
3.10 التحسين بالتفضيل المباشر في الذاكرة 340
4.10 التحسين بالتفضيل المباشر في البحث العلمي 341
5.10 سلسلة التفكير وقت الاستدلال 342
6.10 سلسلة التفكير في السلامة 343
7.10 سلسلة التفكير في الوكلاء 344
8.10 سلسلة التفكير في الأنظمة الحقيقية 345
9.10 التصويت الذاتي في التدريب 346
10.10التصويت الذاتي في التقييم 347
11.10التصويت الذاتي في الذاكرة 348
12.10التصويت الذاتي في البحث العلمي 349
13.10نماذج مكافأة العملية وقت الاستدلال 350
14.10نماذج مكافأة العملية في السلامة 351
15.10نماذج مكافأة العملية في الوكلاء 352
16.10نماذج مكافأة العملية في الأنظمة الحقيقية 353
17.10نماذج مكافأة النتيجة في التدريب 354
18.10نماذج مكافأة النتيجة في التقييم 355
19.10نماذج مكافأة النتيجة في الذاكرة 356
20.10نماذج مكافأة النتيجة في البحث العلمي 357
21.10التحقق الآلي وقت الاستدلال 358
22.10التحقق الآلي في السلامة 359

23.10التحقق الآلي في الوكلاء 360
24.10التحقق الآلي في الأنظمة الحقيقية 361
25.10التوسع وقت الاختبار في التدريب 362
26.10التوسع وقت الاختبار في التقييم 363
27.10التوسع وقت الاختبار في الذاكرة 364
28.10التوسع وقت الاختبار في البحث العلمي 365
29.10التفكير المتكيف وقت الاستدلال 366
30.10التفكير المتكيف في السلامة 367
31.10التفكير المتكيف في الوكلاء 368
32.10التفكير المتكيف في الأنظمة الحقيقية 369
33.10الاسترجاع المعزز في التدريب 370
34.10الاسترجاع المعزز في التقييم 371
35.10الاسترجاع المعزز في الذاكرة 372
36.10الاسترجاع المعزز في البحث العلمي 373
37.10الوكلاء وقت الاستدلال 374
38.10الوكلاء في السلامة 375
39.10الوكلاء في الوكلاء 376
40.10الوكلاء في الأنظمة الحقيقية 377
41.10استخدام الأدوات في التدريب 378
42.10استخدام الأدوات في التقييم 379
43.10استخدام الأدوات في الذاكرة 380
44.10استخدام الأدوات في البحث العلمي 381
45.10الذاكرة الطويلة وقت الاستدلال 382
46.10الذاكرة الطويلة في السلامة 383
47.10الذاكرة الطويلة في الوكلاء 384

11 الجزء التاسع: هندسة الأنظمة، السلامة، الأمن، والمستقبل 385

1.11 الذاكرة الطويلة في الأنظمة الحقيقية 385
2.11 النماذج متعددة الوسائط في التدريب 387
3.11 النماذج متعددة الوسائط في التقييم 388
4.11 النماذج متعددة الوسائط في الذاكرة 389
5.11 النماذج متعددة الوسائط في البحث العلمي 390
6.11 التقييم المعياري وقت الاستدلال 391
7.11 التقييم المعياري في السلامة 392

8.11 التقييم المعياري في الوكلاء 393
9.11 التقييم المعياري في الأنظمة الحقيقية 394
10.11تعريف الذكاء العام في التدريب 395
11.11تعريف الذكاء العام في التقييم 396
12.11تعريف الذكاء العام في الذاكرة 397
13.11تعريف الذكاء العام في البحث العلمي 398
14.11نظرية الحلقات المعرفية وقت الاستدلال 399
15.11نظرية الحلقات المعرفية في السلامة 400
16.11نظرية الحلقات المعرفية في الوكلاء 401
17.11نظرية الحلقات المعرفية في الأنظمة الحقيقية 402
18.11النظام الوكيلي في التدريب 403
19.11النظام الوكيلي في التقييم 404
20.11النظام الوكيلي في الذاكرة 405
21.11النظام الوكيلي في البحث العلمي 406
22.11هندسة الأهداف وقت الاستدلال 407
23.11هندسة الأهداف في السلامة 408
24.11هندسة الأهداف في الوكلاء 409
25.11هندسة الأهداف في الأنظمة الحقيقية 410
26.11تقسيم المهمة في التدريب 411
27.11تقسيم المهمة في التقييم 412
28.11تقسيم المهمة في الذاكرة 413
29.11تقسيم المهمة في البحث العلمي 414
30.11التحكم المعرفي وقت الاستدلال 415
31.11التحكم المعرفي في السلامة 416
32.11التحكم المعرفي في الوكلاء 417
33.11التحكم المعرفي في الأنظمة الحقيقية 418
34.11المراقبة الذاتية في التدريب 419
35.11المراقبة الذاتية في التقييم 420
36.11المراقبة الذاتية في الذاكرة 421
37.11المراقبة الذاتية في البحث العلمي 422
38.11التعلم المستمر وقت الاستدلال 423
39.11التعلم المستمر في السلامة 424
40.11التعلم المستمر في الوكلاء 425

41.11التعلم المستمر في الأنظمة الحقيقية 426
42.11الذاكرة العاملة في التدريب 427
43.11الذاكرة العاملة في التقييم 428
44.11الذاكرة العاملة في الذاكرة 429

صفحات قليلة عن المستقبل والتحديات والأسئلة المفتوحة **430**
45.11المستقبل القريب 430
46.11التحديات 430
47.11أسئلة بحثية حاسمة 430

مصادر ومراجع حديثة مختارة **431**

خاتمة عالية الكثافة **433**

باب 1

الإطار النظري العام

الذكاء الاصطناعي الحديث لم يعد نموذجا منفردا. إنه طبقات متداخلة: بيانات، نموذج أساس، ضبط لاحق، ذاكرة، استرجاع، أدوات، حوسبة وقت الاختبار، تحقق، واجهة، مراقبة، وحوكمة. لذلك لا يصح فهم reasoning models كأنها فقط نماذج تعرضت لتدريب أكثر. التدريب مهم، لكنه ليس كافيا. النقلة الحقيقية هي انتقال الذكاء من احتمال الكلمة التالية إلى نظام يخصص موارده، يبحث في بدائل، يراجع خطواته، يستدعي أدوات، ويخضع لتقييمات متعددة.

الأطروحة المركزية: النموذج المفكر ليس وعيا غامضا، بل حلقة معرفية مضبوطة: توليد فرضيات، اختبار، انتقاء، ذاكرة، وفعل. قوته تقاس بقدرته على نقل هذه الحلقة بين مجالات متباعدة دون انهيار.

1.1 تمييز الحقيقة عن الفرضية

ما هو ثابت: الخوارزميات الرياضية الأساسية، مبادئ الاحتمال، التحسين، الانتباه، التعلم المعزز، والتقييم. ما هو متحرك: وصف البنى المغلقة للنماذج الحدودية، تفاصيل البيانات، طرق ما بعد التدريب، وضوابط السلامة الداخلية. لذلك سيقول الكتاب أحيانا: هذه بنية منشورة، وهذه ممارسة مربحة، وهذه فرضية بحثية.

2.1 النموذج التفسيري المقترح

نقترح تسمية Verified Cognitive Loop Model لا كنظرية نهائية، بل كإطار عمل: كل نظام ذكاء متقدم يتكون من حلقة إدراك، حلقة توليد، حلقة تحقق، حلقة ذاكرة، حلقة فعل، وحلقة حوكمة. كل فشل كبير يحدث عادة عندما تتضخم حلقة وتضعف أخرى: توليد بلا تحقق، ذاكرة بلا نظافة، أداة بلا صلاحيات، أو هدف بلا قيود.

باب 2

المبادئ الأولية التي لا يجوز القفز فوقها

1.2 المبدأ الأول: التمثيل

كل نظام ذكاء يحتاج تمثيلا. التمثيل ليس نسخة من الواقع؛ إنه ضغط انتقائي يحافظ على ما يفيد المهمة. في LLM يظهر التمثيل في التضمينات والطبقات الداخلية وأنماط الانتباه. في الدماغ يظهر عبر شبكات حسية وحركية وذاكرية. في BCI يظهر عبر تحويل الإشارة العصبية إلى سمات قابلة للتصنيف.

2.2 المبدأ الثاني: الخطأ

لا تعلم بلا خطأ. الخسارة loss هي صياغة رياضية لما لا يريده النظام. لكن اختيار الخسارة يحدد نوع الذكاء الناتج: خسارة توقع رمز تنتج طلاقة؛ خسارة تفضيل تنتج امتثالا؛ مكافأة عملية تنتج خطوات أفضل؛ تحقق تنفيذي ينتج دقة في مجالات قابلة للفحص.

3.2 المبدأ الثالث: الموارد

الذكاء ليس قدرة مجردة؛ إنه توزيع موارد. كم عينة؟ كم ذاكرة؟ كم وقت تفكير؟ كم استدعاء أداة؟ كم تحقق؟ نماذج test-time compute تجعل هذه الموارد جزءا من بنية الذكاء نفسها.

4.2 المبدأ الرابع: القياس

ما لا يقاس يتحول إلى خطاب. لكن القياس الضعيف أخطر من غياب القياس لأنه يصنع ثقة زائفة. لذلك يحتاج كل فصل إلى مؤشرات: دقة، معايرة، متانة، تكلفة، زمن، قابلية تفسير، سلامة، أثر اجتماعي.

باب 3

الجزء الأول: الأساس الرياضي والمنطقي

هذا الجزء يبني اللغة التي تفهم بها الخوارزميات: الجبر الخطي، الاحتمال، الإحصاء، التحسين، المعلومات، والمنطق. لا توجد نماذج استدلالية قوية بلا هذه الطبقة.

1.3 الجبر الخطي للنماذج

Linear Algebra

المجال: الرياضيات

التعريف العملي. المتجهات والمصفوفات والقيم الذاتية والتحليل الطيفي هي البنية الداخلية للتمثيلات، والانتباه، والتضمينات، وتقريب الدوال. داخل هذا الكتاب لا نعامل Linear Algebra ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Linear Algebra في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب

الأهداف.

2.3 حساب التفاضل والتدرج

Differential Calculus

المجال: الرياضيات

التعريف العملي. التعلم الحديث هو هندسة تدرجات؛ كل تحديث وزن هو تقدير محلي لاتجاه يخفض الخسارة. داخل هذا الكتاب لا نعامل Differential Calculus ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V)=\mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Differential Calculus في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

3.3 الاحتمال البايزي

Bayesian Probability

المجال: الرياضيات

التعريف العملي. الاحتمال ليس تكرارا فقط بل درجة اعتقاد منظمة تتحدث عن المجهول وتستقبل الدليل. داخل هذا الكتاب لا نعامل Bayesian Probability ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Bayesian Probability في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

4.3 نظرية المعلومات

Information Theory

المجال: الرياضيات

التعريف العملي. الانتروبيا والمعلومة المتبادلة والانضغاط تقدم لغة لقياس ما يحمله التمثيل وما يهمله. داخل هذا الكتاب لا نعامل Information Theory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Information Theory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

5.3 التحسين العددي

Numerical Optimization

المجال: الرياضيات

التعريف العملي. تدريب النموذج مسألة بحث في فضاء عال الأبعاد تحت ضوضاء، قيود، وانحناء غير متجانس. داخل هذا الكتاب لا نعامل Numerical Optimization ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Numerical Optimization في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

6.3 الإحصاء الاستدلالي

Inferential Statistics

المجال: الرياضيات

التعريف العملي. الاستدلال الإحصائي يحمي الباحث من خداع العينة ومن خلط الارتباط بالسببية. داخل هذا الكتاب لا نعامل Inferential Statistics ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Inferential Statistics في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

7.3 العمليات العشوائية

Stochastic Processes

المجال: الرياضيات

التعريف العملي. السلاسل الزمنية، ماركوف، والانتشار العشوائي تفسر التعلم، التحكم، والنشاط العصبي كحركة احتمالية. داخل هذا الكتاب لا نعامل Stochastic Processes ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Stochastic Processes في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

8.3 الطوبولوجيا والفضاءات

Topology

المجال: الرياضيات

التعريف العملي. تصف الطوبولوجيا شكل فضاءات التمثيل: التجاور، الاستمرارية، العناقيد، والانقطاعات المفاهيمية. داخل هذا الكتاب لا نعامل Topology ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Topology في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

9.3 المنطق الرسمي

Formal Logic

المجال: الرياضيات

التعريف العملي. المنطق يحدد ما يعنيه أن تكون الحجة صحيحة حتى عندما يكون النص مقنعا لغويا. داخل هذا الكتاب لا نعامل Formal Logic ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Formal Logic في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

10.3 نظرية القياس

Measure Theory

المجال: الرياضيات

التعريف العملي. تمنح الاحتمال أساسه الدقيق عندما تصبح الفضاءات مستمرة ومعقدة وغير قابلة للعد البسيط. داخل هذا الكتاب لا نعامل Measure Theory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n} \sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Measure Theory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

11.3 نظرية الألعاب

Game Theory

المجال: الرياضيات

التعريف العملي. كل وكيل ذكي يعيش بين حوافز متصارعة؛ ونظرية الألعاب تفكك الاستراتيجية، التوازن، والمخاطرة. داخل هذا الكتاب لا نعامل Game Theory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda\Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Game Theory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

12.3 الهندسة التفاضلية

Differential Geometry

المجال: الرياضيات

التعريف العملي. تظهر في فهم فضاءات المعلمات، التعلم الطبيعي، ومناور التمثيل العميق. داخل هذا الكتاب لا نعامل Differential Geometry ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Differential Geometry في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

13.3 البحث في فضاء الحالات

State-Space Search

المجال: الذكاء الكلاسيكي

التعريف العملي. جذر الذكاء الاصطناعي هو تحويل المشكلة إلى حالات، أفعال، كلفة، وهدف. داخل هذا الكتاب لا نعامل State-Space Search ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال State-Space Search في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

14.3 خوارزمية النجمة

A-Star Search

المجال: الذكاء الكلاسيكي

التعريف العملي. تدمج الكلفة الماضية مع تقدير مستقبلي لتوجيه البحث نحو الهدف بكفاءة. داخل هذا الكتاب لا نعامل A-Star Search ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال A-Star Search في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

15.3 التخطيط الرمزي

Symbolic Planning

المجال: الذكاء الكلاسيكي

التعريف العملي. يعالج الفعل كسلسلة شروط وتأثيرات لا كمجرد نص مولد. داخل هذا الكتاب لا نعامل Symbolic Planning ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Symbolic Planning في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

16.3 البرمجة القيدية

Constraint Programming

المجال: الذكاء الكلاسيكي

التعريف العملي. تحول المشكلة إلى قيود يجب إرضاؤها، وتستعمل الاستبعاد الذكي بدل التجريب الأعمى. داخل هذا الكتاب لا نعامل Constraint Programming ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Constraint Programming في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

17.3 الشبكات البايزية

Bayesian Networks

المجال: الذكاء الكلاسيكي

التعريف العملي. تمثل الاعتماد الشرطي بين المتغيرات وتسمح باستدلال سببي واحتمالي. داخل هذا الكتاب لا نعامل Bayesian Networks ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Bayesian Networks في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

18.3 نماذج ماركوف المخفية

Hidden Markov Models

المجال: الذكاء الكلاسيكي

التعريف العملي. تتعامل مع حالات خفية تولد ملاحظات، وهي أصل مهم في الكلام والسلاسل الحيوية. داخل هذا الكتاب لا نعامل Hidden Markov Models ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \operatorname{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Hidden Markov Models في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

19.3 عمليات القرار الماركوفي

Markov Decision Processes

المجال: الذكاء الكلاسيكي

التعريف العملي. تؤطر القرار كحالات وأفعال ومكافآت وانتقالات، وهي قاعدة التعلم المعزز. داخل هذا الكتاب لا نعامل Markov Decision Processes ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Markov Decision Processes في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

20.3 البحث الشجري

Tree Search

المجال: الذكاء الكلاسيكي

التعريف العملي. يفتح بدائل الفعل على هيئة شجرة ويوازن بين الاستكشاف والاستغلال. داخل هذا الكتاب لا نعامل Tree Search ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Tree Search في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

21.3 تمثيل المعرفة

Knowledge Representation

المجال: الذكاء الكلاسيكي

العملي. يسأل كيف نمثل الحقائق والعلاقات والقواعد كي تصبح قابلة للاستدلال. داخل هذا الكتاب لا نعامل Knowledge Representation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Knowledge Representation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

22.3 الأنطولوجيات

Ontologies

المجال: الذكاء الكلاسيكي

التعريف العملي. تمنح المجال مفردات منظمة وعلاقات رسمية تمنع فوضى المعنى. داخل هذا الكتاب لا نعامل Ontologies ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V) = \mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Ontologies في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

23.3 الاستدلال غير الرتيب

Non-Monotonic Reasoning

المجال: الذكاء الكلاسيكي

التعريف العملي. في العالم الواقعي قد تلغي معلومة جديدة استنتاجا قديما؛ وهذا يتجاوز المنطق المدرسي. داخل هذا الكتاب لا نعامل Non-Monotonic Reasoning ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Non-Monotonic Reasoning في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

24.3 حل المسائل العامة

General Problem Solving

المجال: الذكاء الكلاسيكي

التعريف العملي. يربط الهدف بالاستراتيجية والتمثيل والتقييم، وهو سلف مباشر لفكرة الوكيل الذكي. داخل هذا الكتاب لا نعامل General Problem Solving ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال General Problem Solving في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

25.3 الانحدار الخطي

Linear Regression

المجال: تعلم آلي

التعريف العملي. أبسط نموذج يوضح معنى الملاءمة، الخطأ، التعميم، والتفسير العددي. داخل هذا الكتاب لا نعامل Linear Regression ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Linear Regression في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

26.3 الانحدار اللوجستي

Logistic Regression

المجال: تعلم آلي

التعريف العملي. يربط الخطي بالاحتمالي عبر دالة سيغمويد لتصنيف ثنائي قابل للتفسير. داخل هذا الكتاب لا نعامل Logistic Regression ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Logistic Regression في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

27.3 آلات المتجهات الداعمة

Support Vector Machines

المجال: تعلم آلي

التعريف العملي. تبحث عن هامش فاصل أقصى وتكشف قيمة الهندسة في التصنيف. داخل هذا الكتاب لا نعامل Support Vector Machines ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Support Vector Machines في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

28.3 الأشجار العشوائية

Random Forests

المجال: تعلم آلي

التعريف العملي. تجمع أشجارا ضعيفة نسبيا لتقليل التباين وتحسين الثبات. داخل هذا الكتاب لا نعامل Random Forests ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Random Forests في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

29.3 التعزيز التدرجي

Gradient Boosting

المجال: تعلم آلي

التعريف العملي. يبني نموذجا قويا بإضافة مصححات متتالية لأخطاء النماذج السابقة. داخل هذا الكتاب لا نعامل Gradient Boosting ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Gradient Boosting في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

30.3 تحليل المكونات الرئيسية

PCA

المجال: تعلم آلي

التعريف العملي. يضغط البيانات إلى اتجاهات تفسر أكبر قدر من التباين. داخل هذا الكتاب لا نعامل PCA ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال PCA في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

31.3 العناقيد

Clustering

المجال: تعلم آلي

التعريف العملي. يكشف بنى غير موسومة عبر القرب، الكثافة، أو النموذج الاحتمالي. داخل هذا الكتاب لا نعامل Clustering ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda\Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Clustering في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

32.3 النماذج الخليطية

Gaussian Mixture Models

المجال: تعلم آلي

التعريف العملي. تفترض أن البيانات صادرة عن خليط توزيعات وتستعمل خوارزمية التوقع والتعظيم. داخل هذا الكتاب لا نعامل Gaussian Mixture Models ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Gaussian Mixture Models في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

33.3 التحقق المتقاطع

Cross-Validation

المجال: تعلم آلي

التعريف العملي. يقيس التعميم على تقسيمات متعددة بدل الثقة في تقسيم واحد. داخل هذا الكتاب لا نعامل Cross-Validation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Cross-Validation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

34.3 اختبار الفرضيات

Hypothesis Testing

المجال: تعلم آلي

التعريف العملي. يفرق بين الأثر الحقيقي والتذبذب العيني وفق تصميم إحصائي. داخل هذا الكتاب لا نعامل Hypothesis Testing ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Hypothesis Testing في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

35.3 السببية العملية

Causal Inference

المجال: تعلم آلي

التعريف العملي. تسأل عما يحدث عند التدخل، لا عما يصاحب ماذا فقط. داخل هذا الكتاب لا نعامل Causal Inference ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Causal Inference في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

36.3 التعلم شبه المراقب

Semi-Supervised Learning

المجال: تعلم آلي

التعريف العملي. يستغل البيانات غير الموسومة عندما تكون الوسوم نادرة ومكلفة. داخل هذا الكتاب لا نعامل Semi-Supervised Learning ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Semi-Supervised Learning في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

37.3 الشبكات متعددة الطبقات

Multilayer Perceptrons

المجال: تعلم عميق

التعريف العملي. تقرب الدوال المعقدة عبر تراكيب غير خطية من تحويلات خطية وتنشيطات. داخل هذا الكتاب لا نعامل Multilayer Perceptrons ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Multilayer Perceptrons في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

38.3 الانتشار العكسي

Backpropagation

المجال: تعلم عميق

التعريف العملي. يحسب تدرجات الخسارة بكفاءة عبر قاعدة السلسلة. داخل هذا الكتاب لا نعامل Backpropagation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \operatorname{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Backpropagation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

39.3 الشبكات الالتفافية

Convolutional Neural Networks

المجال: تعلم عميق

التعريف العملي. تستغل المحلية والتشارك الوزني لفهم الصور والإشارات. داخل هذا الكتاب لا نعامل Convolutional Neural Networks ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Convolutional Neural Networks في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

40.3 الشبكات المتكررة

Recurrent Neural Networks

المجال: تعلم عميق

التعريف العملي. تعالج التسلسل ذاكرة بخطوة، لكنها تعاني من التدرجات الطويلة. داخل هذا الكتاب لا نعامل Recurrent Neural Networks ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Recurrent Neural Networks في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

41.3 آليات الانتباه

Attention Mechanisms

المجال: تعلم عميق

التعريف العملي. تجعل النموذج يختار ما يهم من السياق بدل ضغط كل شيء في حالة واحدة. داخل هذا الكتاب لا نعامل Attention Mechanisms ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Attention Mechanisms في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

42.3 المحول

Transformer

المجال: تعلم عميق

التعريف العملي. بنية الانتباه الذاتي صارت العمود الفقري للنماذج اللغوية والرؤيوية الحديثة. داخل هذا الكتاب لا نعامل Transformer ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V)=\mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Transformer في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

43.3 النماذج الانتشارية

Diffusion Models

المجال: تعلم عميق

التعريف العملي. تتعلم عكس عملية إضافة الضجيج لتوليد صور وصوت وفيديو. داخل هذا الكتاب لا نعامل Diffusion Models ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Diffusion Models في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

44.3 المرمزات الذاتية

Autoencoders

المجال: تعلم عميق

التعريف العملي. تتعلم تمثيلا مضغوطا يحافظ على بنية البيانات المهمة. داخل هذا الكتاب لا نعامل Autoencoders ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Autoencoders في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

45.3 النماذج التوليدية الخصمية

GANs

المجال: تعلم عميق

التعريف العملي. تضع مولدا وناقدا في لعبة تعلم توليدي. داخل هذا الكتاب لا نعامل GANs ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال GANs في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

46.3 خليط الخبراء

Mixture of Experts

المجال: تعلم عميق

التعريف العملي. يفعل أجزاء محددة من النموذج لكل عينة لتحقيق كفاءة وسعة أعلى. داخل هذا الكتاب لا نعامل Mixture of Experts ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Mixture of Experts في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

47.3 نماذج فضاء الحالة

State Space Models

المجال: تعلم عميق

التعريف العملي. بديل أو مكمل للمحول يعالج التسلسل بكلفة خطية تقريبا. داخل هذا الكتاب لا نعامل State Space Models ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال State Space Models في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

باب 4

الجزء الثاني: الذكاء الاصطناعي الكلاسيكي والبحث والتخطيط

هنا تظهر جذور الذكاء الاصطناعي قبل الشبكات العميقة: البحث، التخطيط، المنطق، البرمجة القيدية، التمثيل الرمزي، والقرار تحت عدم اليقين.

1.4 التعلم الذاتي الإشراف

Self-Supervised Learning

المجال: تعلم عميق

التعريف العملي. يستخرج الإشارة التعليمية من البيانات نفسها عبر إخفاء، تنبؤ، أو تباين. داخل هذا الكتاب لا نعامل Self-Supervised Learning ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Self-Supervised Learning في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

2.4 التقسيم إلى رموز

Tokenization

المجال: نماذج لغوية واستدلال

التعريف العملي. يحدد وحدة القراءة والكتابة التي يرى بها النموذج العالم اللغوي. داخل هذا الكتاب لا نعامل Tokenization ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Tokenization في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

3.4 التدريب القبلي

Pretraining

المجال: نماذج لغوية واستدلال

التعريف العملي. يبني معرفة عامة من كميات ضخمة قبل التخصص. داخل هذا الكتاب لا نعامل Pretraining ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Pretraining في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

4.4 الضبط الدقيق

Fine-Tuning

المجال: نماذج لغوية واستدلال

التعريف العملي. ينقل النموذج من عمومية واسعة إلى مجال أو سلوك مطلوب. داخل هذا الكتاب لا نعامل Fine-Tuning ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda\Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Fine-Tuning في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

5.4 التعلم من تفضيلات البشر

RLHF

المجال: نماذج لغوية واستدلال

التعريف العملي. يستعمل ملاحظات البشر أو نماذج المكافأة لتشكيل السلوك النهائي. داخل هذا الكتاب لا نعامل RLHF ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال RLHF في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

6.4 التحسين بالتفضيل المباشر

DPO

المجال: نماذج لغوية واستدلال

التعريف العملي. يحول بيانات التفضيل إلى هدف مباشر دون حلقة تعزيز كاملة. داخل هذا الكتاب لا نعامل DPO ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال DPO في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

7.4 سلسلة التفكير

Chain-of-Thought

المجال: نماذج لغوية واستدلال

التعريف العملي. تزيد قدرة النموذج على تنظيم الخطوات، لكنها لا تضمن صحة النتيجة. داخل هذا الكتاب لا نعامل Chain-of-Thought ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Chain-of-Thought في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

8.4 التصويت الذاتي

Self-Consistency

المجال: نماذج لغوية واستدلال

التعريف العملي. يولد مسارات متعددة ثم يختار الجواب الأكثر اتساقا. داخل هذا الكتاب لا نعامل Self-Consistency ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Self-Consistency في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

9.4 نماذج مكافأة العملية

Process Reward Models

المجال: نماذج لغوية واستدلال

التعريف العملي. تقوّم خطوات الحل لا النتيجة النهائية فقط. داخل هذا الكتاب لا نعامل Process Reward Models ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Process Reward Models في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

10.4 نماذج مكافأة النتيجة

Outcome Reward Models

المجال: نماذج لغوية واستدلال

التعريف العملي. تقوّم الجواب النهائي وتخدم الاختيار بين عينات متعددة. داخل هذا الكتاب لا نعامل Outcome Reward Models ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Outcome Reward Models في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

11.4 التحقق الآلي

Verifiers

المجال: نماذج لغوية واستدلال

التعريف العملي. يربط التوليد بآليات تحقق صورية أو تنفيذية أو إحصائية. داخل هذا الكتاب لا نعامل Verifiers ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \operatorname{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Verifiers في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

12.4 التوسع وقت الاختبار

Test-Time Scaling

المجال: نماذج لغوية واستدلال

التعريف العملي. يزيد التفكير أو البحث عند الاستدلال بدل زيادة التدريب فقط. داخل هذا الكتاب لا نعامل Test-Time Scaling ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Test-Time Scaling في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

13.4 التفكير المتكيف

Adaptive Thinking

المجال: نماذج لغوية واستدلال

التعريف العملي. يضبط عمق التفكير حسب صعوبة المسألة وثقة النموذج. داخل هذا الكتاب لا نعامل Adaptive Thinking ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Adaptive Thinking في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

14.4 الاسترجاع المعزز

Retrieval-Augmented Generation

المجال: نماذج لغوية واستدلال

العملي. يفصل الذاكرة الخارجية عن ذاكرة الأوزان ويزيد قابلية التحديث. داخل هذا الكتاب لا نعامل Retrieval-Augmented Generation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Retrieval-Augmented Generation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

15.4 الوكلاء

AI Agents

المجال: نماذج لغوية واستدلال

التعريف العملي. يضيفون للنموذج هدفا وذاكرة وأدوات وحلقة فعل وملاحظة. داخل هذا الكتاب لا نعامل AI Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V)=\mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال AI Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

16.4 استخدام الأدوات

Tool Use

المجال: نماذج لغوية واستدلال

التعريف العملي. ينقل النموذج من كلام عن العالم إلى أفعال داخل أنظمة حقيقية. داخل هذا الكتاب لا نعامل Tool Use ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Tool Use في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

17.4 الذاكرة الطويلة

Long-Term Memory

المجال: نماذج لغوية واستدلال

التعريف العملي. تحفظ سياقا عابرا للجلسات والمهام، لكنها تفتح مشاكل الخصوصية والتحيز. داخل هذا الكتاب لا نعامل Long-Term Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Long-Term Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

18.4 النماذج متعددة الوسائط

Multimodal Models

المجال: نماذج لغوية واستدلال

التعريف العملي. تدمج اللغة مع الصورة والصوت والفيديو والحركة والبيانات المنظمة. داخل هذا الكتاب لا نعامل Multimodal Models ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Multimodal Models في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

19.4 التقييم المعياري

Benchmarks

المجال: نماذج لغوية واستدلال

التعريف العملي. يقيس القدرات لكنه قد يصنع وهما إذا تحول إلى هدف تدريب مباشر. داخل هذا الكتاب لا نعامل Benchmarks ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Benchmarks في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

20.4 تعريف الذكاء العام

Artificial General Intelligence

المجال: AGI وأنظمة

التعريف العملي. ليس نموذجا واحدا بل قدرة نظامية على النقل، التخطيط، التكيف، والتعلم عبر مجالات متباعدة. داخل هذا الكتاب لا نعامل Artificial General Intelligence ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Artificial General Intelligence في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

21.4 نظرية الحلقات المعرفية

Cognitive Loops

المجال: AGI وأنظمة

التعريف العملي. تفسر الذكاء كنظام حلقات: توليد، تحقق، ذاكرة، فعل، تغذية راجعة، وإعادة ضبط. داخل هذا الكتاب لا نعامل Cognitive Loops ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Cognitive Loops في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

22.4 النظام الوكيلي

Agentic System

المجال: AGI وأنظمة

التعريف العملي. يجمع نموذج أساس وأدوات وذاكرة وسياسة فعل ومراقبة أمان. داخل هذا الكتاب لا نعامل Agentic System ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Agentic System في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

23.4 هندسة الأهداف

Goal Engineering

المجال: AGI وأنظمة

التعريف العملي. تحدد الغاية بطريقة تمنع الانحرافات والحلول الخطرة. داخل هذا الكتاب لا نعامل Goal Engineering ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Goal Engineering في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

24.4 تقسيم المهمة

Task Decomposition

المجال: AGI وأنظمة

التعريف العملي. يكسر العمل الطويل إلى وحدات قابلة للتحقق والتفويض. داخل هذا الكتاب لا نعامل Task Decomposition ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda \Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Task Decomposition في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

25.4 التحكم المعرفي

Cognitive Control

المجال: AGI وأنظمة

التعريف العملي. ينظم متى يفكر النموذج، متى يبحث، متى ينفذ، ومتى يتوقف. داخل هذا الكتاب لا نعامل Cognitive Control ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Cognitive Control في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

26.4 المراقبة الذاتية

Self-Monitoring

المجال: AGI وأنظمة

التعريف العملي. تجعل النظام يقدر ثقته وأخطاءه وحدوده قبل أن يتصرف. داخل هذا الكتاب لا نعامل Self-Monitoring ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Self-Monitoring في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

27.4 التعلم المستمر

Continual Learning

المجال: AGI وأنظمة

التعريف العملي. يحاول التعلم بعد النشر دون نسيان كارثي أو تلوث بيانات. داخل هذا الكتاب لا نعامل Continual Learning ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Continual Learning في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

28.4 الذاكرة العاملة

Working Memory

المجال: AGI وأنظمة

التعريف العملي. تدير العناصر النشطة أثناء حل المسألة، وهي عنق زجاجة حاسم. داخل هذا الكتاب لا نعامل Working Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Working Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

29.4 الحوسبة المتوازية وقت الاختبار

Parallel Test-Time Compute

المجال: AGI وأنظمة

التعريف العملي. تجرب مسارات متعددة في وقت واحد وتختار أو تدمج الأفضل. داخل هذا الكتاب لا نعامل Parallel Test-Time Compute ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Parallel Test-Time Compute في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

30.4 الاستدلال العلمي

Scientific Reasoning

المجال: AGI وأنظمة

التعريف العملي. يتطلب توليد فرضيات واختبارها وتعديلها لا حفظ نتائج فقط. داخل هذا الكتاب لا نعامل Scientific Reasoning ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Scientific Reasoning في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

31.4 النمذجة العالمية

World Models

المجال: AGI وأنظمة

التعريف العملي. تبني تمثيلا ديناميكيا لما يحدث إذا فعل الوكيل شيئا. داخل هذا الكتاب لا نعامل World Models ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \mathrm{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال World Models في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

32.4 الروبوتات الإدراكية

Cognitive Robotics

المجال: AGI وأنظمة

التعريف العملي. تجعل الذكاء يواجه الاحتكاك والضجيج والزمن والجسم. داخل هذا الكتاب لا نعامل Cognitive Robotics ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Cognitive Robotics في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

33.4 الإنسان في الحلقة

Human-in-the-Loop

المجال: AGI وأنظمة

التعريف العملي. يبقي الإنسان جزءا من القرار في المواقف عالية المخاطر. داخل هذا الكتاب لا نعامل Human-in-the-Loop ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Human-in-the-Loop في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

34.4 حوكمة الوكلاء

Agent Governance

المجال: AGI وأنظمة

التعريف العملي. تضبط الصلاحيات، السجلات، الحدود، والمساءلة. داخل هذا الكتاب لا نعامل Agent Governance ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Agent Governance في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

35.4 علم الإدراك

Cognitive Science

المجال: إدراك ووعي ودماغ

التعريف العملي. يدرس العقل كنظام تمثيل ومعالجة وسلوك، ويصل بين النفس والدماغ والحوسبة. داخل هذا الكتاب لا نعامل Cognitive Science ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في إدراك ووعي ودماغ نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V)=\mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Cognitive Science في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

36.4 علم الأعصاب الحسابي

Computational Neuroscience

المجال: إدراك ووعي ودماغ

التعريف العملي. يحاول تفسير النشاط العصبي بنماذج رياضية وديناميكية. داخل هذا الكتاب لا نعامل Computational Neuroscience ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في إدراك ووعي ودماغ نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Computational Neuroscience في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

37.4 الانتباه العصبي

Neural Attention

المجال: إدراك ووعي ودماغ

التعريف العملي. ليس مطابقا لانتباه المحولات لكنه يقدم استعارات مفيدة عن الاختيار والموارد. داخل هذا الكتاب لا نعامل Neural Attention ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في إدراك ووعي ودماغ نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Neural Attention في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

38.4 الوعي العملي

Operational Consciousness

المجال: إدراك ووعي ودماغ

ف العملي. نتعامل معه كقدرة قياس وتنظيم وتمثيل ذاتي، لا كادعاء ذاتية داخلية. داخل هذا الكتاب لا نعامل Operational Consciousness ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في إدراك ووعي ودماغ نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Operational Consciousness في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

39.4 الميتا-إدراك

Metacognition

المجال: إدراك ووعي ودماغ

التعريف العملي. قدرة النظام على تمثيل معرفته وجهله ومراقبة أدائه. داخل هذا الكتاب لا نعامل Metacognition ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في إدراك ووعي ودماغ نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Metacognition في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

40.4 نظرية التراكب الوعائي

Vascular Superposition Theory

المجال: إدراك ووعي ودماغ

التعريف العملي. صياغة بحثية مقترحة تربط الوعي بتراكب طبقات تنظيمية وديناميكية قابلة للاختبار. داخل هذا الكتاب لا نعامل Vascular Superposition Theory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في إدراك ووعي ودماغ نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Vascular Superposition Theory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

41.4 واجهة الدماغ والحاسوب

Brain-Computer Interface

المجال: إدراك ووعي ودماغ

تعريف العملي. تحول الإشارات العصبية إلى أوامر وتغذية راجعة ضمن حلقة تكيفية. داخل هذا الكتاب لا نعامل Brain-Computer Interface ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في إدراك ووعي ودماغ نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Brain-Computer Interface في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

42.4 تخطيط الدماغ الكهربائي

EEG

المجال: إدراك ووعي ودماغ

التعريف العملي. يوفر قياسا زمنيا سريعا لكنه منخفض الدقة المكانية وحساس للضجيج. داخل هذا الكتاب لا نعامل EEG ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في إدراك ووعي ودماغ نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال EEG في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

43.4 نماذج الحالة المعرفية

Cognitive State Models

المجال: إدراك ووعي ودماغ

التعريف العملي. تقدر التعب، الانتباه، الضغط، النية، أو الخطأ من إشارات متعددة. داخل هذا الكتاب لا نعامل Cognitive State Models ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في إدراك ووعي ودماغ نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Cognitive State Models في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

44.4 التحكم المشترك

Shared Control

المجال: إدراك ووعي ودماغ

التعريف العملي. يوزع الفعل بين الإنسان والآلة وفق الثقة والسياق والخطر. داخل هذا الكتاب لا نعامل Shared Control ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في إدراك ووعي ودماغ نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda \Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Shared Control في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

45.4 الخصوصية العصبية

Neuroprivacy

المجال: إدراك ووعي ودماغ

التعريف العملي. تحمي الإشارات العصبية من الاستنتاجات غير المرغوبة عن الشخص. داخل هذا الكتاب لا نعامل Neuroprivacy ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في إدراك ووعي ودماغ نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Neuroprivacy في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

46.4 النفس العصبية الحسابية

Computational Psychiatry

المجال: إدراك ووعي ودماغ

التعريف العملي. تفسر الأعراض كاختلال في التنبؤ، المكافأة، التحكم، أو التعلم. داخل هذا الكتاب لا نعامل Computational Psychiatry ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في إدراك ووعي ودماغ نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Computational Psychiatry في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

47.4 التعلم والنوم

Sleep and Learning

المجال: إدراك ووعي ودماغ

التعريف العملي. يربط التثبيت الذاكري والتنظيم العاطفي بإعادة تشغيل الأنماط العصبية. داخل هذا الكتاب لا نعامل Sleep and Learning ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في إدراك ووعي ودماغ نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Sleep and Learning في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

باب 5

الجزء الثالث: التعلم الآلي والإحصاء التطبيقي

هذا الجزء يربط بين النمذجة الإحصائية، التعميم، الانحياز، القياس، اختيار النماذج، والتجريب الأكاديمي الصارم.

1.5 الإدراك المتجسد

Embodied Cognition

المجال: إدراك ووعي ودماغ

التعريف العملي. يرى العقل موزعا بين الدماغ والجسم والبيئة، لا منعزلا داخل الرأس. داخل هذا الكتاب لا نعامل Embodied Cognition ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في إدراك ووعي ودماغ نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Embodied Cognition في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

2.5 الحوسبة الكمية

Quantum Computing

المجال: كمي وتعقيد

التعريف العملي. تستعمل التراكب والتشابك والقياس لبناء نماذج حساب مختلفة عن الكلاسيكية. داخل هذا الكتاب لا نعامل Quantum Computing ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في كمي وتعقيد نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Quantum Computing في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

3.5 مرحلة نيسك

NISQ

المجال: كمي وتعقيد

التعريف العملي. أجهزة كمية متوسطة وضوضائية تفيد تجريبيا لكنها ليست حواسيب كمية كاملة التصحيح. داخل هذا الكتاب لا نعامل NISQ ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في كمي وتعقيد نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\mathrm{signal}}}{P_{\mathrm{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال NISQ في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

4.5 التعلم الآلي الكمي

Quantum Machine Learning

المجال: كمي وتعقيد

التعريف العملي. يمزج تمثيلات كمية أو خوارزميات كمية مع أهداف تعلم إحصائي. داخل هذا الكتاب لا نعامل Quantum Machine Learning ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في كمي وتعقيد نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \mathrm{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Quantum Machine Learning في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

5.5 التصحيح الكمي للأخطاء

Quantum Error Correction

المجال: كمي وتعقيد

تعريف العملي. شرط مركزي للانتقال من تجارب ضوضائية إلى حوسبة كمية موثوقة. داخل هذا الكتاب لا نعامل Quantum Error Correction ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في كمي وتعقيد نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Quantum Error Correction في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

6.5 معلومات كمية

Quantum Information

المجال: كمي وتعقيد

التعريف العملي. تدرس الكيوبت، القنوات، الانتروبيا الكمية، والتشابك كمورد. داخل هذا الكتاب لا نعامل Quantum Information ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في كمي وتعقيد نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Quantum Information في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

7.5 التعقيد الحسابي

Computational Complexity

المجال: كمي وتعقيد

تعريف العملي. يفرق بين ما يمكن حله وما يمكن حله بكفاءة وما لا نعرف حدوده. داخل هذا الكتاب لا نعامل Computational Complexity ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في كمي وتعقيد نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Computational Complexity في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

8.5 نظرية الفوضى

Chaos Theory

المجال: كمي وتعقيد

التعريف العملي. تدرس الحساسية للشروط الابتدائية في أنظمة حتمية ظاهريا. داخل هذا الكتاب لا نعامل Chaos Theory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في كمي وتعقيد نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V)=\mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Chaos Theory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

9.5 الأنظمة المعقدة

Complex Systems

المجال: كمي وتعقيد

التعريف العملي. تبحث في ظهور الكل من تفاعلات محلية بين أجزاء كثيرة. داخل هذا الكتاب لا نعامل Complex Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في كمي وتعقيد نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Complex Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

10.5 نظرية التحكم

Control Theory

المجال: كمي وتعقيد

التعريف العملي. تضبط أنظمة ديناميكية عبر التغذية الراجعة والاستقرار والملاحظة. داخل هذا الكتاب لا نعامل Control Theory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في كمي وتعقيد نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Control Theory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

11.5 الفيزياء الإحصائية

Statistical Physics

المجال: كمي وتعقيد

التعريف العملي. تربط السلوك الجماعي بالاحتمال والطاقة والانتروبيا. داخل هذا الكتاب لا نعامل Statistical Physics ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في كمي وتعقيد نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Statistical Physics في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

12.5 علم الكون المعلوماتي

Information Cosmology

المجال: كمي وتعقيد

التعريف العملي. ينظر للكون بوصفه بنية معلوماتية وديناميكية لا مادة خام فقط. داخل هذا الكتاب لا نعامل Information Cosmology ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في كمي وتعقيد نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Information Cosmology في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

13.5 الرياضيات الفلسفية للزمن

Mathematics of Time

المجال: كمي وتعقيد

التعريف العملي. تميز بين الزمن الفيزيائي والزمن الداخلي والزمن الحسابي داخل النظام. داخل هذا الكتاب لا نعامل Mathematics of Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في كمي وتعقيد نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Mathematics of Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

14.5 هندسة الأنظمة

Systems Engineering

المجال: هندسة وأمان

لتعريف العملي. تنظم المتطلبات، الواجهات، المخاطر، الاختبارات، والتكامل في نظام حي. داخل هذا الكتاب لا نعامل Systems Engineering ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في هندسة وأمان نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Systems Engineering في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

15.5 عمليات التعلم الآلي

MLOps

المجال: هندسة وأمان

التعريف العملي. تدير دورة حياة النموذج: بيانات، تدريب، نشر، مراقبة، وإعادة تدريب. داخل هذا الكتاب لا نعامل MLOps ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في هندسة وأمان نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta) p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال MLOps في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

16.5 هندسة البيانات

Data Engineering

المجال: هندسة وأمان

التعريف العملي. تبني خطوطا موثوقة لجمع البيانات وتنظيفها وحفظ نسبها وإتاحتها. داخل هذا الكتاب لا نعامل Data Engineering ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في هندسة وأمان نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Data Engineering في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

17.5 الأمن السيبراني للذكاء الاصطناعي

AI Security

المجال: هندسة وأمان

التعريف العملي. يتعامل مع الحقن، التسميم، سرقة النموذج، وتسريب البيانات. داخل هذا الكتاب لا نعامل AI Security ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في هندسة وأمان نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda \Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال AI Security في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

18.5 التقييم المستمر

Continuous Evaluation

المجال: هندسة وأمان

التعريف العملي. يجعل القياس عملية تشغيلية مستمرة لا مرحلة قبل النشر فقط. داخل هذا الكتاب لا نعامل Continuous Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في هندسة وأمان نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Continuous Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

19.5 السلامة والمحاذاة

AI Safety and Alignment

المجال: هندسة وأمان

التعريف العملي. تحاول جعل سلوك النظام متوافقا مع القيم والقيود والنية البشرية. داخل هذا الكتاب لا نعامل AI Safety and Alignment ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في هندسة وأمان نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال AI Safety and Alignment في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

20.5 إدارة المخاطر

Risk Management

المجال: هندسة وأمان

التعريف العملي. تحدد الخطر واحتماله وأثره وضوابطه ومؤشرات الإنذار. داخل هذا الكتاب لا نعامل Risk Management ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في هندسة وأمان نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Risk Management في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

21.5 التفسيرية

Interpretability

المجال: هندسة وأمان

التعريف العملي. تبحث عن فهم داخلي لتمثيلات النموذج ومسارات قراره. داخل هذا الكتاب لا نعامل Interpretability ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في هندسة وأمان نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Interpretability في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

22.5 الخصوصية

Privacy

المجال: هندسة وأمان

التعريف العملي. توازن بين التعلم من البيانات وحماية الأفراد من التسريب والاستنتاج. داخل هذا الكتاب لا نعامل Privacy ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في هندسة وأمان نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Privacy في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

23.5 الحوسبة الموزعة

Distributed Computing

المجال: هندسة وأمان

التعريف العملي. تدرب النماذج الضخمة عبر عتاد متعدد واتصال محدود. داخل هذا الكتاب لا نعامل Distributed Computing ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في هندسة وأمان نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Distributed Computing في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

24.5 هندسة المعالجات

Accelerator Engineering

المجال: هندسة وأمان

التعريف العملي. تجعل الذكاء ممكنا اقتصاديا عبر وحدات معالجة وذاكرة واتصال عالي الإنتاجية. داخل هذا الكتاب لا نعامل Accelerator Engineering ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في هندسة وأمان نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \operatorname{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Accelerator Engineering في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

25.5 القياس الاقتصادي

AI Economics

المجال: هندسة وأمان

التعريف العملي. يدرس الكلفة، الإنتاجية، سوق العمل، والاحتكار المعرفي. داخل هذا الكتاب لا نعامل AI Economics ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في هندسة وأمان نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال AI Economics في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

26.5 القانون والتنظيم

AI Governance

المجال: هندسة وأمان

التعريف العملي. ينقل السلامة من نوايا مختبرية إلى التزامات ومساءلة. داخل هذا الكتاب لا نعامل AI Governance ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في هندسة وأمان نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال AI Governance في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

27.5 الأخلاق التطبيقية

Applied Ethics

المجال: هندسة وأمان

التعريف العملي. تسأل عمن يتضرر، من يقرر، وكيف نمنع تحويل الإنسان إلى بيانات بلا كرامة. داخل هذا الكتاب لا نعامل Applied Ethics ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في هندسة وأمان نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Applied Ethics في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

28.5 الجبر الخطي للنماذج في التدريب

Linear Algebra - Training

المجال: الرياضيات

التعريف العملي. المتجهات والمصفوفات والقيم الذاتية والتحليل الطيفي هي البنية الداخلية للتمثيلات، والانتباه، والتضمينات، وتقريب الدوال. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Linear Algebra - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V) = \mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Linear Algebra - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

29.5 الجبر الخطي للنماذج في التقييم

Linear Algebra - Evaluation

المجال: الرياضيات

التعريف العملي. المتجهات والمصفوفات والقيم الذاتية والتحليل الطيفي هي البنية الداخلية للتمثيلات، والانتباه، والتضمينات، وتقريب الدوال. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Linear Algebra - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Linear Algebra - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

30.5 الجبر الخطي للنماذج في الذاكرة

Linear Algebra - Memory

المجال: الرياضيات

التعريف العملي. المتجهات والمصفوفات والقيم الذاتية والتحليل الطيفي هي البنية الداخلية للتمثيلات، والانتباه، والتضمينات، وتقريب الدوال. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Linear Algebra - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Linear Algebra - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

31.5 الجبر الخطي للنماذج في البحث العلمي

Linear Algebra - Scientific Discovery

المجال: الرياضيات

التعريف العملي. المتجهات والمصفوفات والقيم الذاتية والتحليل الطيفي هي البنية الداخلية للتمثيلات، والانتباه، والتضمينات، وتقريب الدوال. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Linear Algebra - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Linear Algebra - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

32.5 حساب التفاضل والتدرج وقت الاستدلال

Differential Calculus - Inference Time

المجال: الرياضيات

التعريف العملي. التعلم الحديث هو هندسة تدرجات؛ كل تحديث وزن هو تقدير محلي لاتجاه يخفض الخسارة. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Differential Calculus - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Differential Calculus - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

33.5 حساب التفاضل والتدرج في السلامة

Differential Calculus - Safety

المجال: الرياضيات

التعريف العملي. التعلم الحديث هو هندسة تدرجات؛ كل تحديث وزن هو تقدير محلي لاتجاه يخفض الخسارة. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Differential Calculus - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Differential Calculus - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

34.5 حساب التفاضل والتدرج في الوكلاء

Differential Calculus - Agents

المجال: الرياضيات

التعريف العملي. التعلم الحديث هو هندسة تدرجات؛ كل تحديث وزن هو تقدير محلي لاتجاه يخفض الخسارة. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Differential Calculus - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Differential Calculus - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

35.5 حساب التفاضل والتدرج في الأنظمة الحقيقية

Differential Calculus - Real Systems

المجال: الرياضيات

التعريف العملي. التعلم الحديث هو هندسة تدرجات؛ كل تحديث وزن هو تقدير محلي لاتجاه يخفض الخسارة. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Differential Calculus - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Differential Calculus - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

36.5 الاحتمال البايزي في التدريب

Bayesian Probability - Training

المجال: الرياضيات

التعريف العملي. الاحتمال ليس تكرارا فقط بل درجة اعتقاد منظمة تتحدث عن المجهول وتستقبل الدليل. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Bayesian Probability - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Bayesian Probability - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

37.5 الاحتمال البايزي في التقييم

Bayesian Probability - Evaluation

المجال: الرياضيات

التعريف العملي. الاحتمال ليس تكرارا فقط بل درجة اعتقاد منظمة تتحدث عن المجهول وتستقبل الدليل. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Bayesian Probability - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda \Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Bayesian Probability - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

38.5 الاحتمال البايزي في الذاكرة

Bayesian Probability - Memory

المجال: الرياضيات

التعريف العملي. الاحتمال ليس تكرارا فقط بل درجة اعتقاد منظمة تتحدث عن المجهول وتستقبل الدليل. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Bayesian Probability - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Bayesian Probability - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

39.5 الاحتمال البايزي في البحث العلمي

Bayesian Probability - Scientific Discovery

المجال: الرياضيات

التعريف العملي. الاحتمال ليس تكرارا فقط بل درجة اعتقاد منظمة تتحدث عن المجهول وتستقبل الدليل. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Bayesian Probability - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Bayesian Probability - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

40.5 نظرية المعلومات وقت الاستدلال

Information Theory - Inference Time

المجال: الرياضيات

التعريف العملي. الانتروبيا والمعلومة المتبادلة والانضغاط تقدم لغة لقياس ما يحمله التمثيل وما يهمله. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Information Theory - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Information Theory - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

41.5 نظرية المعلومات في السلامة

Information Theory - Safety

المجال: الرياضيات

التعريف العملي. الانتروبيا والمعلومة المتبادلة والانضغاط تقدم لغة لقياس ما يحمله التمثيل وما يهمله. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Information Theory - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Information Theory - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

42.5 نظرية المعلومات في الوكلاء

Information Theory - Agents

المجال: الرياضيات

التعريف العملي. الانتروبيا والمعلومة المتبادلة والانضغاط تقدم لغة لقياس ما يحمله التمثيل وما يهمله. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Information Theory - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Information Theory - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

43.5 نظرية المعلومات في الأنظمة الحقيقية

Information Theory - Real Systems

المجال: الرياضيات

التعريف العملي. الانتروبيا والمعلومة المتبادلة والانضغاط تقدم لغة لقياس ما يحمله التمثيل وما يهمله. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Information Theory - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Information Theory - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

44.5 التحسين العددي في التدريب

Numerical Optimization - Training

المجال: الرياضيات

التعريف العملي. تدريب النموذج مسألة بحث في فضاء عال الأبعاد تحت ضوضاء، قيود، وانحناء غير متجانس. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Numerical Optimization - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \operatorname{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Numerical Optimization - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

45.5 التحسين العددي في التقييم

Numerical Optimization - Evaluation

المجال: الرياضيات

التعريف العملي. تدريب النموذج مسألة بحث في فضاء عال الأبعاد تحت ضوضاء، قيود، وانحناء غير متجانس. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Numerical Optimization - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Numerical Optimization - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

46.5 التحسين العددي في الذاكرة

Numerical Optimization - Memory

المجال: الرياضيات

التعريف العملي. تدريب النموذج مسألة بحث في فضاء عال الأبعاد تحت ضوضاء، قيود، وانحناء غير متجانس. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Numerical Optimization - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Numerical Optimization - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

47.5 التحسين العددي في البحث العلمي

Numerical Optimization - Scientific Discovery

المجال: الرياضيات

التعريف العملي. تدريب النموذج مسألة بحث في فضاء عال الأبعاد تحت ضوضاء، قيود، وانحناء غير متجانس. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Numerical Optimization - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Numerical Optimization - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

باب 6

الجزء الرابع: التعلم العميق وبنى النماذج الحديثة

ننتقل إلى الشبكات، الانتشار، المحولات، النماذج المختلطة، الذاكرة، والنماذج ذات فضاء الحالة.

1.6 الإحصاء الاستدلالي وقت الاستدلال

Inferential Statistics - Inference Time

المجال: الرياضيات

التعريف العملي. الاستدلال الإحصائي يحمي الباحث من خداع العينة ومن خلط الارتباط بالسببية. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Inferential Statistics - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V)=\mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Inferential Statistics - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

2.6 الإحصاء الاستدلالي في السلامة

Inferential Statistics - Safety

المجال: الرياضيات

التعريف العملي. الاستدلال الإحصائي يحمي الباحث من خداع العينة ومن خلط الارتباط بالسببية. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Inferential Statistics - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Inferential Statistics - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

3.6 الإحصاء الاستدلالي في الوكلاء

Inferential Statistics - Agents

المجال: الرياضيات

التعريف العملي. الاستدلال الإحصائي يحمي الباحث من خداع العينة ومن خلط الارتباط بالسببية. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Inferential Statistics - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Inferential Statistics - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

4.6 الإحصاء الاستدلالي في الأنظمة الحقيقية

Inferential Statistics - Real Systems

المجال: الرياضيات

التعريف العملي. الاستدلال الإحصائي يحمي الباحث من خداع العينة ومن خلط الارتباط بالسببية. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Inferential Statistics - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Inferential Statistics - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

5.6 العمليات العشوائية في التدريب

Stochastic Processes - Training

المجال: الرياضيات

التعريف العملي. السلاسل الزمنية، ماركوف، والانتشار العشوائي تفسر التعلم، التحكم، والنشاط العصبي كحركة احتمالية. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Stochastic Processes - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Stochastic Processes - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

6.6 العمليات العشوائية في التقييم

Stochastic Processes - Evaluation

المجال: الرياضيات

التعريف العملي. السلاسل الزمنية، ماركوف، والانتشار العشوائي تفسر التعلم، التحكم، والنشاط العصبي كحركة احتمالية. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Stochastic Processes - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Stochastic Processes - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

7.6 العمليات العشوائية في الذاكرة

Stochastic Processes - Memory

المجال: الرياضيات

التعريف العملي. السلاسل الزمنية، ماركوف، والانتشار العشوائي تفسر التعلم، التحكم، والنشاط العصبي كحركة احتمالية. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Stochastic Processes - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Stochastic Processes - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

8.6 العمليات العشوائية في البحث العلمي

Stochastic Processes - Scientific Discovery

المجال: الرياضيات

التعريف العملي. السلاسل الزمنية، ماركوف، والانتشار العشوائي تفسر التعلم، التحكم، والنشاط العصبي كحركة احتمالية. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Stochastic Processes - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Stochastic Processes - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

9.6 الطوبولوجيا والفضاءات وقت الاستدلال

Topology - Inference Time

المجال: الرياضيات

التعريف العملي. تصف الطوبولوجيا شكل فضاءات التمثيل: التجاور، الاستمرارية، العناقيد، والانقطاعات المفاهيمية. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Topology - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Topology - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

10.6 الطوبولوجيا والفضاءات في السلامة

Topology - Safety

المجال: الرياضيات

التعريف العملي. تصف الطوبولوجيا شكل فضاءات التمثيل: التجاور، الاستمرارية، العناقيد، والانقطاعات المفاهيمية. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Topology - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda \Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Topology - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

11.6 الطوبولوجيا والفضاءات في الوكلاء

Topology - Agents

المجال: الرياضيات

التعريف العملي. تصف الطوبولوجيا شكل فضاءات التمثيل: التجاور، الاستمرارية، العناقيد، والانقطاعات المفاهيمية. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Topology - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Topology - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

12.6 الطوبولوجيا والفضاءات في الأنظمة الحقيقية

Topology - Real Systems

المجال: الرياضيات

التعريف العملي. تصف الطوبولوجيا شكل فضاءات التمثيل: التجاور، الاستمرارية، العناقيد، والانقطاعات المفاهيمية. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Topology - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Topology - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

13.6 المنطق الرسمي في التدريب

Formal Logic - Training

المجال: الرياضيات

التعريف العملي. المنطق يحدد ما يعنيه أن تكون الحجة صحيحة حتى عندما يكون النص مقنعا لغويا. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Formal Logic - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Formal Logic - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

14.6 المنطق الرسمي في التقييم

Formal Logic - Evaluation

المجال: الرياضيات

التعريف العملي. المنطق يحدد ما يعنيه أن تكون الحجة صحيحة حتى عندما يكون النص مقنعا لغويا. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Formal Logic - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Formal Logic - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

15.6 المنطق الرسمي في الذاكرة

Formal Logic - Memory

المجال: الرياضيات

التعريف العملي. المنطق يحدد ما يعنيه أن تكون الحجة صحيحة حتى عندما يكون النص مقنعا لغويا. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Formal Logic - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Formal Logic - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

16.6 المنطق الرسمي في البحث العلمي

Formal Logic - Scientific Discovery

المجال: الرياضيات

التعريف العملي. المنطق يحدد ما يعنيه أن تكون الحجة صحيحة حتى عندما يكون النص مقنعا لغويا. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Formal Logic - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Formal Logic - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

17.6 نظرية القياس وقت الاستدلال

Measure Theory - Inference Time

المجال: الرياضيات

التعريف العملي. تمنح الاحتمال أساسه الدقيق عندما تصبح الفضاءات مستمرة ومعقدة وغير قابلة للعد البسيط. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Measure Theory - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \operatorname{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Measure Theory - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

18.6 نظرية القياس في السلامة

Measure Theory - Safety

المجال: الرياضيات

التعريف العملي. تمنح الاحتمال أساسه الدقيق عندما تصبح الفضاءات مستمرة ومعقدة وغير قابلة للعد البسيط. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Measure Theory - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Measure Theory - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

19.6 نظرية القياس في الوكلاء

Measure Theory - Agents

المجال: الرياضيات

التعريف العملي. تمنح الاحتمال أساسه الدقيق عندما تصبح الفضاءات مستمرة ومعقدة وغير قابلة للعد البسيط. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Measure Theory - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Measure Theory - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

20.6 نظرية القياس في الأنظمة الحقيقية

Measure Theory - Real Systems

المجال: الرياضيات

التعريف العملي. تمنح الاحتمال أساسه الدقيق عندما تصبح الفضاءات مستمرة ومعقدة وغير قابلة للعد البسيط. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Measure Theory - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Measure Theory - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

21.6 نظرية الألعاب في التدريب

Game Theory - Training

المجال: الرياضيات

التعريف العملي. كل وكيل ذكي يعيش بين حوافز متصارعة، ونظرية الألعاب تفكك الاستراتيجية، التوازن، والمخاطرة. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Game Theory - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V) = \mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Game Theory - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

22.6 نظرية الألعاب في التقييم

Game Theory - Evaluation

المجال: الرياضيات

التعريف العملي. كل وكيل ذكي يعيش بين حوافز متصارعة؛ ونظرية الألعاب تفكك الاستراتيجية، التوازن، والمخاطرة. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Game Theory - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Game Theory - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

23.6 نظرية الألعاب في الذاكرة

Game Theory - Memory

المجال: الرياضيات

التعريف العملي. كل وكيل ذكي يعيش بين حوافز متصارعة؛ ونظرية الألعاب تفكك الاستراتيجية، التوازن، والمخاطرة. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Game Theory - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Game Theory - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

24.6 نظرية الألعاب في البحث العلمي

Game Theory - Scientific Discovery

المجال: الرياضيات

التعريف العملي. كل وكيل ذكي يعيش بين حوافز متصارعة؛ ونظرية الألعاب تفكك الاستراتيجية، التوازن، والمخاطرة. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Game Theory - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Game Theory - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

25.6 الهندسة التفاضلية وقت الاستدلال

Differential Geometry - Inference Time

المجال: الرياضيات

التعريف العملي. تظهر في فهم فضاءات المعلمات، التعلم الطبيعي، ومناور التمثيل العميق. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Differential Geometry - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Differential Geometry - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

26.6 الهندسة التفاضلية في السلامة

Differential Geometry - Safety

المجال: الرياضيات

التعريف العملي. تظهر في فهم فضاءات المعلمات، التعلم الطبيعي، ومناور التمثيل العميق. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Differential Geometry - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Differential Geometry - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

27.6 الهندسة التفاضلية في الوكلاء

Differential Geometry - Agents

المجال: الرياضيات

التعريف العملي. تظهر في فهم فضاءات المعلمات، التعلم الطبيعي، ومناور التمثيل العميق. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Differential Geometry - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Differential Geometry - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

28.6 الهندسة التفاضلية في الأنظمة الحقيقية

Differential Geometry - Real Systems

المجال: الرياضيات

التعريف العملي. تظهر في فهم فضاءات المعلمات، التعلم الطبيعي، ومناور التمثيل العميق. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Differential Geometry - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الرياضيات نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Differential Geometry - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

29.6 البحث في فضاء الحالات في التدريب

State-Space Search - Training

المجال: الذكاء الكلاسيكي

التعريف العملي. جذر الذكاء الاصطناعي هو تحويل المشكلة إلى حالات، أفعال، كلفة، وهدف. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل State-Space Search - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال State-Space Search - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

30.6 البحث في فضاء الحالات في التقييم

State-Space Search - Evaluation

المجال: الذكاء الكلاسيكي

التعريف العملي. جذر الذكاء الاصطناعي هو تحويل المشكلة إلى حالات، أفعال، كلفة، وهدف. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل State-Space Search - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda \Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال State-Space Search - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

31.6 البحث في فضاء الحالات في الذاكرة

State-Space Search - Memory

المجال: الذكاء الكلاسيكي

التعريف العملي. جذر الذكاء الاصطناعي هو تحويل المشكلة إلى حالات، أفعال، كلفة، وهدف. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل State-Space Search - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال State-Space Search - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

32.6 البحث في فضاء الحالات في البحث العلمي

State-Space Search - Scientific Discovery

المجال: الذكاء الكلاسيكي

التعريف العملي. جذر الذكاء الاصطناعي هو تحويل المشكلة إلى حالات، أفعال، كلفة، وهدف. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل State-Space Search - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال State-Space Search - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

33.6 خوارزمية النجمة وقت الاستدلال

A-Star Search - Inference Time

المجال: الذكاء الكلاسيكي

التعريف العملي. تدمج الكلفة الماضية مع تقدير مستقبلي لتوجيه البحث نحو الهدف بكفاءة. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل A-Star Search - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال A-Star Search - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

34.6 خوارزمية النجمة في السلامة

A-Star Search - Safety

المجال: الذكاء الكلاسيكي

التعريف العملي. تدمج الكلفة الماضية مع تقدير مستقبلي لتوجيه البحث نحو الهدف بكفاءة. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل A-Star Search - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال A-Star Search - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

35.6 خوارزمية النجمة في الوكلاء

A-Star Search - Agents

المجال: الذكاء الكلاسيكي

التعريف العملي. تدمج الكلفة الماضية مع تقدير مستقبلي لتوجيه البحث نحو الهدف بكفاءة. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل A-Star Search - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال A-Star Search - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

36.6 خوارزمية النجمة في الأنظمة الحقيقية

A-Star Search - Real Systems

المجال: الذكاء الكلاسيكي

التعريف العملي. تدمج الكلفة الماضية مع تقدير مستقبلي لتوجيه البحث نحو الهدف بكفاءة. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل A-Star Search - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال A-Star Search - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

37.6 التخطيط الرمزي في التدريب

Symbolic Planning - Training

المجال: الذكاء الكلاسيكي

التعريف العملي. يعالج الفعل كسلسلة شروط وتأثيرات لا كمجرد نص مولد. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Symbolic Planning - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \operatorname{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Symbolic Planning - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

38.6 التخطيط الرمزي في التقييم

Symbolic Planning - Evaluation

المجال: الذكاء الكلاسيكي

التعريف العملي. يعالج الفعل كسلسلة شروط وتأثيرات لا كمجرد نص مولد. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Symbolic Planning - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Symbolic Planning - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

39.6 التخطيط الرمزي في الذاكرة

Symbolic Planning - Memory

المجال: الذكاء الكلاسيكي

التعريف العملي. يعالج الفعل كسلسلة شروط وتأثيرات لا كمجرد نص مولد. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Symbolic Planning - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Symbolic Planning - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

40.6 التخطيط الرمزي في البحث العلمي

Symbolic Planning - Scientific Discovery

المجال: الذكاء الكلاسيكي

التعريف العملي. يعالج الفعل كسلسلة شروط وتأثيرات لا كمجرد نص مولد. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Symbolic Planning - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Symbolic Planning - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

41.6 البرمجة القيدية وقت الاستدلال

Constraint Programming - Inference Time

المجال: الذكاء الكلاسيكي

التعريف العملي. تحول المشكلة إلى قيود يجب إرضاؤها، وتستعمل الاستبعاد الذكي بدل التجريب الأعمى. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Constraint Programming - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V)=\mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Constraint Programming - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

42.6 البرمجة القيدية في السلامة

Constraint Programming - Safety

المجال: الذكاء الكلاسيكي

التعريف العملي. تحول المشكلة إلى قيود يجب إرضاؤها، وتستعمل الاستبعاد الذكي بدل التجريب الأعمى. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Constraint Programming - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Constraint Programming - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

43.6 البرمجة القيدية في الوكلاء

Constraint Programming - Agents

المجال: الذكاء الكلاسيكي

التعريف العملي. تحول المشكلة إلى قيود يجب إرضاؤها، وتستعمل الاستبعاد الذكي بدل التجريب الأعمى. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Constraint Programming - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Constraint Programming - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

44.6 البرمجة القيدية في الأنظمة الحقيقية

Constraint Programming - Real Systems

المجال: الذكاء الكلاسيكي

التعريف العملي. تحول المشكلة إلى قيود يجب إرضاؤها، وتستعمل الاستبعاد الذكي بدل التجريب الأعمى. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Constraint Programming - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Constraint Programming - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

45.6 الشبكات البايزية في التدريب

Bayesian Networks - Training

المجال: الذكاء الكلاسيكي

التعريف العملي. تمثل الاعتماد الشرطي بين المتغيرات وتسمح باستدلال سببي واحتمالي. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Bayesian Networks - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Bayesian Networks - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

46.6 الشبكات البايزية في التقييم

Bayesian Networks - Evaluation

المجال: الذكاء الكلاسيكي

التعريف العملي. تمثل الاعتماد الشرطي بين المتغيرات وتسمح باستدلال سببي واحتمالي. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Bayesian Networks - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Bayesian Networks - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

47.6 الشبكات البايزية في الذاكرة

Bayesian Networks - Memory

المجال: الذكاء الكلاسيكي

التعريف العملي. تمثل الاعتماد الشرطي بين المتغيرات وتسمح باستدلال سببي واحتمالي. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Bayesian Networks - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Bayesian Networks - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

باب 7

الجزء الخامس: النماذج اللغوية الكبيرة ونماذج الاستدلال

القلب العملي للمشروع: التدريب الذاتي، التوجيه، التحقق، البحث وقت الاستدلال، السلاسل الطويلة، الوكلاء، الأدوات، والذاكرة.

1.7 الشبكات البايزية في البحث العلمي

Bayesian Networks - Scientific Discovery

المجال: الذكاء الكلاسيكي

التعريف العملي. تمثل الاعتماد الشرطي بين المتغيرات وتسمح باستدلال سببي واحتمالي. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Bayesian Networks - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Bayesian Networks - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

2.7 نماذج ماركوف المخفية وقت الاستدلال

Hidden Markov Models - Inference Time

المجال: الذكاء الكلاسيكي

التعريف العملي. تتعامل مع حالات خفية تولد ملاحظات، وهي أصل مهم في الكلام والسلاسل الحيوية. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Hidden Markov Models - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Hidden Markov Models - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

3.7 نماذج ماركوف المخفية في السلامة

Hidden Markov Models - Safety

المجال: الذكاء الكلاسيكي

التعريف العملي. تتعامل مع حالات خفية تولد ملاحظات، وهي أصل مهم في الكلام والسلاسل الحيوية. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Hidden Markov Models - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda \Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Hidden Markov Models - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

4.7 نماذج ماركوف المخفية في الوكلاء

Hidden Markov Models - Agents

المجال: الذكاء الكلاسيكي

التعريف العملي. تتعامل مع حالات خفية تولد ملاحظات، وهي أصل مهم في الكلام والسلاسل الحيوية. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Hidden Markov Models - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Hidden Markov Models - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

5.7 نماذج ماركوف المخفية في الأنظمة الحقيقية

Hidden Markov Models - Real Systems

المجال: الذكاء الكلاسيكي

التعريف العملي. تتعامل مع حالات خفية تولد ملاحظات، وهي أصل مهم في الكلام والسلاسل الحيوية. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Hidden Markov Models - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Hidden Markov Models - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

6.7 عمليات القرار الماركوفي في التدريب

Markov Decision Processes - Training

المجال: الذكاء الكلاسيكي

التعريف العملي. تؤطر القرار كحالات وأفعال ومكافآت وانتقالات، وهي قاعدة التعلم المعزز. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Markov Decision Processes - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Markov Decision Processes - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

7.7 عمليات القرار الماركوفي في التقييم

Markov Decision Processes - Evaluation

المجال: الذكاء الكلاسيكي

التعريف العملي. تؤطر القرار كحالات وأفعال ومكافآت وانتقالات، وهي قاعدة التعلم المعزز. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Markov Decision Processes - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Markov Decision Processes - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

8.7 عمليات القرار الماركوفي في الذاكرة

Markov Decision Processes - Memory

المجال: الذكاء الكلاسيكي

التعريف العملي. تؤطر القرار كحالات وأفعال ومكافآت وانتقالات، وهي قاعدة التعلم المعزز. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Markov Decision Processes - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Markov Decision Processes - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

9.7 عمليات القرار الماركوفي في البحث العلمي

Markov Decision Processes - Scientific Discovery

المجال: الذكاء الكلاسيكي

التعريف العملي. تؤطر القرار كحالات وأفعال ومكافآت وانتقالات، وهي قاعدة التعلم المعزز. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Markov Decision Processes - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Markov Decision Processes - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

10.7 البحث الشجري وقت الاستدلال

Tree Search - Inference Time

المجال: الذكاء الكلاسيكي

التعريف العملي. يفتح بدائل الفعل على هيئة شجرة ويوازن بين الاستكشاف والاستغلال. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Tree Search - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \operatorname{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Tree Search - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

11.7 البحث الشجري في السلامة

Tree Search - Safety

المجال: الذكاء الكلاسيكي

التعريف العملي. يفتح بدائل الفعل على هيئة شجرة ويوازن بين الاستكشاف والاستغلال. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Tree Search - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Tree Search - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

12.7 البحث الشجري في الوكلاء

Tree Search - Agents

المجال: الذكاء الكلاسيكي

التعريف العملي. يفتح بدائل الفعل على هيئة شجرة ويوازن بين الاستكشاف والاستغلال. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Tree Search - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Tree Search - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

13.7 البحث الشجري في الأنظمة الحقيقية

Tree Search - Real Systems

المجال: الذكاء الكلاسيكي

التعريف العملي. يفتح بدائل الفعل على هيئة شجرة ويوازن بين الاستكشاف والاستغلال. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Tree Search - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Tree Search - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

14.7 تمثيل المعرفة في التدريب

Knowledge Representation - Training

المجال: الذكاء الكلاسيكي

التعريف العملي. يسأل كيف نمثل الحقائق والعلاقات والقواعد كي تصبح قابلة للاستدلال. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Knowledge Representation - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V)=\mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Knowledge Representation - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

15.7 تمثيل المعرفة في التقييم

Knowledge Representation - Evaluation

المجال: الذكاء الكلاسيكي

التعريف العملي. يسأل كيف نمثل الحقائق والعلاقات والقواعد كي تصبح قابلة للاستدلال. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Knowledge Representation - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Knowledge Representation - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

16.7 تمثيل المعرفة في الذاكرة

Knowledge Representation - Memory

المجال: الذكاء الكلاسيكي

التعريف العملي. يسأل كيف نمثل الحقائق والعلاقات والقواعد كي تصبح قابلة للاستدلال. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Knowledge Representation - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \, \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Knowledge Representation - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

17.7 تمثيل المعرفة في البحث العلمي

Knowledge Representation - Scientific Discovery

المجال: الذكاء الكلاسيكي

التعريف العملي. يسأل كيف نمثل الحقائق والعلاقات والقواعد كي تصبح قابلة للاستدلال. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Knowledge Representation - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Knowledge Representation - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

18.7 الأنطولوجيات وقت الاستدلال

Ontologies - Inference Time

المجال: الذكاء الكلاسيكي

التعريف العملي. تمنح المجال مفردات منظمة وعلاقات رسمية تمنع فوضى المعنى. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Ontologies - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Ontologies - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

19.7 الأنطولوجيات في السلامة

Ontologies - Safety

المجال: الذكاء الكلاسيكي

التعريف العملي. تمنح المجال مفردات منظمة وعلاقات رسمية تمنع فوضى المعنى. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Ontologies - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Ontologies - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

20.7 الأنطولوجيات في الوكلاء

Ontologies - Agents

المجال: الذكاء الكلاسيكي

التعريف العملي. تمنح المجال مفردات منظمة وعلاقات رسمية تمنع فوضى المعنى. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Ontologies - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Ontologies - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

21.7 الأنطولوجيات في الأنظمة الحقيقية

Ontologies - Real Systems

المجال: الذكاء الكلاسيكي

التعريف العملي. تمنح المجال مفردات منظمة وعلاقات رسمية تمنع فوضى المعنى. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Ontologies - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Ontologies - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

22.7 الاستدلال غير الرتيب في التدريب

Non-Monotonic Reasoning - Training

المجال: الذكاء الكلاسيكي

التعريف العملي. في العالم الواقعي قد تلغي معلومة جديدة استنتاجا قديما، وهذا يتجاوز المنطق المدرسي. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Non-Monotonic Reasoning - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Non-Monotonic Reasoning - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

23.7 الاستدلال غير الرتيب في التقييم

Non-Monotonic Reasoning - Evaluation

المجال: الذكاء الكلاسيكي

التعريف العملي. في العالم الواقعي قد تلغي معلومة جديدة استنتاجا قديما، وهذا يتجاوز المنطق المدرسي. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Non-Monotonic Reasoning - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda \Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Non-Monotonic Reasoning - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

24.7 الاستدلال غير الرتيب في الذاكرة

Non-Monotonic Reasoning - Memory

المجال: الذكاء الكلاسيكي

التعريف العملي. في العالم الواقعي قد تلغي معلومة جديدة استنتاجا قديما، وهذا يتجاوز المنطق المدرسي. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Non-Monotonic Reasoning - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Non-Monotonic Reasoning - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

25.7 الاستدلال غير الرتيب في البحث العلمي

Non-Monotonic Reasoning - Scientific Discovery

المجال: الذكاء الكلاسيكي

التعريف العملي. في العالم الواقعي قد تلغي معلومة جديدة استنتاجا قديما، وهذا يتجاوز المنطق المدرسي. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Non-Monotonic Reasoning - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Non-Monotonic Reasoning - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

26.7 حل المسائل العامة وقت الاستدلال

General Problem Solving - Inference Time

المجال: الذكاء الكلاسيكي

التعريف العملي. يربط الهدف بالاستراتيجية والتمثيل والتقييم، وهو سلف مباشر لفكرة الوكيل الذكي. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل General Problem Solving - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال General Problem Solving - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

27.7 حل المسائل العامة في السلامة

General Problem Solving - Safety

المجال: الذكاء الكلاسيكي

التعريف العملي. يربط الهدف بالاستراتيجية والتمثيل والتقييم، وهو سلف مباشر لفكرة الوكيل الذكي. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل General Problem Solving - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال General Problem Solving - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

28.7 حل المسائل العامة في الوكلاء

General Problem Solving - Agents

المجال: الذكاء الكلاسيكي

التعريف العملي. يربط الهدف بالاستراتيجية والتمثيل والتقييم، وهو سلف مباشر لفكرة الوكيل الذكي. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل General Problem Solving - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال General Problem Solving - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

29.7 حل المسائل العامة في الأنظمة الحقيقية

General Problem Solving - Real Systems

المجال: الذكاء الكلاسيكي

التعريف العملي. يربط الهدف بالاستراتيجية والتمثيل والتقييم، وهو سلف مباشر لفكرة الوكيل الذكي. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل General Problem Solving - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في الذكاء الكلاسيكي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال General Problem Solving - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

30.7 الانحدار الخطي في التدريب

Linear Regression - Training

المجال: تعلم آلي

التعريف العملي. أبسط نموذج يوضح معنى الملاءمة، الخطأ، التعميم، والتفسير العددي. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Linear Regression - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \operatorname{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Linear Regression - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

31.7 الانحدار الخطي في التقييم

Linear Regression - Evaluation

المجال: تعلم آلي

التعريف العملي. أبسط نموذج يوضح معنى الملاءمة، الخطأ، التعميم، والتفسير العددي. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Linear Regression - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Linear Regression - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

32.7 الانحدار الخطي في الذاكرة

Linear Regression - Memory

المجال: تعلم آلي

التعريف العملي. أبسط نموذج يوضح معنى الملاءمة، الخطأ، التعميم، والتفسير العددي. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Linear Regression - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Linear Regression - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

33.7 الانحدار الخطي في البحث العلمي

Linear Regression - Scientific Discovery

المجال: تعلم آلي

التعريف العملي. أبسط نموذج يوضح معنى الملاءمة، الخطأ، التعميم، والتفسير العددي. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Linear Regression - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Linear Regression - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

34.7 الانحدار اللوجستي وقت الاستدلال

Logistic Regression - Inference Time

المجال: تعلم آلي

التعريف العملي. يربط الخطي بالاحتمالي عبر دالة سيغمويد لتصنيف ثنائي قابل للتفسير. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Logistic Regression - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V)=\mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Logistic Regression - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

35.7 الانحدار اللوجستي في السلامة

Logistic Regression - Safety

المجال: تعلم آلي

التعريف العملي. يربط الخطي بالاحتمالي عبر دالة سيغمويد لتصنيف ثنائي قابل للتفسير. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Logistic Regression - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Logistic Regression - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

36.7 الانحدار اللوجستي في الوكلاء

Logistic Regression - Agents

المجال: تعلم آلي

التعريف العملي. يربط الخطي بالاحتمالي عبر دالة سيغمويد لتصنيف ثنائي قابل للتفسير. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Logistic Regression - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Logistic Regression - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

37.7 الانحدار اللوجستي في الأنظمة الحقيقية

Logistic Regression - Real Systems

المجال: تعلم آلي

التعريف العملي. يربط الخطي بالاحتمالي عبر دالة سيغمويد لتصنيف ثنائي قابل للتفسير. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Logistic Regression - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Logistic Regression - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

38.7 آلات المتجهات الداعمة في التدريب

Support Vector Machines - Training

المجال: تعلم آلي

التعريف العملي. تبحث عن هامش فاصل أقصى وتكشف قيمة الهندسة في التصنيف. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Support Vector Machines - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Support Vector Machines - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

39.7 آلات المتجهات الداعمة في التقييم

Support Vector Machines - Evaluation

المجال: تعلم آلي

التعريف العملي. تبحث عن هامش فاصل أقصى وتكشف قيمة الهندسة في التصنيف. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Support Vector Machines - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Support Vector Machines - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

40.7 آلات المتجهات الداعمة في الذاكرة

Support Vector Machines - Memory

المجال: تعلم آلي

التعريف العملي. تبحث عن هامش فاصل أقصى وتكشف قيمة الهندسة في التصنيف. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Support Vector Machines - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Support Vector Machines - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

41.7 آلات المتجهات الداعمة في البحث العلمي

Support Vector Machines - Scientific Discovery

المجال: تعلم آلي

التعريف العملي. تبحث عن هامش فاصل أقصى وتكشف قيمة الهندسة في التصنيف. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Support Vector Machines - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Support Vector Machines - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

42.7 الأشجار العشوائية وقت الاستدلال

Random Forests - Inference Time

المجال: تعلم آلي

التعريف العملي. تجمع أشجارا ضعيفة نسبيا لتقليل التباين وتحسين الثبات. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Random Forests - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Random Forests - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

43.7 الأشجار العشوائية في السلامة

Random Forests - Safety

المجال: تعلم آلي

التعريف العملي. تجمع أشجارا ضعيفة نسبيا لتقليل التباين وتحسين الثبات. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Random Forests - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda \Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Random Forests - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

44.7 الأشجار العشوائية في الوكلاء

Random Forests - Agents

المجال: تعلم آلي

التعريف العملي. تجمع أشجارا ضعيفة نسبيا لتقليل التباين وتحسين الثبات. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Random Forests - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Random Forests - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

45.7 الأشجار العشوائية في الأنظمة الحقيقية

Random Forests - Real Systems

المجال: تعلم آلي

التعريف العملي. تجمع أشجارا ضعيفة نسبيا لتقليل التباين وتحسين الثبات. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Random Forests - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Random Forests - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

46.7 التعزيز التدرجي في التدريب

Gradient Boosting - Training

المجال: تعلم آلي

التعريف العملي. يبني نموذجا قويا بإضافة مصححات متتالية لأخطاء النماذج السابقة. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Gradient Boosting - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Gradient Boosting - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

47.7 التعزيز التدرجي في التقييم

Gradient Boosting - Evaluation

المجال: تعلم آلي

التعريف العملي. يبني نموذجا قويا بإضافة مصححات متتالية لأخطاء النماذج السابقة. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Gradient Boosting - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Gradient Boosting - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

باب 8

الجزء السادس: الذكاء العام الاصطناعي والهندسة الوكيلية

الذكاء العام هنا ليس كلمة دعائية؛ إنه نظام حلقات تدريب واستدلال وأدوات وذاكرة وتقييم وحوكمة.

1.8 التعزيز التدرجي في الذاكرة

Gradient Boosting - Memory

المجال: تعلم آلي

التعريف العملي. يبني نموذجا قويا بإضافة مصححات متتالية لأخطاء النماذج السابقة. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Gradient Boosting - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Gradient Boosting - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب

الأهداف.

2.8 التعزيز التدرجي في البحث العلمي

Gradient Boosting - Scientific Discovery

المجال: تعلم آلي

التعريف العملي. يبني نموذجا قويا بإضافة مصححات متتالية لأخطاء النماذج السابقة. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Gradient Boosting - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Gradient Boosting - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

3.8 تحليل المكونات الرئيسية وقت الاستدلال

PCA - Inference Time

المجال: تعلم آلي

التعريف العملي. يضغط البيانات إلى اتجاهات تفسر أكبر قدر من التباين. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل PCA - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \operatorname{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال PCA - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

4.8 تحليل المكونات الرئيسية في السلامة

PCA - Safety

المجال: تعلم آلي

التعريف العملي. يضغط البيانات إلى اتجاهات تفسر أكبر قدر من التباين. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل PCA - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال PCA - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

5.8 تحليل المكونات الرئيسية في الوكلاء

PCA - Agents

المجال: تعلم آلي

التعريف العملي. يضغط البيانات إلى اتجاهات تفسر أكبر قدر من التباين. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل PCA - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال PCA - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

6.8 تحليل المكونات الرئيسية في الأنظمة الحقيقية

PCA - Real Systems

المجال: تعلم آلي

التعريف العملي. يضغط البيانات إلى اتجاهات تفسر أكبر قدر من التباين. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل PCA - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال PCA - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

7.8 العناقيد في التدريب

Clustering - Training

المجال: تعلم آلي

التعريف العملي. يكشف بنى غير موسومة عبر القرب، الكثافة، أو النموذج الاحتمالي. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Clustering - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V)=\mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Clustering - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

8.8 العناقيد في التقييم

Clustering - Evaluation

المجال: تعلم آلي

التعريف العملي. يكشف بنى غير موسومة عبر القرب، الكثافة، أو النموذج الاحتمالي. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Clustering - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Clustering - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

9.8 العناقيد في الذاكرة

Clustering - Memory

المجال: تعلم آلي

التعريف العملي. يكشف بنى غير موسومة عبر القرب، الكثافة، أو النموذج الاحتمالي. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Clustering - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Clustering - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

10.8 العناقيد في البحث العلمي

Clustering - Scientific Discovery

المجال: تعلم آلي

التعريف العملي. يكشف بنى غير موسومة عبر القرب، الكثافة، أو النموذج الاحتمالي. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Clustering - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Clustering - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

11.8 النماذج الخليطية وقت الاستدلال

Gaussian Mixture Models - Inference Time

المجال: تعلم آلي

التعريف العملي. تفترض أن البيانات صادرة عن خليط توزيعات وتستعمل خوارزمية التوقع والتعظيم. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Gaussian Mixture Models - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Gaussian Mixture Models - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

12.8 النماذج الخليطية في السلامة

Gaussian Mixture Models - Safety

المجال: تعلم آلي

التعريف العملي. تفترض أن البيانات صادرة عن خليط توزيعات وتستعمل خوارزمية التوقع والتعظيم. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Gaussian Mixture Models - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Gaussian Mixture Models - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

13.8 النماذج الخليطية في الوكلاء

Gaussian Mixture Models - Agents

المجال: تعلم آلي

التعريف العملي. تفترض أن البيانات صادرة عن خليط توزيعات وتستعمل خوارزمية التوقع والتعظيم. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Gaussian Mixture Models - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Gaussian Mixture Models - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

14.8 النماذج الخليطية في الأنظمة الحقيقية

Gaussian Mixture Models - Real Systems

المجال: تعلم آلي

التعريف العملي. تفترض أن البيانات صادرة عن خليط توزيعات وتستعمل خوارزمية التوقع والتعظيم. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Gaussian Mixture Models - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Gaussian Mixture Models - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

15.8 التحقق المتقاطع في التدريب

Cross-Validation - Training

المجال: تعلم آلي

التعريف العملي. يقيس التعميم على تقسيمات متعددة بدل الثقة في تقسيم واحد. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Cross-Validation - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Cross-Validation - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

16.8 التحقق المتقاطع في التقييم

Cross-Validation - Evaluation

المجال: تعلم آلي

التعريف العملي. يقيس التعميم على تقسيمات متعددة بدل الثقة في تقسيم واحد. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Cross-Validation - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda \Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Cross-Validation - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

17.8 التحقق المتقاطع في الذاكرة

Cross-Validation - Memory

المجال: تعلم آلي

التعريف العملي. يقيس التعميم على تقسيمات متعددة بدل الثقة في تقسيم واحد. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Cross-Validation - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Cross-Validation - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

18.8 التحقق المتقاطع في البحث العلمي

Cross-Validation - Scientific Discovery

المجال: تعلم آلي

التعريف العملي. يقيس التعميم على تقسيمات متعددة بدل الثقة في تقسيم واحد. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Cross-Validation - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Cross-Validation - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

19.8 اختبار الفرضيات وقت الاستدلال

Hypothesis Testing - Inference Time

المجال: تعلم آلي

التعريف العملي. يفرق بين الأثر الحقيقي والتذبذب العيني وفق تصميم إحصائي. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Hypothesis Testing - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Hypothesis Testing - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

20.8 اختبار الفرضيات في السلامة

Hypothesis Testing - Safety

المجال: تعلم آلي

التعريف العملي. يفرق بين الأثر الحقيقي والتذبذب العيني وفق تصميم إحصائي. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Hypothesis Testing - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Hypothesis Testing - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

21.8 اختبار الفرضيات في الوكلاء

Hypothesis Testing - Agents

المجال: تعلم آلي

التعريف العملي. يفرق بين الأثر الحقيقي والتذبذب العيني وفق تصميم إحصائي. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Hypothesis Testing - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Hypothesis Testing - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

22.8 اختبار الفرضيات في الأنظمة الحقيقية

Hypothesis Testing - Real Systems

المجال: تعلم آلي

التعريف العملي. يفرق بين الأثر الحقيقي والتذبذب العيني وفق تصميم إحصائي. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Hypothesis Testing - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Hypothesis Testing - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

23.8 السببية العملية في التدريب

Causal Inference - Training

المجال: تعلم آلي

التعريف العملي. تسأل عما يحدث عند التدخل، لا عما يصاحب ماذا فقط. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Causal Inference - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \operatorname{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Causal Inference - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

24.8 السببية العملية في التقييم

Causal Inference - Evaluation

المجال: تعلم آلي

التعريف العملي. تسأل عما يحدث عند التدخل، لا عما يصاحب ماذا فقط. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Causal Inference - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Causal Inference - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

25.8 السببية العملية في الذاكرة

Causal Inference - Memory

المجال: تعلم آلي

التعريف العملي. تسأل عما يحدث عند التدخل، لا عما يصاحب ماذا فقط. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Causal Inference - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Causal Inference - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

26.8 السببية العملية في البحث العلمي

Causal Inference - Scientific Discovery

المجال: تعلم آلي

التعريف العملي. تسأل عما يحدث عند التدخل، لا عما يصاحب ماذا فقط. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Causal Inference - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Causal Inference - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

27.8 التعلم شبه المراقب وقت الاستدلال

Semi-Supervised Learning - Inference Time

المجال: تعلم آلي

التعريف العملي. يستغل البيانات غير الموسومة عندما تكون الوسوم نادرة ومكلفة. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Semi-Supervised Learning - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V)=\mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Semi-Supervised Learning - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

28.8 التعلم شبه المراقب في السلامة

Semi-Supervised Learning - Safety

المجال: تعلم آلي

التعريف العملي. يستغل البيانات غير الموسومة عندما تكون الوسوم نادرة ومكلفة. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Semi-Supervised Learning - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Semi-Supervised Learning - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

29.8 التعلم شبه المراقب في الوكلاء

Semi-Supervised Learning - Agents

المجال: تعلم آلي

التعريف العملي. يستغل البيانات غير الموسومة عندما تكون الوسوم نادرة ومكلفة. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Semi-Supervised Learning - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Semi-Supervised Learning - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

30.8 التعلم شبه المراقب في الأنظمة الحقيقية

Semi-Supervised Learning - Real Systems

المجال: تعلم آلي

التعريف العملي. يستغل البيانات غير الموسومة عندما تكون الوسوم نادرة ومكلفة. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Semi-Supervised Learning - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم آلي نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Semi-Supervised Learning - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

31.8 الشبكات متعددة الطبقات في التدريب

Multilayer Perceptrons - Training

المجال: تعلم عميق

التعريف العملي. تقرب الدوال المعقدة عبر تراكيب غير خطية من تحويلات خطية وتنشيطات. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Multilayer Perceptrons - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Multilayer Perceptrons - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

32.8 الشبكات متعددة الطبقات في التقييم

Multilayer Perceptrons - Evaluation

المجال: تعلم عميق

التعريف العملي. تقرب الدوال المعقدة عبر تراكيب غير خطية من تحويلات خطية وتنشيطات. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Multilayer Perceptrons - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Multilayer Perceptrons - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

33.8 الشبكات متعددة الطبقات في الذاكرة

Multilayer Perceptrons - Memory

المجال: تعلم عميق

التعريف العملي. تقرب الدوال المعقدة عبر تراكيب غير خطية من تحويلات خطية وتنشيطات. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Multilayer Perceptrons - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Multilayer Perceptrons - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

34.8 الشبكات متعددة الطبقات في البحث العلمي

Multilayer Perceptrons - Scientific Discovery

المجال: تعلم عميق

التعريف العملي. تقرب الدوال المعقدة عبر تراكيب غير خطية من تحويلات خطية وتنشيطات. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Multilayer Perceptrons - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Multilayer Perceptrons - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

35.8 الانتشار العكسي وقت الاستدلال

Backpropagation - Inference Time

المجال: تعلم عميق

التعريف العملي. يحسب تدرجات الخسارة بكفاءة عبر قاعدة السلسلة. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Backpropagation - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Backpropagation - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

36.8 الانتشار العكسي في السلامة

Backpropagation - Safety

المجال: تعلم عميق

التعريف العملي. يحسب تدرجات الخسارة بكفاءة عبر قاعدة السلسلة. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Backpropagation - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda\Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Backpropagation - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

37.8 الانتشار العكسي في الوكلاء

Backpropagation - Agents

المجال: تعلم عميق

التعريف العملي. يحسب تدرجات الخسارة بكفاءة عبر قاعدة السلسلة. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Backpropagation - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Backpropagation - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

38.8 الانتشار العكسي في الأنظمة الحقيقية

Backpropagation - Real Systems

المجال: تعلم عميق

التعريف العملي. يحسب تدرجات الخسارة بكفاءة عبر قاعدة السلسلة. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Backpropagation - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Backpropagation - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

39.8 الشبكات الالتفافية في التدريب

Convolutional Neural Networks - Training

المجال: تعلم عميق

التعريف العملي. تستغل المحلية والتشارك الوزني لفهم الصور والإشارات. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Convolutional Neural Networks - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Convolutional Neural Networks - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

40.8 الشبكات الالتفافية في التقييم

Convolutional Neural Networks - Evaluation

المجال: تعلم عميق

التعريف العملي. تستغل المحلية والتشارك الوزني لفهم الصور والإشارات. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Convolutional Neural Networks - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Convolutional Neural Networks - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

41.8 الشبكات الالتفافية في الذاكرة

Convolutional Neural Networks - Memory

المجال: تعلم عميق

التعريف العملي. تستغل المحلية والتشارك الوزني لفهم الصور والإشارات. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Convolutional Neural Networks - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Convolutional Neural Networks - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

42.8 الشبكات الالتفافية في البحث العلمي

Convolutional Neural Networks - Scientific Discovery

المجال: تعلم عميق

التعريف العملي. تستغل المحلية والتشارك الوزني لفهم الصور والإشارات. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Convolutional Neural Networks - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Convolutional Neural Networks - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

43.8 الشبكات المتكررة وقت الاستدلال

Recurrent Neural Networks - Inference Time

المجال: تعلم عميق

التعريف العملي. تعالج التسلسل ذاكرة بخطوة، لكنها تعاني من التدرجات الطويلة. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Recurrent Neural Networks - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \operatorname{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Recurrent Neural Networks - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

44.8 الشبكات المتكررة في السلامة

Recurrent Neural Networks - Safety

المجال: تعلم عميق

التعريف العملي. تعالج التسلسل ذاكرة بخطوة، لكنها تعاني من التدرجات الطويلة. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Recurrent Neural Networks - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Recurrent Neural Networks - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

45.8 الشبكات المتكررة في الوكلاء

Recurrent Neural Networks - Agents

المجال: تعلم عميق

التعريف العملي. تعالج التسلسل ذاكرة بخطوة، لكنها تعاني من التدرجات الطويلة. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Recurrent Neural Networks - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Recurrent Neural Networks - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

46.8 الشبكات المتكررة في الأنظمة الحقيقية

Recurrent Neural Networks - Real Systems

المجال: تعلم عميق

التعريف العملي. تعالج التسلسل ذاكرة بخطوة، لكنها تعاني من التدرجات الطويلة. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Recurrent Neural Networks - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Recurrent Neural Networks - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

47.8 آليات الانتباه في التدريب

Attention Mechanisms - Training

المجال: تعلم عميق

التعريف العملي. تجعل النموذج يختار ما يهم من السياق بدل ضغط كل شيء في حالة واحدة. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Attention Mechanisms - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V)=\mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Attention Mechanisms - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

باب 9

الجزء السابع: الإدراك، الوعي، الدماغ، وواجهة الدماغ والحاسوب

هذا الجزء يربط علم الأعصاب، الإدراك، الوعي العملي، القياس العصبي، وواجهات الدماغ مع الذكاء الآلي.

1.9 آليات الانتباه في التقييم

Attention Mechanisms - Evaluation

المجال: تعلم عميق

التعريف العملي. تجعل النموذج يختار ما يهم من السياق بدل ضغط كل شيء في حالة واحدة. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Attention Mechanisms - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Attention Mechanisms - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

2.9 آليات الانتباه في الذاكرة

Attention Mechanisms - Memory

المجال: تعلم عميق

التعريف العملي. تجعل النموذج يختار ما يهم من السياق بدل ضغط كل شيء في حالة واحدة. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Attention Mechanisms - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Attention Mechanisms - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

3.9 آليات الانتباه في البحث العلمي

Attention Mechanisms - Scientific Discovery

المجال: تعلم عميق

التعريف العملي. تجعل النموذج يختار ما يهم من السياق بدل ضغط كل شيء في حالة واحدة. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Attention Mechanisms - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Attention Mechanisms - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

4.9 المحول وقت الاستدلال

Transformer - Inference Time

المجال: تعلم عميق

التعريف العملي. بنية الانتباه الذاتي صارت العمود الفقري للنماذج اللغوية والرؤيوية الحديثة. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Transformer - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Transformer - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

5.9 المحول في السلامة

Transformer - Safety

المجال: تعلم عميق

التعريف العملي. بنية الانتباه الذاتي صارت العمود الفقري للنماذج اللغوية والرؤيوية الحديثة. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Transformer - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Transformer - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

6.9 المحول في الوكلاء

Transformer - Agents

المجال: تعلم عميق

التعريف العملي. بنية الانتباه الذاتي صارت العمود الفقري للنماذج اللغوية والرؤيوية الحديثة. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Transformer - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Transformer - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

7.9 المحول في الأنظمة الحقيقية

Transformer - Real Systems

المجال: تعلم عميق

التعريف العملي. بنية الانتباه الذاتي صارت العمود الفقري للنماذج اللغوية والرؤيوية الحديثة. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Transformer - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Transformer - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

8.9 النماذج الانتشارية في التدريب

Diffusion Models - Training

المجال: تعلم عميق

التعريف العملي. تتعلم عكس عملية إضافة الضجيج لتوليد صور وصوت وفيديو. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Diffusion Models - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Diffusion Models - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

9.9 النماذج الانتشارية في التقييم

Diffusion Models - Evaluation

المجال: تعلم عميق

التعريف العملي. تتعلم عكس عملية إضافة الضجيج لتوليد صور وصوت وفيديو. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Diffusion Models - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda \Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Diffusion Models - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

10.9 النماذج الانتشارية في الذاكرة

Diffusion Models - Memory

المجال: تعلم عميق

التعريف العملي. تتعلم عكس عملية إضافة الضجيج لتوليد صور وصوت وفيديو. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Diffusion Models - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Diffusion Models - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

11.9 النماذج الانتشارية في البحث العلمي

Diffusion Models - Scientific Discovery

المجال: تعلم عميق

التعريف العملي. تتعلم عكس عملية إضافة الضجيج لتوليد صور وصوت وفيديو. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Diffusion Models - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Diffusion Models - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

12.9 المرمزات الذاتية وقت الاستدلال

Autoencoders - Inference Time

المجال: تعلم عميق

التعريف العملي. تتعلم تمثيلا مضغوطا يحافظ على بنية البيانات المهمة. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Autoencoders - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Autoencoders - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

13.9 المرمزات الذاتية في السلامة

Autoencoders - Safety

المجال: تعلم عميق

التعريف العملي. تتعلم تمثيلا مضغوطا يحافظ على بنية البيانات المهمة. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Autoencoders - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Autoencoders - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

14.9 المرمزات الذاتية في الوكلاء

Autoencoders - Agents

المجال: تعلم عميق

التعريف العملي. تتعلم تمثيلا مضغوطا يحافظ على بنية البيانات المهمة. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Autoencoders - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Autoencoders - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

15.9 المرمزات الذاتية في الأنظمة الحقيقية

Autoencoders - Real Systems

المجال: تعلم عميق

التعريف العملي. تتعلم تمثيلا مضغوطا يحافظ على بنية البيانات المهمة. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Autoencoders - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Autoencoders - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

16.9 النماذج التوليدية الخصمية في التدريب

GANs - Training

المجال: تعلم عميق

التعريف العملي. تضع مولدا وناقدا في لعبة تعلم توليدي. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل GANs - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \operatorname{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال GANs - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

17.9 النماذج التوليدية الخصمية في التقييم

GANs - Evaluation

المجال: تعلم عميق

التعريف العملي. تضع مولدا وناقدا في لعبة تعلم توليدي. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل GANs - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال GANs - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

18.9 النماذج التوليدية الخصمية في الذاكرة

GANs - Memory

المجال: تعلم عميق

التعريف العملي. تضع مولدا وناقدا في لعبة تعلم توليدي. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل GANs - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال GANs - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

19.9 النماذج التوليدية الخصمية في البحث العلمي

GANs - Scientific Discovery

المجال: تعلم عميق

التعريف العملي. تضع مولدا وناقدا في لعبة تعلم توليدي. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل GANs - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال GANs - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

20.9 خليط الخبراء وقت الاستدلال

Mixture of Experts - Inference Time

المجال: تعلم عميق

التعريف العملي. يفعل أجزاء محددة من النموذج لكل عينة لتحقيق كفاءة وسعة أعلى. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Mixture of Experts - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V)=\mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Mixture of Experts - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

21.9 خليط الخبراء في السلامة

Mixture of Experts - Safety

المجال: تعلم عميق

التعريف العملي. يفعل أجزاء محددة من النموذج لكل عينة لتحقيق كفاءة وسعة أعلى. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Mixture of Experts - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Mixture of Experts - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

22.9 خليط الخبراء في الوكلاء

Mixture of Experts - Agents

المجال: تعلم عميق

التعريف العملي. يفعل أجزاء محددة من النموذج لكل عينة لتحقيق كفاءة وسعة أعلى. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Mixture of Experts - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Mixture of Experts - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

23.9 خليط الخبراء في الأنظمة الحقيقية

Mixture of Experts - Real Systems

المجال: تعلم عميق

التعريف العملي. يفعل أجزاء محددة من النموذج لكل عينة لتحقيق كفاءة وسعة أعلى. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Mixture of Experts - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Mixture of Experts - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

24.9 نماذج فضاء الحالة في التدريب

State Space Models - Training

المجال: تعلم عميق

التعريف العملي. بديل أو مكمل للمحول يعالج التسلسل بكلفة خطية تقريبا. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل State Space Models - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال State Space Models - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

25.9 نماذج فضاء الحالة في التقييم

State Space Models - Evaluation

المجال: تعلم عميق

التعريف العملي. بديل أو مكمل للمحول يعالج التسلسل بكلفة خطية تقريبا. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل State Space Models - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال State Space Models - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

26.9 نماذج فضاء الحالة في الذاكرة

State Space Models - Memory

المجال: تعلم عميق

التعريف العملي. بديل أو مكمل للمحول يعالج التسلسل بكلفة خطية تقريبا. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل State Space Models - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال State Space Models - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

27.9 نماذج فضاء الحالة في البحث العلمي

State Space Models - Scientific Discovery

المجال: تعلم عميق

التعريف العملي. بديل أو مكمل للمحول يعالج التسلسل بكلفة خطية تقريبا. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل State Space Models - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال State Space Models - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

28.9 التعلم الذاتي الإشراف وقت الاستدلال

Self-Supervised Learning - Inference Time

المجال: تعلم عميق

التعريف العملي. يستخرج الإشارة التعليمية من البيانات نفسها عبر إخفاء، تنبؤ، أو تباين. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Self-Supervised Learning - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Self-Supervised Learning - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

29.9 التعلم الذاتي الإشراف في السلامة

Self-Supervised Learning - Safety

المجال: تعلم عميق

التعريف العملي. يستخرج الإشارة التعليمية من البيانات نفسها عبر إخفاء، تنبؤ، أو تباين. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Self-Supervised Learning - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda \Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Self-Supervised Learning - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

30.9 التعلم الذاتي الإشراف في الوكلاء

Self-Supervised Learning - Agents

المجال: تعلم عميق

التعريف العملي. يستخرج الإشارة التعليمية من البيانات نفسها عبر إخفاء، تنبؤ، أو تباين. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Self-Supervised Learning - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Self-Supervised Learning - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

31.9 التعلم الذاتي الإشراف في الأنظمة الحقيقية

Self-Supervised Learning - Real Systems

المجال: تعلم عميق

التعريف العملي. يستخرج الإشارة التعليمية من البيانات نفسها عبر إخفاء، تنبؤ، أو تباين. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Self-Supervised Learning - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في تعلم عميق نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Self-Supervised Learning - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

32.9 التقسيم إلى رموز في التدريب

Tokenization - Training

المجال: نماذج لغوية واستدلال

التعريف العملي. يحدد وحدة القراءة والكتابة التي يرى بها النموذج العالم اللغوي. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Tokenization - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Tokenization - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

33.9 التقسيم إلى رموز في التقييم

Tokenization - Evaluation

المجال: نماذج لغوية واستدلال

التعريف العملي. يحدد وحدة القراءة والكتابة التي يرى بها النموذج العالم اللغوي. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Tokenization - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Tokenization - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

34.9 التقسيم إلى رموز في الذاكرة

Tokenization - Memory

المجال: نماذج لغوية واستدلال

التعريف العملي. يحدد وحدة القراءة والكتابة التي يرى بها النموذج العالم اللغوي. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Tokenization - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Tokenization - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

35.9 التقسيم إلى رموز في البحث العلمي

Tokenization - Scientific Discovery

المجال: نماذج لغوية واستدلال

التعريف العملي. يحدد وحدة القراءة والكتابة التي يرى بها النموذج العالم اللغوي. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Tokenization - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Tokenization - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

36.9 التدريب القبلي وقت الاستدلال

Pretraining - Inference Time

المجال: نماذج لغوية واستدلال

التعريف العملي. يبني معرفة عامة من كميات ضخمة قبل التخصص. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Pretraining - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \operatorname{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Pretraining - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

37.9 التدريب القبلي في السلامة

Pretraining - Safety

المجال: نماذج لغوية واستدلال

التعريف العملي. يبني معرفة عامة من كميات ضخمة قبل التخصص. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Pretraining - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Pretraining - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

38.9 التدريب القبلي في الوكلاء

Pretraining - Agents

المجال: نماذج لغوية واستدلال

التعريف العملي. يبني معرفة عامة من كميات ضخمة قبل التخصص. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Pretraining - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Pretraining - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

39.9 التدريب القبلي في الأنظمة الحقيقية

Pretraining - Real Systems

المجال: نماذج لغوية واستدلال

التعريف العملي. يبني معرفة عامة من كميات ضخمة قبل التخصص. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Pretraining - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Pretraining - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

40.9 الضبط الدقيق في التدريب

Fine-Tuning - Training

المجال: نماذج لغوية واستدلال

التعريف العملي. ينقل النموذج من عمومية واسعة إلى مجال أو سلوك مطلوب. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Fine-Tuning - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V)=\mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Fine-Tuning - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

41.9 الضبط الدقيق في التقييم

Fine-Tuning - Evaluation

المجال: نماذج لغوية واستدلال

التعريف العملي. ينقل النموذج من عمومية واسعة إلى مجال أو سلوك مطلوب. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Fine-Tuning - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Fine-Tuning - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

42.9 الضبط الدقيق في الذاكرة

Fine-Tuning - Memory

المجال: نماذج لغوية واستدلال

التعريف العملي. ينقل النموذج من عمومية واسعة إلى مجال أو سلوك مطلوب. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Fine-Tuning - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Fine-Tuning - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

43.9 الضبط الدقيق في البحث العلمي

Fine-Tuning - Scientific Discovery

المجال: نماذج لغوية واستدلال

التعريف العملي. ينقل النموذج من عمومية واسعة إلى مجال أو سلوك مطلوب. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Fine-Tuning - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Fine-Tuning - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

44.9 التعلم من تفضيلات البشر وقت الاستدلال

RLHF - Inference Time

المجال: نماذج لغوية واستدلال

التعريف العملي. يستعمل ملاحظات البشر أو نماذج المكافأة لتشكيل السلوك النهائي. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل RLHF - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال RLHF - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

45.9 التعلم من تفضيلات البشر في السلامة

RLHF - Safety

المجال: نماذج لغوية واستدلال

التعريف العملي. يستعمل ملاحظات البشر أو نماذج المكافأة لتشكيل السلوك النهائي. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل RLHF - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال RLHF - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

46.9 التعلم من تفضيلات البشر في الوكلاء

RLHF - Agents

المجال: نماذج لغوية واستدلال

التعريف العملي. يستعمل ملاحظات البشر أو نماذج المكافأة لتشكيل السلوك النهائي. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل RLHF - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال RLHF - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

47.9 التعلم من تفضيلات البشر في الأنظمة الحقيقية

RLHF - Real Systems

المجال: نماذج لغوية واستدلال

التعريف العملي. يستعمل ملاحظات البشر أو نماذج المكافأة لتشكيل السلوك النهائي. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل RLHF - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال RLHF - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

باب 10

الجزء الثامن: الذكاء الكمي، التعقيد، والعلوم الحدودية

نضع الذكاء الكمي في حجمه الواقعي: مفيد جدا في المحاكاة والتحسين والتحكم، ومحدود حاليا بقيود الضجيج والقياس.

1.10 التحسين بالتفضيل المباشر في التدريب

DPO - Training

المجال: نماذج لغوية واستدلال

التعريف العملي. يحول بيانات التفضيل إلى هدف مباشر دون حلقة تعزيز كاملة. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل DPO - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال DPO - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

2.10 التحسين بالتفضيل المباشر في التقييم

DPO - Evaluation

المجال: نماذج لغوية واستدلال

التعريف العملي. يحول بيانات التفضيل إلى هدف مباشر دون حلقة تعزيز كاملة. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل DPO - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda\Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال DPO - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

3.10 التحسين بالتفضيل المباشر في الذاكرة

DPO - Memory

المجال: نماذج لغوية واستدلال

التعريف العملي. يحول بيانات التفضيل إلى هدف مباشر دون حلقة تعزيز كاملة. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل DPO - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال DPO - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

4.10 التحسين بالتفضيل المباشر في البحث العلمي

DPO - Scientific Discovery

المجال: نماذج لغوية واستدلال

التعريف العملي. يحول بيانات التفضيل إلى هدف مباشر دون حلقة تعزيز كاملة. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل DPO - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال DPO - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

5.10 سلسلة التفكير وقت الاستدلال

Chain-of-Thought - Inference Time

المجال: نماذج لغوية واستدلال

التعريف العملي. تزيد قدرة النموذج على تنظيم الخطوات، لكنها لا تضمن صحة النتيجة. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Chain-of-Thought - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Chain-of-Thought - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

6.10 سلسلة التفكير في السلامة

Chain-of-Thought - Safety

المجال: نماذج لغوية واستدلال

التعريف العملي. تزيد قدرة النموذج على تنظيم الخطوات، لكنها لا تضمن صحة النتيجة. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Chain-of-Thought - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Chain-of-Thought - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

7.10 سلسلة التفكير في الوكلاء

Chain-of-Thought - Agents

المجال: نماذج لغوية واستدلال

التعريف العملي. تزيد قدرة النموذج على تنظيم الخطوات، لكنها لا تضمن صحة النتيجة. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Chain-of-Thought - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Chain-of-Thought - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

8.10 سلسلة التفكير في الأنظمة الحقيقية

Chain-of-Thought - Real Systems

المجال: نماذج لغوية واستدلال

التعريف العملي. تزيد قدرة النموذج على تنظيم الخطوات، لكنها لا تضمن صحة النتيجة. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Chain-of-Thought - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Chain-of-Thought - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

9.10 التصويت الذاتي في التدريب

Self-Consistency - Training

المجال: نماذج لغوية واستدلال

التعريف العملي. يولد مسارات متعددة ثم يختار الجواب الأكثر اتساقا. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Self-Consistency - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \mathrm{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Self-Consistency - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

10.10 التصويت الذاتي في التقييم

Self-Consistency - Evaluation

المجال: نماذج لغوية واستدلال

التعريف العملي. يولد مسارات متعددة ثم يختار الجواب الأكثر اتساقا. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Self-Consistency - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Self-Consistency - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

11.10 التصويت الذاتي في الذاكرة

Self-Consistency - Memory

المجال: نماذج لغوية واستدلال

التعريف العملي. يولد مسارات متعددة ثم يختار الجواب الأكثر اتساقا. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Self-Consistency - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Self-Consistency - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

12.10 التصويت الذاتي في البحث العلمي

Self-Consistency - Scientific Discovery

المجال: نماذج لغوية واستدلال

التعريف العملي. يولد مسارات متعددة ثم يختار الجواب الأكثر اتساقا. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Self-Consistency - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Self-Consistency - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

13.10 نماذج مكافأة العملية وقت الاستدلال

Process Reward Models - Inference Time

المجال: نماذج لغوية واستدلال

التعريف العملي. تقوّم خطوات الحل لا النتيجة النهائية فقط. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Process Reward Models - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V)=\mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Process Reward Models - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

14.10 نماذج مكافأة العملية في السلامة

Process Reward Models - Safety

المجال: نماذج لغوية واستدلال

التعريف العملي. تقوّم خطوات الحل لا النتيجة النهائية فقط. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Process Reward Models - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Process Reward Models - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

15.10 نماذج مكافأة العملية في الوكلاء

Process Reward Models - Agents

المجال: نماذج لغوية واستدلال

التعريف العملي. تقوّم خطوات الحل لا النتيجة النهائية فقط. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Process Reward Models - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Process Reward Models - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

16.10 نماذج مكافأة العملية في الأنظمة الحقيقية

Process Reward Models - Real Systems

المجال: نماذج لغوية واستدلال

التعريف العملي. تقوّم خطوات الحل لا النتيجة النهائية فقط. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Process Reward Models - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Process Reward Models - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

17.10 نماذج مكافأة النتيجة في التدريب

Outcome Reward Models - Training

المجال: نماذج لغوية واستدلال

التعريف العملي. تقوّم الجواب النهائي وتخدم الاختيار بين عينات متعددة. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Outcome Reward Models - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Outcome Reward Models - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

18.10 نماذج مكافأة النتيجة في التقييم

Outcome Reward Models - Evaluation

المجال: نماذج لغوية واستدلال

التعريف العملي. تقوّم الجواب النهائي وتخدم الاختيار بين عينات متعددة. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Outcome Reward Models - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Outcome Reward Models - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

19.10 نماذج مكافأة النتيجة في الذاكرة

Outcome Reward Models - Memory

المجال: نماذج لغوية واستدلال

التعريف العملي. تقوّم الجواب النهائي وتخدم الاختيار بين عينات متعددة. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Outcome Reward Models - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Outcome Reward Models - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

20.10 نماذج مكافأة النتيجة في البحث العلمي

Outcome Reward Models - Scientific Discovery

المجال: نماذج لغوية واستدلال

التعريف العملي. تقوّم الجواب النهائي وتخدم الاختيار بين عينات متعددة. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Outcome Reward Models - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Outcome Reward Models - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

21.10 التحقق الآلي وقت الاستدلال

Verifiers - Inference Time

المجال: نماذج لغوية واستدلال

التعريف العملي. يربط التوليد بآليات تحقق صورية أو تنفيذية أو إحصائية. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Verifiers - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Verifiers - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

22.10 التحقق الآلي في السلامة

Verifiers - Safety

المجال: نماذج لغوية واستدلال

التعريف العملي. يربط التوليد بآليات تحقق صورية أو تنفيذية أو إحصائية. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Verifiers - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda \Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Verifiers - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

23.10 التحقق الآلي في الوكلاء

Verifiers - Agents

المجال: نماذج لغوية واستدلال

التعريف العملي. يربط التوليد بآليات تحقق صورية أو تنفيذية أو إحصائية. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Verifiers - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Verifiers - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

24.10 التحقق الآلي في الأنظمة الحقيقية

Verifiers - Real Systems

المجال: نماذج لغوية واستدلال

التعريف العملي. يربط التوليد بآليات تحقق صورية أو تنفيذية أو إحصائية. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Verifiers - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Verifiers - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

25.10 التوسع وقت الاختبار في التدريب

Test-Time Scaling - Training

المجال: نماذج لغوية واستدلال

التعريف العملي. يزيد التفكير أو البحث عند الاستدلال بدل زيادة التدريب فقط. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Test-Time Scaling - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Test-Time Scaling - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

26.10 التوسع وقت الاختبار في التقييم

Test-Time Scaling - Evaluation

المجال: نماذج لغوية واستدلال

التعريف العملي. يزيد التفكير أو البحث عند الاستدلال بدل زيادة التدريب فقط. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Test-Time Scaling - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Test-Time Scaling - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

27.10 التوسع وقت الاختبار في الذاكرة

Test-Time Scaling - Memory

المجال: نماذج لغوية واستدلال

التعريف العملي. يزيد التفكير أو البحث عند الاستدلال بدل زيادة التدريب فقط. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Test-Time Scaling - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Test-Time Scaling - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

28.10 التوسع وقت الاختبار في البحث العلمي

Test-Time Scaling - Scientific Discovery

المجال: نماذج لغوية واستدلال

التعريف العملي. يزيد التفكير أو البحث عند الاستدلال بدل زيادة التدريب فقط. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Test-Time Scaling - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Test-Time Scaling - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

29.10 التفكير المتكيف وقت الاستدلال

Adaptive Thinking - Inference Time

المجال: نماذج لغوية واستدلال

التعريف العملي. يضبط عمق التفكير حسب صعوبة المسألة وثقة النموذج. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Adaptive Thinking - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \mathrm{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Adaptive Thinking - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

30.10 التفكير المتكيف في السلامة

Adaptive Thinking - Safety

المجال: نماذج لغوية واستدلال

التعريف العملي. يضبط عمق التفكير حسب صعوبة المسألة وثقة النموذج. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Adaptive Thinking - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Adaptive Thinking - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

31.10 التفكير المتكيف في الوكلاء

Adaptive Thinking - Agents

المجال: نماذج لغوية واستدلال

التعريف العملي. يضبط عمق التفكير حسب صعوبة المسألة وثقة النموذج. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Adaptive Thinking - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Adaptive Thinking - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

32.10 التفكير المتكيف في الأنظمة الحقيقية

Adaptive Thinking - Real Systems

المجال: نماذج لغوية واستدلال

التعريف العملي. يضبط عمق التفكير حسب صعوبة المسألة وثقة النموذج. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Adaptive Thinking - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Adaptive Thinking - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

33.10 الاسترجاع المعزز في التدريب

Retrieval-Augmented Generation - Training

المجال: نماذج لغوية واستدلال

التعريف العملي. يفصل الذاكرة الخارجية عن ذاكرة الأوزان ويزيد قابلية التحديث. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Retrieval-Augmented Generation - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V)=\mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Retrieval-Augmented Generation - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

34.10 الاسترجاع المعزز في التقييم

Retrieval-Augmented Generation - Evaluation

المجال: نماذج لغوية واستدلال

التعريف العملي. يفصل الذاكرة الخارجية عن ذاكرة الأوزان ويزيد قابلية التحديث. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Retrieval-Augmented Generation - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Retrieval-Augmented Generation - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

35.10 الاسترجاع المعزز في الذاكرة

Retrieval-Augmented Generation - Memory

المجال: نماذج لغوية واستدلال

التعريف العملي. يفصل الذاكرة الخارجية عن ذاكرة الأوزان ويزيد قابلية التحديث. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Retrieval-Augmented Generation - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Retrieval-Augmented Generation - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

36.10 الاسترجاع المعزز في البحث العلمي

Retrieval-Augmented Generation - Scientific Discovery

المجال: نماذج لغوية واستدلال

التعريف العملي. يفصل الذاكرة الخارجية عن ذاكرة الأوزان ويزيد قابلية التحديث. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Retrieval-Augmented Generation - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Retrieval-Augmented Generation - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

37.10 الوكلاء وقت الاستدلال

AI Agents - Inference Time

المجال: نماذج لغوية واستدلال

التعريف العملي. يضيفون للنموذج هدفا وذاكرة وأدوات وحلقة فعل وملاحظة. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل AI Agents - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال AI Agents - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

38.10 الوكلاء في السلامة

AI Agents - Safety

المجال: نماذج لغوية واستدلال

التعريف العملي. يضيفون للنموذج هدفا وذاكرة وأدوات وحلقة فعل وملاحظة. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل AI Agents - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال AI Agents - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

39.10 الوكلاء في الوكلاء

AI Agents - Agents

المجال: نماذج لغوية واستدلال

التعريف العملي. يضيفون للنموذج هدفا وذاكرة وأدوات وحلقة فعل وملاحظة. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل AI Agents - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال AI Agents - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

40.10 الوكلاء في الأنظمة الحقيقية

AI Agents - Real Systems

المجال: نماذج لغوية واستدلال

التعريف العملي. يضيفون للنموذج هدفا وذاكرة وأدوات وحلقة فعل وملاحظة. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل AI Agents - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال AI Agents - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

41.10 استخدام الأدوات في التدريب

Tool Use - Training

المجال: نماذج لغوية واستدلال

التعريف العملي. ينقل النموذج من كلام عن العالم إلى أفعال داخل أنظمة حقيقية. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Tool Use - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Tool Use - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

42.10 استخدام الأدوات في التقييم

Tool Use - Evaluation

المجال: نماذج لغوية واستدلال

التعريف العملي. ينقل النموذج من كلام عن العالم إلى أفعال داخل أنظمة حقيقية. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Tool Use - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda \Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Tool Use - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

43.10 استخدام الأدوات في الذاكرة

Tool Use - Memory

المجال: نماذج لغوية واستدلال

التعريف العملي. ينقل النموذج من كلام عن العالم إلى أفعال داخل أنظمة حقيقية. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Tool Use - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Tool Use - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

44.10 استخدام الأدوات في البحث العلمي

Tool Use - Scientific Discovery

المجال: نماذج لغوية واستدلال

التعريف العملي. ينقل النموذج من كلام عن العالم إلى أفعال داخل أنظمة حقيقية. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Tool Use - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Tool Use - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

45.10 الذاكرة الطويلة وقت الاستدلال

Long-Term Memory - Inference Time

المجال: نماذج لغوية واستدلال

التعريف العملي. تحفظ سياقا عابرا للجلسات والمهام، لكنها تفتح مشاكل الخصوصية والتحيز. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Long-Term Memory - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Long-Term Memory - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

46.10 الذاكرة الطويلة في السلامة

Long-Term Memory - Safety

المجال: نماذج لغوية واستدلال

التعريف العملي. تحفظ سياقا عابرا للجلسات والمهام، لكنها تفتح مشاكل الخصوصية والتحيز. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Long-Term Memory - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Long-Term Memory - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

47.10 الذاكرة الطويلة في الوكلاء

Long-Term Memory - Agents

المجال: نماذج لغوية واستدلال

التعريف العملي. تحفظ سياقا عابرا للجلسات والمهام، لكنها تفتح مشاكل الخصوصية والتحيز. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Long-Term Memory - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Long-Term Memory - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

باب 11

الجزء التاسع: هندسة الأنظمة، السلامة، الأمن، والمستقبل

الخاتمة التطبيقية: كيف يتحول النموذج إلى نظام آمن، مراقب، قابل للقياس، وقابل للتطوير في العالم الحقيقي.

1.11 الذاكرة الطويلة في الأنظمة الحقيقية

Long-Term Memory - Real Systems

المجال: نماذج لغوية واستدلال

التعريف العملي. تحفظ سياقا عابرا للجلسات والمهام، لكنها تفتح مشاكل الخصوصية والتحيز. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Long-Term Memory - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Long-Term Memory - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

2.11 النماذج متعددة الوسائط في التدريب

Multimodal Models - Training

المجال: نماذج لغوية واستدلال

التعريف العملي. تدمج اللغة مع الصورة والصوت والفيديو والحركة والبيانات المنظمة. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Multimodal Models - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \operatorname{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Multimodal Models - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

3.11 النماذج متعددة الوسائط في التقييم

Multimodal Models - Evaluation

المجال: نماذج لغوية واستدلال

التعريف العملي. تدمج اللغة مع الصورة والصوت والفيديو والحركة والبيانات المنظمة. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Multimodal Models - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Multimodal Models - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

4.11 النماذج متعددة الوسائط في الذاكرة

Multimodal Models - Memory

المجال: نماذج لغوية واستدلال

التعريف العملي. تدمج اللغة مع الصورة والصوت والفيديو والحركة والبيانات المنظمة. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Multimodal Models - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Multimodal Models - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

5.11 النماذج متعددة الوسائط في البحث العلمي

Multimodal Models - Scientific Discovery

المجال: نماذج لغوية واستدلال

التعريف العملي. تدمج اللغة مع الصورة والصوت والفيديو والحركة والبيانات المنظمة. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Multimodal Models - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Multimodal Models - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

6.11 التقييم المعياري وقت الاستدلال

Benchmarks - Inference Time

المجال: نماذج لغوية واستدلال

التعريف العملي. يقيس القدرات لكنه قد يصنع وهما إذا تحول إلى هدف تدريب مباشر. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Benchmarks - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V)=\mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Benchmarks - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

7.11 التقييم المعياري في السلامة

Benchmarks - Safety

المجال: نماذج لغوية واستدلال

التعريف العملي. يقيس القدرات لكنه قد يصنع وهما إذا تحول إلى هدف تدريب مباشر. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Benchmarks - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Benchmarks - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

8.11 التقييم المعياري في الوكلاء

Benchmarks - Agents

المجال: نماذج لغوية واستدلال

التعريف العملي. يقيس القدرات لكنه قد يصنع وهما إذا تحول إلى هدف تدريب مباشر. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Benchmarks - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Benchmarks - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

9.11 التقييم المعياري في الأنظمة الحقيقية

Benchmarks - Real Systems

المجال: نماذج لغوية واستدلال

التعريف العملي. يقيس القدرات لكنه قد يصنع وهما إذا تحول إلى هدف تدريب مباشر. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Benchmarks - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في نماذج لغوية واستدلال نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Benchmarks - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

10.11 تعريف الذكاء العام في التدريب

Artificial General Intelligence - Training

المجال: AGI وأنظمة

التعريف العملي. ليس نموذجا واحدا بل قدرة نظامية على النقل، التخطيط، التكيف، والتعلم عبر مجالات متباعدة. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Artificial General Intelligence - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Artificial General Intelligence - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

11.11 تعريف الذكاء العام في التقييم

Artificial General Intelligence - Evaluation

المجال: AGI وأنظمة

التعريف العملي. ليس نموذجا واحدا بل قدرة نظامية على النقل، التخطيط، التكيف، والتعلم عبر مجالات متباعدة. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Artificial General Intelligence - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Artificial General Intelligence - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

12.11 تعريف الذكاء العام في الذاكرة

Artificial General Intelligence - Memory

المجال: AGI وأنظمة

التعريف العملي. ليس نموذجا واحدا بل قدرة نظامية على النقل، التخطيط، التكيف، والتعلم عبر مجالات متباعدة. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Artificial General Intelligence - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Artificial General Intelligence - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

13.11 تعريف الذكاء العام في البحث العلمي

Artificial General Intelligence - Scientific Discovery

المجال: AGI وأنظمة

التعريف العملي. ليس نموذجا واحدا بل قدرة نظامية على النقل، التخطيط، التكيف، والتعلم عبر مجالات متباعدة. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Artificial General Intelligence - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Artificial General Intelligence - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

14.11 نظرية الحلقات المعرفية وقت الاستدلال

Cognitive Loops - Inference Time

المجال: AGI وأنظمة

التعريف العملي. تفسر الذكاء كنظام حلقات: توليد، تحقق، ذاكرة، فعل، تغذية راجعة، وإعادة ضبط. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Cognitive Loops - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Cognitive Loops - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

15.11 نظرية الحلقات المعرفية في السلامة

Cognitive Loops - Safety

المجال: AGI وأنظمة

التعريف العملي. تفسر الذكاء كنظام حلقات: توليد، تحقق، ذاكرة، فعل، تغذية راجعة، وإعادة ضبط. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Cognitive Loops - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda \Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Cognitive Loops - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

16.11 نظرية الحلقات المعرفية في الوكلاء

Cognitive Loops - Agents

المجال: AGI وأنظمة

التعريف العملي. تفسر الذكاء كنظام حلقات: توليد، تحقق، ذاكرة، فعل، تغذية راجعة، وإعادة ضبط. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Cognitive Loops - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Cognitive Loops - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

17.11 نظرية الحلقات المعرفية في الأنظمة الحقيقية

Cognitive Loops - Real Systems

المجال: AGI وأنظمة

التعريف العملي. تفسر الذكاء كنظام حلقات: توليد، تحقق، ذاكرة، فعل، تغذية راجعة، وإعادة ضبط. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Cognitive Loops - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Cognitive Loops - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

18.11 النظام الوكيلي في التدريب

Agentic System - Training

المجال: AGI وأنظمة

التعريف العملي. يجمع نموذج أساس وأدوات وذاكرة وسياسة فعل ومراقبة أمان. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Agentic System - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Agentic System - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

19.11 النظام الوكيلي في التقييم

Agentic System - Evaluation

المجال: AGI وأنظمة

التعريف العملي. يجمع نموذج أساس وأدوات وذاكرة وسياسة فعل ومراقبة أمان. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Agentic System - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Agentic System - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

20.11 النظام الوكيلي في الذاكرة

Agentic System - Memory

المجال: AGI وأنظمة

التعريف العملي. يجمع نموذج أساس وأدوات وذاكرة وسياسة فعل ومراقبة أمان. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Agentic System - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Agentic System - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

21.11 النظام الوكيلي في البحث العلمي

Agentic System - Scientific Discovery

المجال: AGI وأنظمة

التعريف العملي. يجمع نموذج أساس وأدوات وذاكرة وسياسة فعل ومراقبة أمان. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Agentic System - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء؛ يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Agentic System - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

22.11 هندسة الأهداف وقت الاستدلال

Goal Engineering - Inference Time

المجال: AGI وأنظمة

التعريف العملي. تحدد الغاية بطريقة تمنع الانحرافات والحلول الخطرة. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Goal Engineering - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \operatorname{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Goal Engineering - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

23.11 هندسة الأهداف في السلامة

Goal Engineering - Safety

المجال: AGI وأنظمة

التعريف العملي. تحدد الغاية بطريقة تمنع الانحرافات والحلول الخطرة. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Goal Engineering - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Goal Engineering - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

24.11 هندسة الأهداف في الوكلاء

Goal Engineering - Agents

المجال: AGI وأنظمة

التعريف العملي. تحدد الغاية بطريقة تمنع الانحرافات والحلول الخطرة. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Goal Engineering - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Goal Engineering - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

25.11 هندسة الأهداف في الأنظمة الحقيقية

Goal Engineering - Real Systems

المجال: AGI وأنظمة

التعريف العملي. تحدد الغاية بطريقة تمنع الانحرافات والحلول الخطرة. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Goal Engineering - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$P(y \mid x) = \prod_{t=1}^{T} P(y_t \mid x, y_{<t})$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Goal Engineering - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

26.11 تقسيم المهمة في التدريب

Task Decomposition - Training

المجال: AGI وأنظمة

التعريف العملي. يكسر العمل الطويل إلى وحدات قابلة للتحقق والتفويض. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Task Decomposition - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{Attention}(Q,K,V)=\mathrm{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Task Decomposition - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

27.11 تقسيم المهمة في التقييم

Task Decomposition - Evaluation

المجال: AGI وأنظمة

التعريف العملي. يكسر العمل الطويل إلى وحدات قابلة للتحقق والتفويض. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Task Decomposition - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathcal{L}_{\mathrm{CE}} = -\sum_{t} \log p_\theta(y_t \mid y_{<t}, x)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Task Decomposition - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

28.11 تقسيم المهمة في الذاكرة

Task Decomposition - Memory

المجال: AGI وأنظمة

التعريف العملي. يكسر العمل الطويل إلى وحدات قابلة للتحقق والتفويض. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Task Decomposition - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \mathcal{L}(\theta_t)$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Task Decomposition - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

29.11 تقسيم المهمة في البحث العلمي

Task Decomposition - Scientific Discovery

المجال: AGI وأنظمة

التعريف العملي. يكسر العمل الطويل إلى وحدات قابلة للتحقق والتفويض. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Task Decomposition - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\hat{R} = \sum_{t=0}^{T} \gamma^t r_t, \qquad V^{\pi}(s) = \mathbb{E}_{\pi}[\hat{R} \mid s_0 = s]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Task Decomposition - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

30.11 التحكم المعرفي وقت الاستدلال

Cognitive Control - Inference Time

المجال: AGI وأنظمة

التعريف العملي. ينظم متى يفكر النموذج، متى يبحث، متى ينفذ، ومتى يتوقف. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Cognitive Control - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$Q^\star(s,a) = r(s,a) + \gamma \max_{a'} Q^\star(s',a')$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Cognitive Control - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

31.11 التحكم المعرفي في السلامة

Cognitive Control - Safety

المجال: AGI وأنظمة

التعريف العملي. ينظم متى يفكر النموذج، متى يبحث، متى ينفذ، ومتى يتوقف. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Cognitive Control - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$I(X;Y) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Cognitive Control - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

32.11 التحكم المعرفي في الوكلاء

Cognitive Control - Agents

المجال: AGI وأنظمة

التعريف العملي. ينظم متى يفكر النموذج، متى يبحث، متى ينفذ، ومتى يتوقف. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Cognitive Control - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$D_{\mathrm{KL}}(P\|Q) = \sum_{x} P(x) \log \frac{P(x)}{Q(x)}$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Cognitive Control - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

33.11 التحكم المعرفي في الأنظمة الحقيقية

Cognitive Control - Real Systems

المجال: AGI وأنظمة

التعريف العملي. ينظم متى يفكر النموذج، متى يبحث، متى ينفذ، ومتى يتوقف. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Cognitive Control - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$p(\theta \mid D) \propto p(D \mid \theta)p(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Cognitive Control - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

34.11 المراقبة الذاتية في التدريب

Self-Monitoring - Training

المجال: AGI وأنظمة

التعريف العملي. تجعل النظام يقدر ثقته وأخطاءه وحدوده قبل أن يتصرف. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Self-Monitoring - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$z = \frac{x - \mu}{\sigma}, \qquad \hat{\mu} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Self-Monitoring - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

35.11 المراقبة الذاتية في التقييم

Self-Monitoring - Evaluation

المجال: AGI وأنظمة

التعريف العملي. تجعل النظام يقدر ثقته وأخطاءه وحدوده قبل أن يتصرف. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Self-Monitoring - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\min_{\theta} \ \mathbb{E}_{(x,y)\sim D}[\ell(f_\theta(x), y)] + \lambda \Omega(\theta)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Self-Monitoring - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

36.11 المراقبة الذاتية في الذاكرة

Self-Monitoring - Memory

المجال: AGI وأنظمة

التعريف العملي. تجعل النظام يقدر ثقته وأخطاءه وحدوده قبل أن يتصرف. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Self-Monitoring - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$x_{t+1} = Ax_t + Bu_t + w_t, \qquad y_t = Cx_t + v_t$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Self-Monitoring - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

37.11 المراقبة الذاتية في البحث العلمي

Self-Monitoring - Scientific Discovery

المجال: AGI وأنظمة

التعريف العملي. تجعل النظام يقدر ثقته وأخطاءه وحدوده قبل أن يتصرف. كيف يخدم توليد الفرضيات والاختبار؟ داخل هذا الكتاب لا نعامل Self-Monitoring - Scientific Discovery ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$H(X) = -\sum_{x} p(x) \log p(x)$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: البحث الجشع، البحث بعرض الشجرة، البحث بعمق، ألفا-بيتا، النجمة، البرمجة الديناميكية، البرمجة القيدية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Self-Monitoring - Scientific Discovery في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

38.11 التعلم المستمر وقت الاستدلال

Continual Learning - Inference Time

المجال: AGI وأنظمة

التعريف العملي. يحاول التعلم بعد النشر دون نسيان كارثي أو تلوث بيانات. كيف يظهر عندما يقرر النظام أو يبحث أو يتحقق؟ داخل هذا الكتاب لا نعامل Continual Learning - Inference Time ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: التقسيم إلى رموز، التدريب القبلي، الضبط الدقيق، التعلم من التفضيلات، مكافأة العملية، مكافأة النتيجة، التحقق التنفيذي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Continual Learning - Inference Time في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما المتغير الخفي الذي يحدد انتقال النظام من نمط حفظ إلى نمط استدلال؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

39.11 التعلم المستمر في السلامة

Continual Learning - Safety

المجال: AGI وأنظمة

التعريف العملي. يحاول التعلم بعد النشر دون نسيان كارثي أو تلوث بيانات. كيف يتحول إلى خطر أو ضمان؟ داخل هذا الكتاب لا نعامل Continual Learning - Safety ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\nabla_\theta J(\theta) = \mathbb{E}_{\pi_\theta}[\nabla_\theta \log \pi_\theta(a \mid s) A^\pi(s,a)]$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الاسترجاع الكثيف، إعادة الترتيب، الفهرسة الشعاعية، ضغط السياق، التوليد المشروط، التخطيط بالأدوات، تسجيل الأثر. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Continual Learning - Safety في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نميز التحسن الحقيقي عن تلوث البيانات أو تعود النموذج على بنية الاختبار؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

40.11 التعلم المستمر في الوكلاء

Continual Learning - Agents

المجال: AGI وأنظمة

التعريف العملي. يحاول التعلم بعد النشر دون نسيان كارثي أو تلوث بيانات. كيف يصبح جزءا من حلقة فعل وملاحظة؟ داخل هذا الكتاب لا نعامل Continual Learning - Agents ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\alpha_t = \mathrm{softmax}(q_t K^\top), \qquad c_t = \sum_i \alpha_{t,i} v_i$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: تحليل التباين، اختبار تي، اختبار كاي مربع، الانحدار السببي، المطابقة، الترجيح العكسي، التجارب العشوائية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. يجب تقدير الفاصل الثقي، حجم الأثر، حساسية الاختيار، واحتمال التسرب بين التدريب والاختبار. وعند استعمال Continual Learning - Agents في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما الحد الأدنى من الذاكرة والأدوات والتحقق الذي يجعل الوكيل قابلا للثقة؟

مستقبل المحور. التحدي المفتوح هو تحويل القدرة من إجابة جيدة إلى نظام موثوق تحت ضغط الزمن، نقص المعلومات، وتضارب الأهداف.

41.11 التعلم المستمر في الأنظمة الحقيقية

Continual Learning - Real Systems

المجال: AGI وأنظمة

التعريف العملي. يحاول التعلم بعد النشر دون نسيان كارثي أو تلوث بيانات. كيف يتغير عند التكامل مع بيانات وأدوات وبشر؟ داخل هذا الكتاب لا نعامل Continual Learning - Real Systems ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{SNR} = 10 \log_{10} \frac{P_{\text{signal}}}{P_{\text{noise}}}$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانحدار الخطي، الانحدار اللوجستي، أقرب الجيران، آلات المتجهات الداعمة، أشجار القرار، الغابة العشوائية، التعزيز التدرجي، بايز الساذج. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. لا يكفي متوسط الأداء، يجب فحص الذيل، الانحراف المعياري، التغاير بين المهام، ومتانة العينة. وعند استعمال Continual Learning - Real Systems في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. هل يمكن بناء مكافأة عملية عامة تنتقل بين الرياضيات والبرمجة والعلوم؟

مستقبل المحور. المستقبل القريب لن يحسمه الحجم وحده، بل جودة البيانات، التحكم وقت الاختبار، الذاكرة، التحقق، وتكلفة التشغيل.

42.11 الذاكرة العاملة في التدريب

Working Memory - Training

المجال: AGI وأنظمة

التعريف العملي. تدير العناصر النشطة أثناء حل المسألة، وهي عنق زجاجة حاسم. كيف يدخل المبدأ في بناء التمثيل قبل النشر؟ داخل هذا الكتاب لا نعامل Working Memory - Training ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\rho(\tau) = \mathrm{corr}(x_t, x_{t-\tau})$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: الانتشار العكسي، الهبوط التدرجي العشوائي، آدم، جدولة معدل التعلم، التطبيع الطبقي، الإسقاط المتبقي، الانتباه الذاتي. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. المنهج الصارم يميز بين الارتباط والتدخل، وبين الصلاحية الداخلية والصلاحية الخارجية. وعند استعمال Working Memory - Training في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. كيف نضبط التفكير وقت الاختبار كي لا يفرط النموذج في التفكير ولا يقصر في المسائل الصعبة؟

مستقبل المحور. السؤال البحثي العميق: هل التمثيل يتعلم بنية العالم أم يلتقط آثارا إحصائية كافية للعمل؟

43.11 الذاكرة العاملة في التقييم

Working Memory - Evaluation

المجال: AGI وأنظمة

التعريف العملي. تدير العناصر النشطة أثناء حل المسألة، وهي عنق زجاجة حاسم. كيف نقيسه دون خداع بنية الاختبار؟ داخل هذا الكتاب لا نعامل Working Memory - Evaluation ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathrm{AUC} = \int_0^1 \mathrm{TPR}(u)\, du$$

هذه الصيغة ليست وحيدة ولا نهائية؛ وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: خوارزمية التوقع والتعظيم، مونت كارلو ماركوف، مرشح كالمان، مرشح الجسيمات، الاستدلال المتغير، أخذ العينات الأهمية. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. التقييم الحديث يستعمل مجموعات خفية، اختبارات مقاومة، قياس معايرة، وتحليل أخطاء نوعي لا رقما واحدا فقط. وعند استعمال Working Memory - Evaluation في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما العلاقة بين الانتباه الحسابي والانتباه المعرفي دون الوقوع في تشبيه سطحي؟

مستقبل المحور. نقطة الكسر ستكون عندما يصبح التقييم أضعف من النظام المقاس، وعندها نحتاج مقاييس مؤسسية لا اختبارات مدرسية.

44.11 الذاكرة العاملة في الذاكرة

Working Memory - Memory

المجال: AGI وأنظمة

التعريف العملي. تدير العناصر النشطة أثناء حل المسألة، وهي عنق زجاجة حاسم. كيف يحفظ النظام أثرا صالحا دون تلوث؟ داخل هذا الكتاب لا نعامل Working Memory - Memory ككلمة تقنية معزولة، بل كعقدة بين تمثيل، هدف، خوارزمية، قياس، وخطر. السؤال الأول ليس: ما الاسم؟ بل: ماذا يغير في قدرة النظام على التعلم أو الاستدلال أو الفعل؟

المبدأ الأولي. يبدأ المفهوم من فصل واضح بين البيانات، الفرضية، النموذج، والخطأ. إذا غاب هذا الفصل صار المجال خطابا عاما. في AGI وأنظمة نحتاج أن نسأل: ما المتغيرات؟ ما الفضاء؟ ما دالة الخسارة؟ ما القيود؟ وما نوع عدم اليقين؟

الصياغة الرياضية الدالة.

$$\mathbb{E}[Y \mid do(X = x)] \neq \mathbb{E}[Y \mid X = x]$$

هذه الصيغة ليست وحيدة ولا نهائية، وظيفتها أن تذكر القارئ بأن كل تقنية حديثة، مهما بدا اسمها تجاريا، تعود إلى احتمال أو تحسين أو معلومات أو قرار أو ديناميكيات.

الخوارزميات والتقنيات المتصلة. من العائلة القريبة: القيمة التكرارية، السياسة التكرارية، تعلم كيو، سارسا، دي كيو إن، بي بي أو، البحث الشجري مونت كارلو. لا ينبغي حفظ الأسماء كقائمة، بل فهم وظيفة كل خوارزمية: هل تبحث؟ هل تقرب؟ هل تضغط؟ هل تختار؟ هل توازن بين الاستكشاف والاستغلال؟ هل تتحقق من خطوة أم من نتيجة؟

المنهج الإحصائي. كل نتيجة تحتاج خط أساس، تجربة حذف، تحليل حساسية، وتحديد موارد الحوسبة حتى لا يتحول الإنجاز إلى دعاية. وعند استعمال Working Memory - Memory في بحث أكاديمي يجب ذكر حجم العينة، طريقة التقسيم، خط الأساس، معيار النجاح، وحدود التعميم.

الفشل المحتمل. يفشل هذا المحور عندما نخلط الأداء المحلي بالقدرة العامة، أو عندما نقيس النموذج بسؤال يشبه تدريبه، أو عندما تتحول الأداة إلى غاية. الفشل الأخطر هو أن يبدو النظام عاقلا لغويا بينما لا يملك آلية تحقق كافية.

سؤال بحثي مولد. ما شكل الحوكمة التي تمنع الوكيل من توسيع صلاحياته تلقائيا؟

مستقبل المحور. ينبغي فصل المعرفة المؤكدة عن الفرضية الخصبة: العلم يتقدم عندما نعرف كيف نكذب الفكرة لا عندما نجعلها أجمل.

صفحات قليلة عن المستقبل والتحديات والأسئلة المفتوحة

45.11 المستقبل القريب

سيتحرك المجال في اتجاه نماذج أقل اعتمادا على الذاكرة البارامترية وحدها وأكثر اعتمادا على الذاكرة الخارجية، التحقق، أدوات التنفيذ، الاستدلال المتكيف، والحوكمة المدمجة. ستصبح المنافسة بين الأنظمة لا بين النماذج فقط: من يملك حلقة بيانات أفضل، بيئة أدوات أكثر أمانا، وتقييما مستمرا أقوى، سيملك ذكاء أكثر قابلية للعمل.

46.11 التحديات

أكبر التحديات ليست تقنية فقط: التلوث المعياري، عدم شفافية بيانات التدريب، صعوبة قياس المخاطر النادرة، ضعف التفسير الداخلي، تضخم كلفة الحوسبة، تسرب الصلاحيات في الوكلاء، وسرعة سباق النشر مقارنة بسرعة الحوكمة. في الوعي والواجهات العصبية تظهر تحديات إضافية: الخصوصية العصبية، إساءة تفسير الإشارات، والخلط بين المؤشر العصبي والمعنى النفسي.

47.11 أسئلة بحثية حاسمة

1. هل يمكن بناء verifier عام ينتقل بين الرياضيات والبرمجة والعلوم المفتوحة؟
2. ما حد التفكير المفيد قبل أن يتحول test-time compute إلى ضياع مكلف؟
3. كيف نقيس استقلالية الوكيل دون أن نشجعه على تجاوز الإنسان؟
4. هل يمكن للذاكرة الطويلة أن تكون مفيدة دون أن تصبح سجلا خطرا للخصوصية؟
5. كيف نفرق بين ميتا-إدراك حقيقي تشغيليا وبين خطاب لغوي عن الثقة؟
6. ما البروتوكول التجريبي الذي يحول نظرية وعي مقترحة إلى فرضية قابلة للدحض؟
7. هل سيأتي الاختراق من حجم النموذج، أم من جودة حلقة التحقق والذاكرة والأدوات؟

مصادر ومراجع حديثة مختارة

هذه القائمة ليست نهاية القراءة، بل نواة عمل. الكتب تمنح الأساس، أما حدود 2026 فتوجد غالبا في الأوراق، التقارير، بطاقات النظام، المستودعات، والمعايير.

1. HAI, Stanford. The 2026 AI Index Report, 2026.
2. team, Report Scientfiic International. International AI Safety Report 2026, 2026.
3. OpenAI, . GPT-5.5 System Card, 2026.
4. Anthropic, . Introducing Claude Fable 5 and Claude Mythos 5, 2026.
5. Dao, and Gu. Mamba: Linear-Time Sequence Modeling with Selective State Spaces, 2023.
6. Gao, et al.. Retrieval-Augmented Generation for Large Language Models: A Survey, 2023.
7. Sharma, . Retrieval-Augmented Generation: Architectures, Enhancements, and Robustness Frontiers, 2025.
8. Zhang, et al.. A Survey on Test-Time Scaling in Large Language Models, 2025.
9. Zhang, et al.. A Survey of Reinforcement Learning for Large Reasoning Models, 2025.
10. S, et al.. Scaling LLM Test-Time Compute Optimally Can Be More Effective Than Scaling Model Parameters, 2024.
11. Han, et al.. Multimodal Large Language Models: A Survey, 2025.
12. Luo, et al.. Large Language Model Agent: A Survey on Methodology, Applications and Challenges, 2025.
13. Plaat, et al.. Agentic Large Language Models, a Survey, 2025.
14. NIST, . AI Risk Management Framework: Generative AI Profile, 2024.
15. Union, European. AI Act, 2024.
16. Russell, and Norvig. Artificial Intelligence: A Modern Approach.
17. Bishop, . Pattern Recognition and Machine Learning.
18. Goodfellow, Bengio, and Courville. Deep Learning.
19. Sutton, and Barto. Reinforcement Learning: An Introduction.
20. Pearl, . Causality.
21. MacKay, . Information Theory, Inference, and Learning Algorithms.

22. Probabilistic Graphical Models Friedman, and Koller.

23. Quantum Computation and Quantum Information Chuang, and Nielsen.

24. Theoretical Neuroscience Abbott, and Dayan.

25. papers. related Free Energy Principle Friston,

26. Complex Systems on works related and Bar-Yam, Mitchell, Woflram,.

خاتمة عالية الكثافة

من يريد الإحاطة بهذا العلم يجب أن يترك وهم التخصص الواحد. النماذج المفكرة تقع عند تقاطع الرياضيات، الإحصاء، الحوسبة، اللغة، الإدراك، الهندسة، الأمان، والاقتصاد السياسي للمعرفة. الاختراق لن يأتي من شعار AGI وحده، بل من ضبط الحلقات: كيف يتعلم النظام، كيف يفكر، كيف يتحقق، كيف يتذكر، كيف يستعمل الأدوات، كيف يعرف أنه قد يخطئ، وكيف يخضع لحدود لا يستطيع تجاوزها بسهولة.

الفرضية الأقوى لهذا المشروع هي أن الذكاء المتقدم ليس شيئا واحدا، بل بنية طبقية من الحلقات. إذا أردنا بناء علم جديد حوله، فلا يكفي شرح النماذج؛ يجب بناء مقاييس، بروتوكولات، تجارب دحض، وواجهات تطبيقية في AI وBCI وHCI والصحة العصبية والهندسة المعرفية. هذا الكتاب هو خريطة أولى لذلك الهجوم المعرفي المنظم.