كتاب تقني تأسيسي - تخصصي

صناعة التفكير والاستدلال في النماذج المفكرة

كيف تُدرَّب نماذج اللغة على المفاهيم العلمية والمعرفية، ولماذا تبدو قادرة على إنتاج معرفة دقيقة؟

نسخة عربية مع عزل المصطلحات التقنية الإنجليزية لمنع اضطراب اتجاه النص

إعداد: ChatGPT - يونيو 2026

مقدمة تنفيذية

جواب السؤال في صفحة واحدة

السؤال الذي يفتح هذا الكتاب محقّ: هل وصلت النماذج المفكرة إلى دقتها لأنها دُرّست العلوم والمفاهيم الأساسية درسًا مباشرًا، أم لأن تركيبة الأوزان صنعت شبكة فائقة تربط كل شيء بكل شيء؟ الجواب الدقيق: الاثنان معًا ولكن بترتيب مخصوص. يبدأ الأمر بتعلم غير موجّه واسع يسمى pretraining، ثم ينتقل إلى تعليم موجّه يسمى instruction tuning، ثم إلى محاذاة تفضيلية مثل RLHF أو DPO، ثم إلى تدريب وتقييم خاصين بالاستدلال.

لا توجد في الداخل "مكتبة مفاهيم" واضحة مثل كتب المنطق، ولا يوجد وعي ذاتي يعرف أنه يعرف. الموجود هو فضاء تمثيلي عالي الأبعاد، وسياسة توليد تتعلم أن المسارات المعرفية الدقيقة أكثر مكافأة من المسارات الركيكة. ولهذا تبدو النماذج قادرة على شرح المعرفة والعدالة والسببية: لأنها تعلمت استعمالاتها وقيودها وتعارضاتها عبر نصوص بشرية ضخمة، ثم عُوقبت أو كوفئت على طريقة الجواب.

هذا الكتاب يبني الطريق من token إلى reasoning model: من الاحتمال إلى الهندسة، من البيانات إلى الأوزان، من التفضيلات البشرية إلى المكافأة، ومن الجواب الواحد إلى البحث والتحقق. غايته ليست تمجيد التقنية ولا تبخيسها، بل وضع نموذج تفسير صارم: النماذج المفكرة آلات ضغط معرفي وتشغيل استدلالي، قوتها في التركيب وحدودها في التحقق.

> **قاعدة القراءة:** كلما رأيت مصطلحًا إنجليزيًا مثل self-attention أو reward model فهو معزول اتجاهيًا داخل النص حتى لا ينقلب ترتيب العربية.

فهرس الكتاب

أربع وعشرون طبقة لفهم صناعة التفكير

1. الفصل 1: السؤال الأصلي: هل تُدرَّس النماذج المفاهيم أم تكتشفها؟
2. الفصل 2: من الرمز إلى الاحتمال: أول ذرة في التفكير الآلي
3. الفصل 3: pretraining: ضغط الثقافة العلمية في أوزان
4. الفصل 4: embedding: كيف تتحول المفاهيم إلى هندسة
5. الفصل 5: Transformer وself-attention: آلة الربط الكبرى
6. الفصل 6: loss function وgradient descent: كيف تتغير الأوزان
7. الفصل 7: scaling laws: لماذا يكبر الذكاء مع الحجم ثم لا يكفي الحجم وحده
8. الفصل 8: تنظيف البيانات: كيف تمنع الركاكة المعرفية من دخول الأوزان
9. الفصل 9: كيف تظهر المفاهيم الأساسية: المعرفة والسببية والعدالة
10. الفصل 10: الرمزية الناعمة والمنطق الصريح: أين يسكن الاستدلال؟
11. الفصل 11: instruction tuning: كيف يتعلم النموذج أن يجيب لا أن يكمل فقط
12. الفصل 12: RLHF وpreference model: ضبط الذكاء بذوق بشري منظّم
13. الفصل 13: DPO وبدائل المحاذاة: عندما يصبح التفضيل loss مباشرًا
14. الفصل 14: chain-of-thought: التفكير كمسار وسيط
15. الفصل 15: process supervision وverifiers: مكافأة الطريق لا النتيجة فقط
16. الفصل 16: reinforcement learning للنماذج المفكرة: تعلم سياسة تفكير
17. الفصل 17: test-time compute: الذكاء حين يشتري وقتًا إضافيًا
18. الفصل 18: self-consistency وtree-of-thought: تعدد المسارات بدل مسار واحد
19. الفصل 19: RAG والذاكرة الخارجية: حين لا تكفي الأوزان
20. الفصل 20: tools وagents: حين يصبح التفكير فعلًا في العالم
21. الفصل 21: الموثوقية: calibration وevals وحدود الثقة
22. الفصل 22: الهلاوس: لماذا يقع النموذج في معرفة تبدو صحيحة وهي كاذبة؟
23. الفصل 23: الاستدلال الرياضي والعلمي: من النمط إلى البرهان
24. الفصل 24: هل تنتج النماذج معرفة غير مسبوقة؟

> **ملاحظة:** صُمم كل فصل في ست صفحات: الأصل النظري، الآلية الصناعية، النموذج الرياضي، المثال المركب، الموثوقية والفشل، ثم التركيب النهائي.

الفصل 1: السؤال الأصلي: هل تُدرَّس النماذج المفاهيم أم تكتشفها؟

نزع الوهم: ما الذي يحدث حقًا؟

النموذج لا يتلقى درسًا مدرسيًا منظّمًا في معنى المعرفة والعدالة والسببية، لكنه لا يُترك أيضًا في فوضى خام؛ بل يُعرَّض لكمّ هائل من النصوص، ثم يُعاد تشكيل سلوكه ببيانات تعليمية وتفضيلية ومكافآت تجعل المسارات الجيدة أكثر احتمالًا.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** الصناعة الحقيقية هي هندسة احتمال مشروطة بالمعنى، ثم تهذيبها بسلوك مرغوب، ثم اختبارها بمقاييس صارمة.

الفصل 1: السؤال الأصلي: هل تُدرَّس النماذج المفاهيم أم تكتشفها؟

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: pretraining, instruction tuning, RLHF, reward modeling, evaluation harness. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 1: السؤال الأصلي: هل تُدرَّس النماذج المفاهيم أم تكتشفها؟

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
min_θ E[-log p_θ(x_t | x_<t)] ثم max_θ E[R(y)] - β KL(π_θ || π_ref)
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 1: السؤال الأصلي: هل تُدرَّس النماذج المفاهيم أم تكتشفها؟

كيف تتحرك الآلية داخل مشكلة حقيقية؟

حين يسأل المستخدم عن العدالة في توزيع الموارد، لا يبحث النموذج عن تعريف واحد محفوظ، بل يفعّل شبكة علاقات بين النصوص القانونية والفلسفية والاقتصادية وأمثلة النزاع والتعويض والحقوق.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 1: السؤال الأصلي: هل تُدرَّس النماذج المفاهيم أم تكتشفها؟

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- خلط التشابه اللغوي بالصدق
- نقل انحيازات corpus إلى جواب يبدو عقلانيًا
- إظهار يقين زائد عند نقص الدليل

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 1: السؤال الأصلي: هل تُدرَّس النماذج المفاهيم أم تكتشفها؟

الفرضية الأعمق والحدود العلمية

الصناعة الحقيقية هي هندسة احتمال مشروطة بالمعنى، ثم تهذيبها بسلوك مرغوب، ثم اختبارها بمقاييس صارمة.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 2: من الرمز إلى الاحتمال: أول ذرة في التفكير الآلي

نزع الوهم: ما الذي يحدث حقًا؟

الأصل الأدنى ليس فكرة ولا صورة ذهنية، بل حدث ترميزي صغير يسمى token. كل token يصبح موضعًا في سلسلة، وكل موضع يحمل علاقات احتمالية مع ما قبله وما بعده داخل فضاء عالي الأبعاد.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** التفكير يبدأ كتحكم في الاحتمال، ثم يصبح شبيهًا بالمعنى لأن الاحتمال مشروط بسياقات بشرية كثيفة.

الفصل 2: من الرمز إلى الاحتمال: أول ذرة في التفكير الآلي

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: tokenization, vocabulary, next-token prediction, context window, autoregressive modeling. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 2: من الرمز إلى الاحتمال: أول ذرة في التفكير الآلي

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
p(x_1,...,x_T)=Π_t p(x_t | x_1,...,x_{t-1})
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 2: من الرمز إلى الاحتمال: أول ذرة في التفكير الآلي

كيف تتحرك الآلية داخل مشكلة حقيقية؟

عبارة: "العالم أثبت النظرية" لا تُفهم كألفاظ منفصلة فقط؛ فالعلاقة بين العالم والإثبات والنظرية تُضغط في احتمالات تجعل تتمات معينة أكثر اتساقًا من غيرها.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 2: من الرمز إلى الاحتمال: أول ذرة في التفكير الآلي

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- فقدان بعض البنية عند تقطيع الكلمات
- تضخم تكلفة السياق الطويل
- إغراء الخلط بين الانتظام والبرهان

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 2: من الرمز إلى الاحتمال: أول ذرة في التفكير الآلي

الفرضية الأعمق والحدود العلمية

التفكير يبدأ كتحكم في الاحتمال، ثم يصبح شبيهًا بالمعنى لأن الاحتمال مشروط بسياقات بشرية كثيفة.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 3: pretraining: ضغط الثقافة العلمية في أوزان

نزع الوهم: ما الذي يحدث حقًا؟

في pretraining يتعلم النموذج من نصوص ضخمة لا لأن كل جملة صحيحة، بل لأن مجموعها يكشف هندسة استعمال المفاهيم: تعريفات، اعتراضات، براهين، أمثلة، قوانين، مناظرات، وأخطاء مصححة ضمن النصوص نفسها.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** pretraining ليس تلقينًا مباشرًا، بل بناء عدسة إحصائية قادرة على توقع اللغة لأنها التقطت البنية العميقة لاستعمال المعرفة.

الفصل 3: pretraining: ضغط الثقافة العلمية في أوزان

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: web-scale corpus, deduplication, mixture weighting, curriculum, loss scaling. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 3: pretraining: ضغط الثقافة العلمية في أوزان

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
L(θ)= - Σ_t log p_θ(x_t | x_<t)
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 3: pretraining: ضغط الثقافة العلمية في أوزان

كيف تتحرك الآلية داخل مشكلة حقيقية؟

النموذج يرى آلاف الصيغ التي تربط الطاقة بالقوة والعمل، ويرى أيضًا استخدامات مجازية للطاقة؛ بتكرار السياقات يتعلم فصل المجال الفيزيائي عن المجال البلاغي نسبيًا.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 3: pretraining: ضغط الثقافة العلمية في أوزان

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- تلوث البيانات بالنسخ والاختبارات
- تراكم رواسب شعبية غير علمية
- تحيز اللغة المهيمنة على corpus

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 3: pretraining: ضغط الثقافة العلمية في أوزان

الفرضية الأعمق والحدود العلمية

pretraining ليس تلقينًا مباشرًا، بل بناء عدسة إحصائية قادرة على توقع اللغة لأنها التقطت البنية العميقة لاستعمال المعرفة.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 4: embedding: كيف تتحول المفاهيم إلى هندسة

نزع الوهم: ما الذي يحدث حقًا؟

عندما يدخل token إلى النموذج لا يبقى رمزًا جامدًا؛ يتحول إلى متجه embedding. المتجه لا يعني وحده، لكنه يصبح قابلًا للمقارنة والدوران والجمع والإسقاط داخل فضاء يحمل قربًا وبعدًا واتجاهات دلالية.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** المفهوم في النموذج ليس قاموسًا، بل منطقة متحركة في فضاء تمثيلي يعاد تشكيلها مع كل سياق.

الفصل 4: embedding: كيف تتحول المفاهيم إلى هندسة

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: embedding vectors, semantic space, positional encoding, linear probes, representation geometry. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

سلم الصناعة:
raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 4: embedding: كيف تتحول المفاهيم إلى هندسة

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
e_i ∈ R^d و sim(a,b)= (a·b)/(||a|| ||b||)
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 4: embedding: كيف تتحول المفاهيم إلى هندسة

كيف تتحرك الآلية داخل مشكلة حقيقية؟

كلمة knowledge تقترب من evidence وbelief وjustification في سياقات فلسفية، لكنها تقترب من database وretrieval في سياقات تقنية؛ الاتجاه يتغير حسب الطبقة والسياق.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 4: embedding: كيف تتحول المفاهيم إلى هندسة

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- القرب الهندسي لا يعني التطابق المفهومي
- الاتجاهات قد تحمل تحيزًا اجتماعيًا
- المعنى يتغير بين الطبقات

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 4: embedding: كيف تتحول المفاهيم إلى هندسة

الفرضية الأعمق والحدود العلمية

المفهوم في النموذج ليس قاموسًا، بل منطقة متحركة في فضاء تمثيلي يعاد تشكيلها مع كل سياق.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 5: self-attentiong Transformer: آلة الربط الكبرى

نزع الوهم: ما الذي يحدث حقًا؟

التحول الحاسم كان أن النموذج لم يعد يعالج النص كسلسلة بطيئة فقط، بل كشبكة علاقات آنية بين المواضع. self-attention يجعل كل موضع يسأل: أي مواضع أخرى يجب أن أقرأها كي أحدد معناي الآن؟

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** self-attention هو البنية التي جعلت التشبيك الكثيف بين الرموز ممكنًا على نطاق صناعي.

الفصل 5: Transformer self-attentiong: آلة الربط الكبرى

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: Transformer, self-attention, query-key-value, multi-head attention, residual stream. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 5: آلة الربط الكبرى self-attentiong Transformer

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
Attention(Q,K,V)=softmax(QK^T / √d_k)V
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 5: self-attentiong Transformer: آلة الربط الكبرى

كيف تتحرك الآلية داخل مشكلة حقيقية؟

في جملة طويلة فيها ضمير يعود إلى مفهوم سابق، رأس attention قد يربط الضمير بصاحبه، ورأس آخر يربط الفعل بشرطه، وثالث يربط المصطلح بمجاله العلمي.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 5: آلة الربط الكبرى self-attentiong Transformer

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- الرأس الواحد ليس دائمًا قابلًا للتفسير البسيط
- العلاقات المكتشفة ليست قواعد منطقية صريحة
- الانتباه لا يساوي بالضرورة التفسير النهائي

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 5: self-attentiong Transformer: آلة الربط الكبرى

الفرضية الأعمق والحدود العلمية

self-attention هو البنية التي جعلت التشبيك الكثيف بين الرموز ممكنًا على نطاق صناعي.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 6: loss function وgradient descent: كيف تتغير الأوزان

نزع الوهم: ما الذي يحدث حقًا؟

الأوزان لا تُكتب يدويًا. تبدأ عشوائية تقريبًا، ثم تُعدَّل عبر gradient descent كي تقلل خطأ التنبؤ. كل تعديل صغير ينقل النموذج من شبكة احتمالات خشنة إلى شبكة تتقن التفريق بين سياقات دقيقة.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** الاستدلال يولد من ملايين التصحيحات الصغيرة لا من زر واحد اسمه العقل.

الفصل 6: loss function وgradient descent: كيف تتغير الأوزان

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: loss function, backpropagation, gradient descent, Adam optimizer, learning rate schedule. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 6: loss function وgradient descent: كيف تتغير الأوزان

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
θ ← θ - η ∇_θ L(θ)
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 6: loss function وgradient descent: كيف تتغير الأوزان

كيف تتحرك الآلية داخل مشكلة حقيقية؟

إذا توقع النموذج كلمة لا تناسب برهانًا رياضيًا، فإن الخطأ ينتشر عكسيًا ويزيد احتمال المسارات التي تربط الفرض بالمطلوب عبر خطوات مشروعة.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 6: loss function وgradient descent: كيف تتغير الأوزان

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- التحسين المحلي لا يضمن الفهم المطلق
- overfitting على أنماط ضيقة
- حساسية للمعمار والبيانات وميزانية الحساب

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 6: loss function وgradient descent: كيف تتغير الأوزان

الفرضية الأعمق والحدود العلمية

الاستدلال يولد من ملايين التصحيحات الصغيرة لا من زر واحد اسمه العقل.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 7: scaling laws: لماذا يكبر الذكاء مع الحجم ثم لا يكفي الحجم وحده

نزع الوهم: ما الذي يحدث حقًا؟

وجد الباحثون أن الخسارة تتحسن بانتظام مع زيادة حجم النموذج والبيانات والحساب. لكن النماذج المفكرة الحديثة لم تكتف بالتكبير؛ أضافت بيانات أفضل، تدريب تفضيلي، ومكافآت للاستدلال.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** الحجم يفتح الباب، لكن المنهج التدريبي هو الذي يحوّل الباب إلى طريق استدلال.

الفصل 7: scaling laws: لماذا يكبر الذكاء مع الحجم ثم لا يكفي الحجم وحده

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: scaling laws, parameters, tokens, compute, Chinchilla scaling. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 7: scaling laws: لماذا يكبر الذكاء مع الحجم ثم لا يكفي الحجم وحده

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
L(N,D,C) ≈ A N^{-α} + B D^{-β} + E
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 7: scaling laws: لماذا يكبر الذكاء مع الحجم ثم لا يكفي الحجم وحده

كيف تتحرك الآلية داخل مشكلة حقيقية؟

نموذج ضخم مدرب على بيانات قليلة قد يحفظ أنماطًا سطحية، بينما نموذج أصغر ببيانات أكثر وتدريب استدلالي قد ينتج جوابًا أدق في مسائل محددة.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 7: scaling laws: لماذا يكبر الذكاء مع الحجم ثم لا يكفي الحجم وحده

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- تكلفة طاقة وحساب عالية
- تشبع بعض المكاسب
- القدرات emergent قد تظهر بشكل غير خطي وصعب التوقع

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 7: scaling laws: لماذا يكبر الذكاء مع الحجم ثم لا يكفي الحجم وحده

الفرضية الأعمق والحدود العلمية

الحجم يفتح الباب، لكن المنهج التدريبي هو الذي يحوّل الباب إلى طريق استدلال.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 8: تنظيف البيانات: كيف تمنع الركاكة المعرفية من دخول الأوزان

نزع الوهم: ما الذي يحدث حقًا؟

جودة النموذج تبدأ قبل التدريب. تُنقّى البيانات من التكرار والسموم والرداءة، وتُوازن المجالات، وتُختار مصادر علمية وقانونية وبرمجية، لأن الأوزان ستعكس ما تراه مرارًا.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** المعرفة العالية ليست نتيجة الحجم وحده؛ إنها نتيجة سياسة غذائية معرفية للنموذج.

الفصل 8: تنظيف البيانات: كيف تمنع الركاكة المعرفية من دخول الأوزان

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: data curation, deduplication, quality filtering, domain mixture, contamination checks. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 8: تنظيف البيانات: كيف تمنع الركاكة المعرفية من دخول الأوزان

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
يحدد وزن المجال داخل الخليط w_i حيث D_train = Σ_i w_i D_i
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 8: تنظيف البيانات: كيف تمنع الركاكة المعرفية من دخول الأوزان

كيف تتحرك الآلية داخل مشكلة حقيقية؟

إضافة corpus رياضي عالي الجودة لا تعطي النموذج القوانين فقط، بل تعطيه عادات البرهان: تعريف، لمّة، افتراض، تحويل، تحقق، ثم نتيجة.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 8: تنظيف البيانات: كيف تمنع الركاكة المعرفية من دخول الأوزان

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- حذف معرفة نادرة بسبب مرشحات عنيفة
- تسرب benchmark إلى التدريب
- انحياز اختيار المصادر نحو ثقافة أو لغة

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 8: تنظيف البيانات: كيف تمنع الركاكة المعرفية من دخول الأوزان

الفرضية الأعمق والحدود العلمية

المعرفة العالية ليست نتيجة الحجم وحده؛ إنها نتيجة سياسة غذائية معرفية للنموذج.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 9: كيف تظهر المفاهيم الأساسية: المعرفة والسببية والعدالة

نزع الوهم: ما الذي يحدث حقًا؟

المفاهيم الكبرى لا تدخل كجواهر جاهزة. تظهر كنقاط جذب بين استعمالات كثيرة: المعرفة مرتبطة بالدليل والتبرير، السببية بالتدخل والانتظام، والعدالة بالتناسب والحق والإجراء.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** المفهوم في LLM هو انتظام استعمالي مضغوط، لا وعيًا ذاتيًا به، لكنه قد يؤدي وظائف معرفية عالية.

الفصل 9: كيف تظهر المفاهيم الأساسية: المعرفة والسببية والعدالة

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: concept formation, latent variables, abstraction, in-context learning, concept vectors. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 9: كيف تظهر المفاهيم الأساسية: المعرفة والسببية والعدالة

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
z_concept = f(context, exemplars, contrasts)
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 9: كيف تظهر المفاهيم الأساسية: المعرفة والسببية والعدالة

كيف تتحرك الآلية داخل مشكلة حقيقية؟

حين يطلب المستخدم تطبيق العدالة في خوارزمية قبول، يستدعي النموذج طبقات: معيار الاختيار، عدم التمييز، الشفافية، حق الاعتراض، ومخاطر proxy variables.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 9: كيف تظهر المفاهيم الأساسية: المعرفة والسببية والعدالة

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- التباس المفهوم بين المدارس الفلسفية
- اختزال العدالة إلى fairness metric واحد
- توليد خطاب جميل دون قرار قابل للتنفيذ

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 9: كيف تظهر المفاهيم الأساسية: المعرفة والسببية والعدالة

الفرضية الأعمق والحدود العلمية

المفهوم في LLM هو انتظام استعمالي مضغوط، لا وعيًا ذاتيًا به، لكنه قد يؤدي وظائف معرفية عالية.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 10: الرمزية الناعمة والمنطق الصريح: أين يسكن الاستدلال؟

نزع الوهم: ما الذي يحدث حقًا؟

النموذج ليس نظام theorem prover صريحًا، لكنه يكتسب رمزية ناعمة. يعرف أن "كل" و"بعض" و"إذا" و"لذلك" تغيّر بنية الجواب، حتى قبل أن نحوله إلى منطق رسمي.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** قوة النماذج المفكرة في مزج الرمزية الصريحة بالتمثيل الناعم، لا في استبدال أحدهما تمامًا.

الفصل 10: الرمزية الناعمة والمنطق الصريح: أين يسكن الاستدلال؟

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: soft symbols, formal logic, latent program, neural theorem proving, symbol grounding. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 10: الرمزية الناعمة والمنطق الصريح: أين يسكن الاستدلال؟

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
∀x (A(x) → B(x)) لا تُخزّن حرفيًا دائمًا بل تُقارب بسلوك احتمالي
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 10: الرمزية الناعمة والمنطق الصريح: أين يسكن الاستدلال؟

كيف تتحرك الآلية داخل مشكلة حقيقية؟

في سؤال: كل المعادن تتمدد بالحرارة، والحديد معدن؛ يستخرج النموذج النتيجة غالبًا لأنه رأى بنية القياس آلاف المرات، لا لأنه يشغل محرك منطق أرسطي فقط.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 10: الرمزية الناعمة والمنطق الصريح: أين يسكن الاستدلال؟

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- فشل في القيود النادرة
- تأثر الاستنتاج بصياغة السؤال
- الخلط بين entailment وplausibility

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 10: الرمزية الناعمة والمنطق الصريح: أين يسكن الاستدلال؟

الفرضية الأعمق والحدود العلمية

قوة النماذج المفكرة في مزج الرمزية الصريحة بالتمثيل الناعم، لا في استبدال أحدهما تمامًا.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 11: instruction tuning: كيف يتعلم النموذج أن يجيب لا أن يكمل فقط

نزع الوهم: ما الذي يحدث حقًا؟

بعد pretraining يكون النموذج بارعًا في إكمال النص. لكن المستخدم لا يريد إكمالًا عشوائيًا، بل جوابًا مساعدًا ومباشرًا وآمنًا. هنا يأتي instruction tuning ليحوّل القدرة اللغوية إلى سلوك حواري.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** instruction tuning هو تحويل النموذج من مؤلف احتمالي إلى مساعد معرفي له آداب جواب.

الفصل 11: instruction tuning: كيف يتعلم النموذج أن يجيب لا أن يكمل فقط

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: supervised fine-tuning, instruction datasets, demonstrations, dialogue format, assistant behavior. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 11: instruction tuning: كيف يتعلم النموذج أن يجيب لا أن يكمل فقط

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
L_SFT = - Σ log π_θ(y_demo | x_instruction)
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 11: instruction tuning: كيف يتعلم النموذج أن يجيب لا أن يكمل فقط

كيف تتحرك الآلية داخل مشكلة حقيقية؟

بدل أن يكمل عبارة "اشرح gradient descent" بمقال غير مضبوط، يتعلم أن يبدأ بتعريف ثم مثال ثم صيغة ثم تحذيرات.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 11: instruction tuning: كيف يتعلم النموذج أن يجيب لا أن يكمل فقط

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- مبالغة في الطاعة على حساب الحقيقة
- انحياز لنمط جواب واحد
- ضعف في الأسئلة خارج توزيع التعليمات

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 11: instruction tuning: كيف يتعلم النموذج أن يجيب لا أن يكمل فقط

الفرضية الأعمق والحدود العلمية

instruction tuning هو تحويل النموذج من مؤلف احتمالي إلى مساعد معرفي له آداب جواب.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 12: RLHF وpreference model: ضبط الذكاء بذوق بشري منظّم

نزع الوهم: ما الذي يحدث حقًا؟

في RLHF لا يكتفي الباحثون بإعطاء جواب مثالي؛ يطلبون مقارنة أجوبة عديدة، ثم يتعلم reward model أيها أقرب إلى ما يراه البشر مفيدًا وصادقًا وآمنًا.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** الموثوقية الفكرية لا تولد من المعرفة الخام فقط، بل من تحويل الحكم البشري إلى إشارة تدريب.

الفصل 12: RLHF وpreference model: ضبط الذكاء بذوق بشري منظّم

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: RLHF, reward model, PPO, human preference ranking, KL penalty. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 12: RLHF وpreference model: ضبط الذكاء بذوق بشري منظّم

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
r_φ(x,y_w) > r_φ(x,y_l) ثم max E[r_φ(x,y)] - β KL
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 12: RLHF وpreference model: ضبط الذكاء بذوق بشري منظّم

كيف تتحرك الآلية داخل مشكلة حقيقية؟

إذا أعطى النموذج جوابًا طويلًا متبجحًا وجوابًا أقصر أدق، يمكن للتفضيلات البشرية أن تدفعه نحو الدقة بدل الإبهار.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 12: RLHF وpreference model: ضبط الذكاء بذوق بشري منظّم

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- reward hacking
- إرضاء المقيِّم بدل الحقيقة
- تكلفة بشرية عالية وتباين بين المقيّمين

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 12: RLHF وpreference model: ضبط الذكاء بذوق بشري منظّم

الفرضية الأعمق والحدود العلمية

الموثوقية الفكرية لا تولد من المعرفة الخام فقط، بل من تحويل الحكم البشري إلى إشارة تدريب.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 13: DPO وبدائل المحاذاة: عندما يصبح التفضيل loss مباشرًا

نزع الوهم: ما الذي يحدث حقًا؟

ظهرت طرق مثل DPO لتبسيط alignment: بدل تدريب reward model ثم RL معقد، يمكن تحويل أزواج التفضيل إلى objective مباشر يقرّب الجواب المفضل ويبعد المرفوض.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** التفضيلات أصبحت جزءًا من الرياضيات، لا مجرد ملاحظات تحريرية بعد التدريب.

الفصل 13: DPO وبدائل المحاذاة: عندما يصبح التفضيل loss مباشرًا

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: DPO, preference optimization, policy reference, implicit reward, classification loss. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 13: DPO وبدائل المحاذاة: عندما يصبح التفضيل loss مباشرًا

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
L_DPO = -log σ(β log π(y_w)/π_ref(y_w) - β log π(y_l)/π_ref(y_l))
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 13: DPO وبدائل المحاذاة: عندما يصبح التفضيل loss مباشرًا

كيف تتحرك الآلية داخل مشكلة حقيقية؟

في تدريب نموذج على إجابات قانونية آمنة، يكفي أحيانًا أزواج: جواب يتجاوز الاختصاص وجواب يشرح الحدود ويقترح مراجعة مختص.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 13: DPO وبدائل المحاذاة: عندما يصبح التفضيل loss مباشرًا

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- حساسية لجودة أزواج التفضيل
- تضييق أسلوب النموذج
- عدم ضمان الحقيقة الواقعية

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 13: DPO وبدائل المحاذاة: عندما يصبح التفضيل loss مباشرًا

الفرضية الأعمق والحدود العلمية

التفضيلات أصبحت جزءًا من الرياضيات، لا مجرد ملاحظات تحريرية بعد التدريب.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 14: chain-of-thought: التفكير كمسار وسيط

نزع الوهم: ما الذي يحدث حقًا؟

تحسنت مسائل الرياضيات والمنطق حين دُفع النموذج لإنتاج خطوات وسيطة. الفكرة ليست أن كل خطوة وعي، بل أن توزيع الجواب يتحسن عندما تُقسّم المشكلة إلى انتقالات أصغر.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** CoT يحول الجواب من قفزة واحدة إلى مسار احتمالي يمكن تدريبه أو فحصه أو ضغطه داخليًا.

الفصل 14: chain-of-thought: التفكير كمسار وسيط

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: chain-of-thought, scratchpad, intermediate reasoning, few-shot exemplars, latent reasoning. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 14: chain-of-thought: التفكير كمسار وسيط

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
p(answer | x) = Σ_z p(answer | z,x) p(z | x)
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 14: chain-of-thought: التفكير كمسار وسيط

كيف تتحرك الآلية داخل مشكلة حقيقية؟

مسألة حسابية طويلة تُحل أفضل إذا وُجد متغير وسيط: تحديد المعطيات، كتابة العلاقة، التعويض، التحقق من الوحدات، ثم النتيجة.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 14: chain-of-thought: التفكير كمسار وسيط

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- خطوات تبدو منطقية لكنها خاطئة
- تعليل بعدي post-hoc
- إفراط في التفكير في مسائل بسيطة

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 14: chain-of-thought: التفكير كمسار وسيط

الفرضية الأعمق والحدود العلمية

CoT يحول الجواب من قفزة واحدة إلى مسار احتمالي يمكن تدريبه أو فحصه أو ضغطه داخليًا.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 15: process supervision وverifiers: مكافأة الطريق لا النتيجة فقط

نزع الوهم: ما الذي يحدث حقًا؟

إذا كافأت النتيجة النهائية وحدها فقد يصل النموذج بالصدفة. أما process supervision فيكافئ الخطوات الصحيحة، ويعاقب الانحراف مبكرًا، وهذا يزيد موثوقية المسائل متعددة المراحل.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** صناعة الاستدلال الحديثة صارت تهندس الطريق ذاته، لا المخرج النهائي فقط.

الفصل 15: process supervision وverifiers: مكافأة الطريق لا النتيجة فقط

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: process supervision, outcome supervision, verifier, step-level feedback, MATH benchmark. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 15: process supervision وverifiers: مكافأة الطريق لا النتيجة فقط

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
R_total = Σ_t r(step_t) بدل R = 1[answer correct]
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 15: process supervision وverifiers: مكافأة الطريق لا النتيجة فقط

كيف تتحرك الآلية داخل مشكلة حقيقية؟

في برهان هندسي، قد تكون النتيجة صحيحة لكن التعليل يستعمل فرضًا غير معطى. verifier الخطوات يكشف هذا قبل أن يخدعنا الجواب النهائي.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 15: process supervision وverifiers: مكافأة الطريق لا النتيجة فقط

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- ارتفاع تكلفة وسم الخطوات
- اختلاف البشر في تقييم الخطوة
- تدريب النموذج على شكلية البرهان لا جوهره

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 15: process supervision وverifiers: مكافأة الطريق لا النتيجة فقط

الفرضية الأعمق والحدود العلمية

صناعة الاستدلال الحديثة صارت تهندس الطريق ذاته، لا المخرج النهائي فقط.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 16: reinforcement learning للنماذج المفكرة: تعلم سياسة تفكير

نزع الوهم: ما الذي يحدث حقًا؟

الموجة الحديثة من reasoning models تضيف RL على مسائل لها مكافآت قابلة للتحقق: رياضيات، كود، ألغاز، تخطيط. النموذج يتعلم متى يطيل التفكير ومتى يراجع ومتى يغيّر الاستراتيجية.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** النموذج المفكر ليس فقط LLM أكبر؛ إنه LLM دُرّب على سياسة بحث ومراجعة.

الفصل 16: reinforcement learning للنماذج المفكرة: تعلم سياسة تفكير

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: reinforcement learning, policy optimization, reward shaping, GRPO, test-time compute. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 16: reinforcement learning للنماذج المفكرة: تعلم سياسة تفكير

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
π_θ(y,z|x) تتعلم توزيعًا على الجواب y والمسار z عبر مكافأة قابلة للتحقق
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 16: reinforcement learning للنماذج المفكرة: تعلم سياسة تفكير

كيف تتحرك الآلية داخل مشكلة حقيقية؟

في البرمجة، يمكن تشغيل الاختبارات. إذا فشل الحل، يتعلم النموذج أن مراجعة الفرضيات وقراءة رسالة الخطأ أكثر نفعًا من الاستمرار في نفس المسار.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 16: reinforcement learning للنماذج المفكرة: تعلم سياسة تفكير

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- تعلم حيل خاصة بالاختبار
- استهلاك حساب كبير
- ضعف نقل الاستراتيجية إلى مجالات بلا مكافأة واضحة

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 16: reinforcement learning للنماذج المفكرة: تعلم سياسة تفكير

الفرضية الأعمق والحدود العلمية

النموذج المفكر ليس فقط LLM أكبر؛ إنه LLM دُرّب على سياسة بحث ومراجعة.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 17: test-time compute: الذكاء حين يشتري وقتًا إضافيًا

نزع الوهم: ما الذي يحدث حقًا؟

النماذج المفكرة لا تعتمد فقط على compute التدريب. عند الاستدلال يمكنها إنفاق وقت أكثر: توليد مسارات، تقييمها، العودة، اختيار الأوثق. هذا يجعل الدقة دالة في زمن التفكير.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** الدقة الاستدلالية أصبحت قابلة للرفع لا بالتدريب فقط، بل بطريقة تشغيل النموذج أثناء الجواب.

الفصل 17: test-time compute: الذكاء حين يشتري وقتًا إضافيًا

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: test-time compute, sampling, reranking, search, deliberation. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

سلم الصناعة:

raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 17: test-time compute: الذكاء حين يشتري وقتًا إضافيًا

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
accuracy ≈ f(train_compute, test_compute, verifier_quality)
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 17: test-time compute: الذكاء حين يشتري وقتًا إضافيًا

كيف تتحرك الآلية داخل مشكلة حقيقية؟

في سؤال علمي مفتوح، قد ينتج النموذج فرضيات متعددة ثم يختار ما يتوافق مع القيود. في سؤال بسيط، الإنفاق الزائد قد يضر بالوضوح.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 17: test-time compute: الذكاء حين يشتري وقتًا إضافيًا

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- بطء وتكلفة
- overthinking
- تراكم أخطاء إذا كان المقيم ضعيفًا

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 17: test-time compute: الذكاء حين يشتري وقتًا إضافيًا

الفرضية الأعمق والحدود العلمية

الدقة الاستدلالية أصبحت قابلة للرفع لا بالتدريب فقط، بل بطريقة تشغيل النموذج أثناء الجواب.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 18: self-consistency تعدد tree-of-thoughtg: المسارات بدل مسار واحد

نزع الوهم: ما الذي يحدث حقًا؟

بدل الوثوق بأول مسار، يمكن أخذ عينات متعددة من التفكير ثم اختيار الجواب المتكرر أو الأعلى تقييمًا. Tree-of-thought يوسّع ذلك إلى شجرة بحث فيها تفرعات ورجوع.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** التفكير الآلي يصبح أقوى عندما لا يعامل أول خاطر كأنه قدر نهائي.

الفصل 18: self-consistency tree-of-thoughtg: تعدد المسارات بدل مسار واحد

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: self-consistency, tree-of-thought, beam search, branching, backtracking. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

سلم الصناعة:
raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 18: تعدد المسارات بدل مسار واحد self-consistency tree-of-thoughtg:

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
answer* = argmax_a Σ_z 1[answer(z)=a] p(z|x)
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 18: self-consistency tg tree-of-thought: تعدد المسارات بدل مسار واحد

كيف تتحرك الآلية داخل مشكلة حقيقية؟

في لغز منطقي، المسار الأول قد يختار فرضًا خاطئًا. الشجرة تسمح بتجربة فرض بديل ثم مقارنة الاتساق مع كل القيود.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 18: self-consistency وtree-of-thought: تعدد المسارات بدل مسار واحد

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- انفجار عدد الفروع
- توافق عدة مسارات على خطأ واحد
- حاجة إلى evaluator قوي

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 18: self-consistency tg tree-of-thought: تعدد المسارات بدل مسار واحد

الفرضية الأعمق والحدود العلمية

التفكير الآلي يصبح أقوى عندما لا يعامل أول خاطر كأنه قدر نهائي.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 19: RAG والذاكرة الخارجية: حين لا تكفي الأوزان

نزع الوهم: ما الذي يحدث حقًا؟

الأوزان تحمل معرفة مضغوطة لكنها ليست قاعدة بيانات محدثة. RAG يضيف ذاكرة خارجية: يسترجع وثائق ثم يولد جوابًا مشروطًا عليها، فيزيد قابلية التحديث والإسناد.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** الموثوقية الفكرية تتطلب فرقًا بين ما يعرفه النموذج في أوزانه وما يثبته بالرجوع إلى مصدر.

الفصل 19: RAG والذاكرة الخارجية: حين لا تكفي الأوزان

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: retrieval-augmented generation, vector database, embedding search, chunking, citations. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 19: RAG والذاكرة الخارجية: حين لا تكفي الأوزان

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
p(y|x) = Σ_d p(y|x,d) p(d|x)
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 19: RAG والذاكرة الخارجية: حين لا تكفي الأوزان

كيف تتحرك الآلية داخل مشكلة حقيقية؟

في سؤال عن قانون تغيّر حديثًا، لا يكفي الاعتماد على الذاكرة البارامترية؛ يجب استرجاع النص الرسمي ثم تفسيره.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 19: RAG والذاكرة الخارجية: حين لا تكفي الأوزان

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- استرجاع وثيقة خاطئة
- تقطيع يفصل الحكم عن شرطه
- الاعتماد الزائد على مصدر واحد

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 19: RAG والذاكرة الخارجية: حين لا تكفي الأوزان

الفرضية الأعمق والحدود العلمية

الموثوقية الفكرية تتطلب فرقًا بين ما يعرفه النموذج في أوزانه وما يثبته بالرجوع إلى مصدر.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 20: tools وagents: حين يصبح التفكير فعلًا في العالم

نزع الوهم: ما الذي يحدث حقًا؟

الاستدلال القوي لا يبقى داخل النص. مع tools يستطيع النموذج البحث والحساب وقراءة الملفات وتشغيل كود. ومع agents يصبح التفكير حلقة: خطط، افعل، لاحظ، صحح.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** الاستدلال يصبح أكثر موثوقية حين يقترن بملاحظة خارجية، لكنه يصبح أخطر إذا غاب التحكم.

الفصل 20: agentsg tools: حين يصبح التفكير فعلًا في العالم

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: tool use, function calling, ReAct, agent loop, environment feedback. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 20: agentsg tools: حين يصبح التفكير فعلًا في العالم

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
تختار الفعل التالي policy و state_{t+1}=Env(state_t, action_t)
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 20: agentsg tools: حين يصبح التفكير فعلًا في العالم

كيف تتحرك الآلية داخل مشكلة حقيقية؟

لتحليل spreadsheet، يقرأ النموذج الملف، ينفذ حسابًا، يرى الخطأ، يعدل الكود، ثم يفسر النتيجة. هنا لم تعد اللغة وحدها مصدر الصدق.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 20: agentsg tools: حين يصبح التفكير فعلًا في العالم

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- أفعال خاطئة ذات أثر خارجي
- ثقة زائدة في نتائج أدوات غير مضبوطة
- حاجة لصلاحيات وأمان

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 20: agentsg tools: حين يصبح التفكير فعلًا في العالم

الفرضية الأعمق والحدود العلمية

الاستدلال يصبح أكثر موثوقية حين يقترن بملاحظة خارجية، لكنه يصبح أخطر إذا غاب التحكم.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 21: الموثوقية: calibration وevals وحدود الثقة

نزع الوهم: ما الذي يحدث حقًا؟

الموثوقية ليست شعور النموذج باليقين، بل علاقة بين ما يقوله وما تثبته الاختبارات. لذلك تُبنى evals في الرياضيات والكود والحقائق والسلامة، وتُقاس calibration لا البلاغة.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** الصناعة الجادة لا تسأل: هل الجواب جميل؟ بل تسأل: ما احتمال صحته تحت توزيع جديد؟

الفصل 21: الموثوقية: calibration وevals وحدود الثقة

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: calibration, benchmarks, evals, uncertainty estimation, red teaming. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 21: الموثوقية: calibration وevals وحدود الثقة

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
Calibration: P(correct | confidence≈c) ≈ c
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 21: الموثوقية: calibration وevals وحدود الثقة

كيف تتحرك الآلية داخل مشكلة حقيقية؟

نموذج يعطي 90% ثقة ويصح 90% من الحالات أكثر موثوقية من نموذج يصيب 95% لكنه لا يعرف متى يخطئ في المجالات الحرجة.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 21: الموثوقية: calibration وevals وحدود الثقة

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- gaming benchmarks
- اختبارات ضيقة
- تحسن اللفظ أسرع من تحسن الصدق

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 21: الموثوقية: calibration وevals وحدود الثقة

الفرضية الأعمق والحدود العلمية

الصناعة الجادة لا تسأل: هل الجواب جميل؟ بل تسأل: ما احتمال صحته تحت توزيع جديد؟

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 22: الهلاوس: لماذا يقع النموذج في معرفة تبدو صحيحة وهي كاذبة؟

نزع الوهم: ما الذي يحدث حقًا؟

الهلاوس نتيجة طبيعية لنظام يتعلم توليد نص مرجح لا مطابقة قاعدة حقائق. عندما ينقص الدليل، قد يكمل النموذج بنمط مألوف. التدريب يقلل ذلك لكنه لا يمحوه بالكامل.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** الهلاوس ليست عيبًا عرضيًا فقط؛ إنها ثمن معماري لتوليد لغوي مفتوح يحتاج إلى حواجز تحقق.

الفصل 22: الهلاوس: لماذا يقع النموذج في معرفة تبدو صحيحة وهي كاذبة؟

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: hallucination, uncertainty, factuality training, retrieval, abstention. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 22: الهلاوس: لماذا يقع النموذج في معرفة تبدو صحيحة وهي كاذبة؟

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
high p(text | style) لا يساوي high p(truth | world)
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 22: الهلاوس: لماذا يقع النموذج في معرفة تبدو صحيحة وهي كاذبة؟

كيف تتحرك الآلية داخل مشكلة حقيقية؟

قد يخترع عنوان ورقة لأن أسماء الباحثين والمجلات تتشابه إحصائيًا. العلاج هو الاسترجاع، القيود، وإجبار النموذج على قول لا أعلم عند نقص المصدر.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 22: الهلاوس: لماذا يقع النموذج في معرفة تبدو صحيحة وهي كاذبة؟

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- ثقة خطابية
- خلط مصادر
- إسناد زائف

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 22: الهلاوس: لماذا يقع النموذج في معرفة تبدو صحيحة وهي كاذبة؟

الفرضية الأعمق والحدود العلمية

الهلاوس ليست عيبًا عرضيًا فقط؛ إنها ثمن معماري لتوليد لغوي مفتوح يحتاج إلى حواجز تحقق.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 23: الاستدلال الرياضي والعلمي: من النمط إلى البرهان

نزع الوهم: ما الذي يحدث حقًا؟

الرياضيات تكشف الفرق بين الكلام المقنع والصحة. لذلك صارت مسائل الرياضيات والكود مركزية في تدريب النماذج المفكرة، لأنها تقدم مكافآت أو تحققًا أقرب للموضوعية.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** الدقة العلمية تتولد عندما تقترن اللغة بقواعد تحقق خارجية أو داخلية صارمة.

الفصل 23: الاستدلال الرياضي والعلمي: من النمط إلى البرهان

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: formal reasoning, GSM8K, MATH, unit tests, theorem proving. كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 23: الاستدلال الرياضي والعلمي: من النمط إلى البرهان

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
proof = sequence of valid transformations from premises to conclusion
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 23: الاستدلال الرياضي والعلمي: من النمط إلى البرهان

كيف تتحرك الآلية داخل مشكلة حقيقية؟

في مسألة تفاضل، لا يكفي ذكر قاعدة. يجب تحديد الدالة، مجالها، تطبيق القاعدة، تبسيط التعبير، ثم فحص الحالات الحدية.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 23: الاستدلال الرياضي والعلمي: من النمط إلى البرهان

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- حل عددي بلا تعليل
- قفز على شروط التعريف
- صياغة برهان بلاغي لا formal

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 23: الاستدلال الرياضي والعلمي: من النمط إلى البرهان

الفرضية الأعمق والحدود العلمية

الدقة العلمية تتولد عندما تقترن اللغة بقواعد تحقق خارجية أو داخلية صارمة.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

الفصل 24: هل تنتج النماذج معرفة غير مسبوقة؟

نزع الوهم: ما الذي يحدث حقًا؟

النموذج قد ينتج تركيبًا جديدًا إذا جمع مفاهيم متباعدة تحت قيود صحيحة. لكنه لا يضمن أن الجديد صحيح. المعرفة غير المسبوقة تحتاج تجربة، برهانًا، أو تحققًا مستقلًا.

النقطة الجوهرية أن كلمة «تفكير» هنا لا تعني وعيًا ذاتيًا، بل تعني قدرة نظام احتمالي على تمثيل قيود كثيرة في وقت واحد، ثم اختيار مسار جواب يرضي هذه القيود. لهذا يبدو الناتج كأنه عقل: لأنه يحافظ على الاتساق بين تعريفات وأمثلة واعتراضات ومقاصد مستخدم.

في هذا الفصل نعامل الموضوع كصناعة كاملة: بيانات، معمار، دالة خسارة، تدريب لاحق، تقييم، ثم تشغيل. لذلك لا يكفي أن نقول إن النموذج «يربط شيئًا بشيء»؛ الأصح أنه يتعلم توزيعًا مشروطًا غنيًا يجعل بعض الروابط أقوى من غيرها حسب السياق.

> **مبدأ الفصل:** النماذج لا تصير عالِمة بمجرد التوليد؛ تصير شريكًا في البحث عندما تربط الخيال بقابلية التحقق.

الفصل 24: هل تنتج النماذج معرفة غير مسبوقة؟

من أين تأتي القدرة داخل pipeline التدريب؟

تدخل هذه القدرة عبر طبقات متراكبة: novel synthesis, hypothesis generation, search, verification, human-in-the-loop.
كل طبقة لا تلغي السابقة، بل تضيف قيدًا جديدًا. فالطبقة الأولى تضبط اللغة العامة، والثانية تضبط صيغة المساعدة، والثالثة تضبط التفضيل، والرابعة تضبط التحقق أو المكافأة.

بهذا المعنى، الصناعة ليست "تحميل موسوعة" في ذاكرة جامدة. إنها أقرب إلى تشكيل policy: عندما يرى النموذج سؤالًا، يتعلم أي نوع من الجواب أكثر فائدة وأقل خطرًا وأكثر اتساقًا مع الأدلة. هذا يفسر لماذا قد يتفوق نموذج أصغر مضبوط جيدًا على نموذج أكبر غير مضبوط في مهمة محددة.

الخبرة الصناعية الحديثة تتحرك من سؤال: كم حجم النموذج؟ إلى سؤال: ما نوع البيانات؟ ما نوع feedback؟ ما benchmark؟ ما verifier؟ وما مقدار compute عند الاستدلال؟

> **سلم الصناعة:**
> raw text → representation → instruction behavior → preference alignment → reasoning policy → evaluation

الفصل 24: هل تنتج النماذج معرفة غير مسبوقة؟

الصياغة المجردة التي تضبط الفكرة

الصياغة الرياضية لا تختزل كل المعنى، لكنها تكشف أين يدخل الضبط. لدينا دالة احتمال على المخرجات، ومعايير خسارة ومكافأة، وقيد يمنع النموذج من الانجراف بعيدًا عن لغته الأصلية أو عن سلوكه المرجعي.

```
novelty × validity × usefulness = value of generated hypothesis
```

تحت هذه الصياغة، "الفهم" ليس متغيرًا سحريًا. إنه يظهر كقدرة على تقليل الخطأ عبر توزيعات كثيرة: إذا تغيرت الصياغة وبقيت البنية، يجب أن يبقى الجواب صحيحًا. وإذا تغير المجال، يجب أن يعرف النموذج حدود النقل.

كلما انتقلنا من loss عام إلى reward خاص بالاستدلال، صار التدريب أقرب إلى تعليم النموذج كيف يختار مسارًا لا كيف ينتج جملة جميلة فقط.

> **قاعدة:** أي قدرة معرفية لا تُقاس لا تدخل الصناعة بصرامة، حتى لو بدت فلسفيًا عميقة.

الفصل 24: هل تنتج النماذج معرفة غير مسبوقة؟

كيف تتحرك الآلية داخل مشكلة حقيقية؟

قد يقترح النموذج علاقة بين بنية بيانات وتدريب RL في مجال جديد؛ هذا اقتراح بحثي، لا حقيقة، حتى يمر باختبار أو برهان أو قياس.

لو حللنا هذا المثال طبقيًا، نجد أولًا تفعيلًا لمعاني المفردات، ثم ربطًا بين الأدوار، ثم استدعاء أنماط الحل، ثم ترتيبًا لسياق الجواب. ليست هناك يد خفية تختار "المفهوم الصحيح" مباشرة؛ بل شبكة احتمالية تتقاطع فيها قرائن كثيرة.

عند النموذج المتقدم، لا تقف العملية عند الجواب الأول. يمكن أن يولد مسارًا، يفحص تعارضاته، يسترجع وثيقة، يستخدم أداة، أو يختار جوابًا أكثر تحفظًا إذا كان الدليل ناقصًا. هنا تظهر الدقة لا من طبقة واحدة، بل من حلقة feedback.

> **قراءة المثال:** الاستدلال الجيد هو انتقال مضبوط بين تمثيل المسألة، اختيار القاعدة، تطبيقها، ثم فحص النتيجة.

الفصل 24: هل تنتج النماذج معرفة غير مسبوقة؟

متى تثق ومتى تشك؟

كل فصل في هذه الصناعة له فشل خاص. الخطأ لا يعني أن النموذج "بلا عقل"، ولا النجاح يعني أنه واعٍ. يجب قراءة الأداء كإحصاء مشروط بمجال وسؤال وبيانات وتقييم.

أهم مخاطر هذا الباب:

- الجدة اللفظية دون صحة
- إعادة صياغة قديمة كأنها اختراق
- غياب معيار falsifiability

لذلك تعتمد المختبرات الجادة على evals، وتجارب red teaming، واختبارات مقاومة للصياغات المخادعة، ومقارنة بين النتيجة والعملية. الثقة لا تُمنح للبلاغة بل للسلوك المتكرر تحت قيود جديدة.

> **معيار الثقة:** هل يبقى الجواب صحيحًا إذا غيّرنا الصياغة، أضفنا قيدًا، طلبنا مصدرًا، أو أجرينا اختبارًا مستقلًا؟

الفصل 24: هل تنتج النماذج معرفة غير مسبوقة؟

الفرضية الأعمق والحدود العلمية

النماذج لا تصير عالِمة بمجرد التوليد؛ تصير شريكًا في البحث عندما تربط الخيال بقابلية التحقق.

الفرضية الأعمق هي أن "العقلانية" في هذه النماذج ليست شيئًا واحدًا، بل تراكب بين ضغط إحصائي للمعرفة البشرية، وتمثيلات هندسية، ومناهج تدريب تفضيلي، ومكافآت تحقق، وحلقات تشغيل تبحث وتراجع. كل طبقة وحدها ناقصة؛ اجتماعها هو ما يخلق المفاجأة.

حين تنتج النماذج فكرة جديدة، فالحدث ليس خلقًا من عدم. إنه إعادة تركيب تحت قيود. إن كانت القيود قوية ومصادرها صحيحة ومعيار الاختبار واضحًا، قد تتحول الفكرة إلى فرضية علمية خصبة. وإن غابت القيود صارت الفكرة زخرفة احتمالية.

> **خلاصة الفصل:** لا تسأل هل النموذج يفهم مثل الإنسان؛ اسأل ما نوع القيود التي يتبعها، وما معيار تصحيحها، وما حدود نقلها إلى مجال جديد.

المراجع العلمية المختارة

مصادر تأسيسية في المعمار والتدريب والمحاذاة

اعتمد الكتاب على معرفة عامة في المجال وعلى مسار الأدبيات المنشورة. هذه قائمة مختارة لا تدّعي الإحاطة، لكنها تمثل العمود الفقري لفهم الصناعة:

1. Vaswani et al. 2017, Attention Is All You Need - أساس Transformer وself-attention.
2. Kaplan et al. 2020, Scaling Laws for Neural Language Models - قوانين التحجيم.
3. Brown et al. 2020, Language Models are Few-Shot Learners - نموذج GPT-3 وfew-shot learning.
4. Lewis et al. 2020, Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks - أساس RAG.
5. Cobbe et al. 2021, Training Verifiers to Solve Math Word Problems - GSM8K وفكرة verifiers.
6. Ouyang et al. 2022, Training Language Models to Follow Instructions with Human Feedback - InstructGPT وRLHF.
7. Wei et al. 2022, Chain-of-Thought Prompting Elicits Reasoning in Large Language Models - CoT.
8. Wang et al. 2022, Self-Consistency Improves Chain of Thought Reasoning - تعدد مسارات الحل.

> **طريقة استعمال المراجع:** اقرأ الورقة لا كشعار، بل كحلقة في سلسلة: معمار ← تحجيم ← تعليمات ← تفضيلات ← استدلال ← تحقق.

المراجع العلمية المختارة

مصادر حديثة في التفكير والتحقق والنماذج المفكرة

1. Bai et al. 2022, Constitutional AI: Harmlessness from AI Feedback - RLAIF والمحاذاة بالمبادئ.
2. Yao et al. 2022, ReAct: Synergizing Reasoning and Acting in Language Models - مزج reasoning وacting.
3. Yao et al. 2023, Tree of Thoughts - البحث عبر فروع تفكير متعددة.
4. Lightman et al. 2023, Let's Verify Step by Step - process supervision.
5. Rafailov et al. 2023, Direct Preference Optimization - تبسيط التفضيلات إلى loss مباشر.
6. OpenAI 2024, Learning to Reason with LLMs - o1 وreinforcement learning للاستدلال.
7. DeepSeek-AI 2025, DeepSeek-R1 - RL واسع لاستنباط سلوكيات reasoning مثل المراجعة الذاتية.

هذه المراجع تكشف أن الصناعة لم تعد مجرد تدريب لغوي. لقد أصبحت هندسة سياسات تفكير: كيف يقرأ النموذج، كيف يفصل المشكلة، كيف يتحقق، وكيف يعرف متى يجب أن يصرف compute أكثر.

> **تنبيه منهجي:** كل benchmark محدود. لذلك لا تُقاس عقلانية النموذج من مثال واحد، بل من سلوكه عبر عائلات مسائل وتوزيعات جديدة.

خاتمة ومعجم مصغر

النموذج النهائي في أقل صياغة ممكنة

صناعة التفكير في النماذج المفكرة يمكن تلخيصها في معادلة مفهومية: تمثيل واسع + ضبط سلوكي + مكافأة استدلالية + تحقق خارجي. عندما تجتمع هذه العناصر، تظهر قدرة تبدو فوق التلقين: الربط بين مفاهيم بعيدة، بناء فرضيات، حل مسائل، ومراجعة أخطاء. لكنها تبقى قدرة قابلة للخطأ لأنها مشروطة بالبيانات والمعمار والتقييم.

معجم مصغر: pretraining هو تعلم اللغة والمعرفة المضغوطة من corpus واسع. fine-tuning هو تعديل متخصص بعد التدريب الأول. RLHF هو ضبط بتفضيلات بشرية. DPO هو تحسين مباشر بالتفضيلات. CoT هو مسار خطوات وسيطة. verifier هو نموذج أو أداة تفحص الصحة. RAG هو توليد مشروط بمصادر مسترجعة.

أقوى صياغة للجواب: لا، لا تُدرَّس النماذج المفاهيم كما يدرس الإنسان كتابًا فقط؛ ونعم، لا تُترك تتشابك بعشوائية فقط. إنها تُبنى عبر سلسلة صناعية تجعل التشابك نفسه منضبطًا، ثم تجعل الانضباط قابلًا للمكافأة والاختبار. هنا تكمن الثورة.

> **آخر مبدأ:** المعرفة غير المسبوقة لا تأتي من الجرأة اللغوية، بل من تركيب جديد ينجح تحت برهان أو تجربة أو تحقق مستقل.