هندسة MOUSSAIF9B للتدريب الحاكمي نحو نماذج AGI

إطار تأسيسي متعدد المقاييس لنموذج فعلي 1B ومسار ترقية إلى 9B عبر MCD وQ-MCD وHAKIM-MCD وMICAGFI وKB-as-OS

Zouhair Moussaif / زهير مساعف

يوليو 2026

ورقة تأسيسية نظرية وهندسية - لا تتضمن ادعاء تدريب نموذج فعلي أو إثبات *AGI*

الفهرس التركيبي

- الملخص التنفيذي
- الملخص
- 1. الإعلان المنهجي ومراتب المعرفة
- 2. الوضع الأنطولوجي ونوع السؤال
- 3. مشكلة البحث والفجوة المركزية
- 4. الخلفية العلمية: من القياس إلى النماذج العملية
- 5. النسب العربي والمتعدد اللغات
- 6. هوية المشروع: MOUSSAIF9B-1B وMOUSSAIF9B-9B
- 7. المعمارية المرجعية متعددة المقاييس
- 8. دستور البيانات: من corpus إلى حجة تدريبية
- 9. تحويل المئة برنامج قبل التدريب إلى عشر طبقات
- 10. مصفوفة طبقات Pretraining
- 11. مراحل ما قبل التدريب المقترحة
- 12. تحويل المئة برنامج بعد التدريب إلى عشر دوائر
- 13. مصفوفة طبقات Post-training
- 14. هندسة التفكير: متى يفكر النموذج؟
- 15. منظومة التحقق ومحكمة الهدم
- 16. الأدوات والوكالة: من النص إلى الفعل
- 17. السياق والذاكرة وKB-as-OS
- 18. MCD وQ-MCD وHAKIM-MCD وMICAGFI
- 19. تحليل المجال في 26 نقطة مؤسسة
- 20. ثلاثة نماذج متنافسة للمشروع
- 21. المقارنة باستخدام MCD وQMCD
- 22. نظرية مساعف للرافعة المعرفية للمعلمة
- 23. نظرية عرض نطاق الفرق الحاكمي
- 24. نظرية الوعائية الحسابية متعددة المديات
- 25. نظرية تبلور المهارة المحكوم بالهدم
- 26. نظرية الذاكرة المزدوجة ذات النزاهة
- 27. نظرية الوكالة العودية المحدودة بأثر العالم
- 28. النموذج النظري النهائي: معمارية الرافعة الحاكمية
- 29. الصياغة الصورية وشبه الرياضية
- 30. عشرون مفهوما جديدا أو معاد ضبطه
- 31. عشر أدوات منهجية وتشغيلية
- 32. سبعة مقاييس أولية
- 33. ثماني عشرة فرضية بحثية
- 34. تسعة تنبؤات فارقة
- 35. محفظة التقييم: الذكاء متجه لا ترتيب واحد
- 36. بروتوكول بناء MOUSSAIF9B-1B
- 37. بروتوكول الترقية إلى MOUSSAIF9B-9B
- 38. استراتيجية الحساب والتكلفة والمخاطر التشغيلية
- 38.1 هندسة الأهداف ودوال الخسارة
- 38.2 البنية الموزعة للتدريب ومراقبة الاستقرار
- 38.3 تشغيل 70 HyperSkills وHyperLoops
- 38.4 الضغط والتقطير والنشر متعدد الطبقات
- 38.5 المنهج الإحصائي وإثبات التحسن السببي
- 38.6 مقارنة مرجعية مع نماذج الحجم القريب
- 38.7 شجرة القرار: التدريب من الصفر أم التكييف؟
- 39. السلامة والتفويض والمرونة
- 40. محكمة الهدم: اثنا عشر اعتراضا قويا
- 41. النسخة المعدلة بعد الهدم
- 42. برنامج سنة واحدة
- 43. برنامج ثلاث سنوات وعشر سنوات
- 44. نواة قاعدة المعرفة المقترحة
- 45. سجل البناء المعرفي
- 46. اختبار الجودة الداخلي
- 47. الخاتمة التأسيسية: ماذا أصبح لدينا؟
- 48. الملخص الشامل المحيط والهندسة المعرفية
- المراجع
- الملحق أ: سجل 100 برنامج Pretraining
- الملحق ب: سجل 100 برنامج Post-training

الملخص التنفيذي

تقدم هذه الورقة قرارًا هندسيًا واضحًا: يبدأ مشروع MOUSSAIF9B بنموذج فعلي في نطاق 1B بوصفه مختبرًا قابلًا للتكرار وطبقة edge، ثم ينتقل إلى نموذج مستهدف يقارب 9B بعد أن تُثبت وصفة البيانات والتدريب والقياس صلاحيتها على المقاييس الأصغر. الاسم MOUSSAIF9B يظل اسم المشروع ما لم يتحقق الحجم فعليًا، ويجب أن تحمل كل نسخة عدد معلماتها الحقيقي في الاسم والبطاقة.

لا تقوم الاستراتيجية على مطاردة الحجم وحده. الأدبيات الحديثة توضح أن جودة البيانات، طول التدريب، post-training، والاسترجاع والأدوات قد تمنح النماذج الصغيرة رافعة كبيرة. لذلك تُقترح معمارية 1B تقريبية بأبعاد 1792 و24 طبقة، ومعمارية 9B تقريبية بأبعاد 4608 و32 طبقة، مع GQA وSwiGLU وRMSNorm وRoPE. هذه التكوينات ليست مقدسة؛ تُختبر عبر عائلة proxies قبل أي التزام مالي واسع.

المئتا برنامج تدريبي لا تُنفذ كقائمة مستقلة؛ تُضغط إلى عشر طبقات قبل التدريب وعشر دوائر بعده. قبل التدريب تشمل المعرفة واللغة والعلوم والكود والاستدلال والسياق ونماذج العالم والنزاهة والأدوات وMoussaif-native training. بعد التدريب تشمل اتباع التعليمات والحكم والأدوات والذاكرة والبحث والكود والنقد والسلامة والتعدد اللغوي والتكامل الحاكمي. كل برنامج يحصل على capability target وdata source وverifier وfailure mode.

القيمة المضافة للمشروع تُختبر عبر ست نظريات: الرافعة المعرفية للمعلمة؛ عرض نطاق الفرق الحاكمي؛ الوعائية الحسابية متعددة المديات؛ تبلور المهارة المحكوم بالهدم؛ الذاكرة المزدوجة ذات النزاهة؛ والوكالة العودية المحدودة بأثر العالم. لا يُفترض صدق هذه النظريات؛ تُفصل باختبارات ablation ومهام انتقال خارج التوزيع.

مسار التنفيذ الواقعي من أربع درجات: proxies صغيرة لاختبار tokenizer والخلطات؛ 1B MVP على 100-300B token؛ 1B طويل التدريب إذا أثبتت المنهجية جدواها؛ ثم 9B على 2-5T token وفق الميزانية ومنحنيات القياس المحلية. إذا لم تتوفر البنية التحتية، يبقى المسار العلمي صالحًا عبر 1B من الصفر وcontinued pretraining أو post-training لنموذج 7-9B مفتوح.

بوابات النجاح ليست MMLU أو IQ-like score منفردًا. يلزم متجه قدرات يضم المعرفة والاستدلال والتجريد والأدوات والذاكرة والمعايرة والمرونة والكفاءة، مع أرضيات إلزامية للسلامة ونزاهة المعرفة. ويجب أن تنجو المكاسب من contamination checks، procedural holdouts، تبديل اللغة، أعطال الأدوات، تقليص compute، ومحكمة هدم قوية.

الأفق الأعلى هو بناء نموذج-نظام يستطيع استخراج الفرق الذي يغير الحكم، رفع السؤال، توجيه الحساب، استخدام الأدوات والذاكرة ضمن تفويض، اختبار الاستنتاج، ثم تحويل النجاح المتكرر إلى HyperSkill. لكن الورقة تخفض ادعاء AGI إلى برنامج بحث: لا يصبح المشروع قريبًا من الذكاء العام إلا إذا أثبت انتقالًا مستمرًا إلى مهام جديدة وتعلمًا من الأثر وتعافيًا من الفشل، لا بمجرد إنتاج نص عميق أو جمع عدد كبير من المهارات.

الملخص

تقترح هذه الورقة إطارًا تأسيسيًا لهندسة MOUSSAIF9B بوصفه مشروعًا معماريًا موجّهًا نحو الذكاء العام، مع تمييز ملزم بين مستويين: MOUSSAIF9B-1B، وهو النموذج التجريبي الفعلي الذي قد يقع في نطاق مليار معلمة تقريبًا؛ وMOUSSAIF9B-9B، وهو النموذج المستهدف الذي يصبح الاسم فيه وصفيًا للحجم بعد تحقق التدريب الفعلي. تنطلق الورقة من أن عدد المعلمات مورد ضروري لكنه غير كافٍ، وأن الذكاء القابل للاستعمال ينتج من رافعة مركبة تشمل جودة البيانات، هندسة المنهج، التخصص اللغوي، التدريب على الاستدلال، التحقق، استعمال الأدوات، الذاكرة غير المعلمية، التخصيص الوعائي للحساب، والقدرة على التعافي من الفشل.

تُهندس المادة الخام المكوّنة من مئتي برنامج تدريبي - مئة قبل التدريب ومئة بعده - داخل خط تشغيل موحد يربط MCD لاستخراج الفروق، وQ-MCD لتوليد السؤال الحاكمي، وHAKIM-MCD للانتقال من الفرق إلى الحكم والفعل، وMICAGFI لدمج المعرفة والذاكرة والأداة والأثر، وHyperSkills لتبلور المهارات، وBounded HyperLoops للتحسين العودي المحدود، وKB-as-OS لتوسيع النموذج بذاكرة منظمة قابلة للتحديث. وتقترح الورقة معماريتين مرجعيتين: نموذجًا كثيفًا يقارب 1B بأبعاد 1792 و24 طبقة، ونموذجًا يقارب 9B بأبعاد 4608 و32 طبقة، مع GQA وSwiGLU وRMSNorm وRoPE وسياق متدرج، على أن تُعامل هذه الأرقام كفرضيات هندسية أولية تُحسم بالتجارب الاستطلاعية وقوانين القياس الخاصة بالبيانات والحساب.

تولّد الورقة ست نظريات جديدة: نظرية الرافعة المعرفية للمعلمة، نظرية عرض نطاق الفرق الحاكمي، نظرية الوعائية الحسابية متعددة المديات، نظرية تبلور المهارة المحكوم بالهدم، نظرية الذاكرة المزدوجة ذات النزاهة، ونظرية الوكالة العودية المحدودة بأثر العالم. كما تقدم سبعة مقاييس، وثماني عشرة فرضية، وتسعة تنبؤات فارقة، وبروتوكولًا تجريبيًا للانتقال من 1B إلى 9B، ومحكمة هدم تكشف أن المشروع لا يجوز أن يدّعي AGI قبل إظهار انتقال معتبر خارج التوزيع، وتعلم من الأثر، وقدرة مستقرة على الاستدلال والأداة والذاكرة تحت اضطراب مركب. النتيجة ليست إعلان نموذج AGI مكتمل، بل برنامج هندسي-بحثي قابل للاختبار يبني ذكاءً أكثر كثافة ومرونة لكل معلمة ولكل وحدة حساب.

الكلمات المفتاحية

MOUSSAIF9B؛ AGI-oriented models؛ Small Language Models؛ 1B، 9B؛ MCD؛ Q-MCD؛ HAKIM-MCD؛ MICAGFI؛ HyperSkills؛ HyperLoops؛ KB-as-OS؛ Process Supervision؛ Verifier-Guided Training؛ Resilience.

1. الإعلان المنهجي ومراتب المعرفة

لن تخلط هذه الورقة بين الحقيقة والفرضية، ولا بين النموذج والدليل، ولا بين الإبداع والإثبات، ولا بين الاستعارة والآلية، ولا بين قوة اللغة وقوة البرهان. ما يرد عن بنية Transformer، وقوانين القياس التجريبية، وأثر التنقية وإزالة التكرار، وفاعلية بعض أساليب ما بعد التدريب، مستند إلى أعمال منشورة. أما MCD وQ-MCD وHAKIM-MCD وMICAGFI والنظريات الست المقترحة فهي أطر هندسية ناشئة من برنامج زهير مساعف؛ تُعرض هنا كتركيبات نظرية وأدوات تصميم لا كحقائق علمية مثبتة.

يُستعمل سلم من ست مراتب: (أ) مدعوم تجريبيًا في الأدبيات؛ (ب) راجح هندسيًا لكنه حساس للميزانية والبيانات؛ (ج) تركيب نظري جديد؛ (د) فرضية قابلة للاختبار؛ (هـ) أداة تحليلية أو مقياس أولي؛ (و) أفق بحثي تخميني. ومن ثم فإن اسم MOUSSAIF9B لا يثبت حجمًا ولا ذكاءً: إذا كان النموذج الفعلي في نطاق 1B بقي الاسم علامة المشروع، ويجب أن تُذكر المعلمات الحقيقية في كل بطاقة نموذج وتقرير تقييم.

المادة الأصلية المتاحة هي القائمة المئوية المزدوجة وخط التدريب الحاكمي والمفاهيم المؤسسة الواردة في الطلب. لم تُنفذ الورقة تدريبًا فعليًا، ولم تطلع على سجلات تجارب خاصة بالمشروع؛ لذلك فإن الأرقام المقترحة للمعمارية والرموز والخلطات هي نقطة انطلاق تجريبية تحتاج إلى ablation studies، وليست وصفًا لنموذج موجود أو نتيجة تحقق ميداني.

2. الوضع الأنطولوجي ونوع السؤال

MOUSSAIF9B ليس «شيئًا» واحدًا، بل نظام تطوير متعدد الطبقات: نموذج أوزان، دستور بيانات، منهج تدريب، طبقة تحقق، بيئة أدوات، ذاكرة خارجية، ونظام حوكمة إصدار. ولذلك فالوضع الأنطولوجي الأدق هو «عملية شبكية تطورية ذات مكونات معلمية وغير معلمية». اعتبار المشروع مجرد checkpoint يقتل ديناميته؛ واعتباره AGI مكتملًا يخلط الغاية بالحالة الراهنة.

السؤال الرئيس معماري-إبستمولوجي-قياسي: كيف يمكن بناء نموذج في نطاق 1B ثم 9B يحقق أكبر كثافة ممكنة من الاستدلال والمرونة والثقة لكل معلمة ووحدة حساب، من دون أن تتحول المقاييس إلى تضخم تسويقي؟ ويتفرع عنه سؤال سببي حول أثر البيانات والتدريب، وسؤال بنيوي حول توزيع الحساب والذاكرة، وسؤال نقدي حول حدود مقاييس الذكاء، وسؤال عملي حول مسار التنفيذ التدريجي.

يترتب على هذا التصنيف أن الورقة لا تبحث عن وصفة واحدة، بل عن بنية تفصل بين: القدرة المخزنة في الأوزان، والقدرة المسترجعة من KB، والقدرة المنتجة بالتفكير وقت الاختبار، والقدرة المنفذة عبر الأدوات، والقدرة المصححة بواسطة verifier، والقدرة المتراكمة عبر الذاكرة. ويصبح معيار التقدم هو تحسن المتجه الكلي تحت اضطرابات وتكاليف محددة، لا ارتفاع رقم منفرد.

3. مشكلة البحث والفجوة المركزية

تواجه مشاريع النماذج الصغيرة والمتوسطة مفارقة مزدوجة. الأولى أن تضخيم الحجم مكلف، بينما الاقتصار على نموذج صغير قد يحبس المشروع في سقف معرفي واستدلالي. والثانية أن benchmark gains يمكن أن تنتج من التلوث، أو اختلاف prompts، أو زيادة sampling، أو انحياز judge، من دون زيادة مماثلة في القدرة العامة. أظهرت قوانين القياس أن الأداء يرتبط بالحجم والبيانات والحساب [1،2]، ثم بينت أعمال لاحقة أن احتساب تكلفة الاستدلال قد يبرر تدريب نماذج أصغر مدة أطول [3]. كما قدمت TinyLlama وSmolLM2 وPhi-3 قرائن على أن البيانات عالية الجودة والوصفات الكثيفة تستطيع رفع النماذج الصغيرة فوق توقعات الحجم الخام [4-6].

لكن الأدبيات لا تمنح وصفة جاهزة لمشروع عربي-إنجليزي-فرنسي يجمع reasoning وtool use وKB-as-OS ومحاكم الهدم. الفجوة التي تستهدفها الورقة هي غياب إطار يربط ثلاثة أنواع من الكفاءة: كفاءة المعلمة Parameter Efficiency، وكفاءة الحكم Epistemic Efficiency، وكفاءة الوكالة Agentic Efficiency. أغلب الوصفات تحسن أحدها: نموذج أصغر، أو reasoning RL، أو RAG، أو function calling؛ أما MOUSSAIF9B فيحتاج إلى حاكمية تنسقها وتمنع تضخم كل طبقة على حساب الأخرى.

تُصاغ الفجوة كالتالي: لا يوجد بعدُ دليل على أن إضافة traces أو أدوات أو ذاكرة تكفي لصنع ذكاء عام، لكنها قد تصنع رافعة قوية إذا كانت محكومة بتقدير الصعوبة، وتحقق مستقل، وحدود توقف، وقياس انتقال خارج التوزيع. ومن هنا تتحول المئتا برنامج من قائمة محتوى إلى «منهج تغطية سببية»: كل برنامج يجب أن يصرح بأي قدرة يستهدفها، وما الاختبار الذي يفصل التعلم الحقيقي عن الحفظ أو التحايل.

4. الخلفية العلمية: من القياس إلى النماذج العملية

اقترحت أعمال scaling laws أن خسارة النماذج تتبع علاقات قوى تقريبية مع عدد المعلمات والبيانات والحساب [1]. وصححت دراسة Chinchilla اتجاهًا كان يميل إلى نماذج ضخمة ناقصة التدريب، مبرزةً ضرورة توسيع البيانات بالتوازي مع الحجم [2]. ومع الاستخدام واسع النطاق، أظهر تحليل inference-aware scaling أن النموذج الأصغر المدرب على tokens أكثر قد يكون أمثل اقتصاديًا عندما تتكرر الاستدعاءات [3]. هذا مهم لمسار MOUSSAIF9B: نموذج 1B ليس مجرد نسخة ناقصة؛ يمكن أن يكون مختبرًا عالي التكرار ومكوّن edge، بينما 9B هو طبقة أوسع للتركيب والاستدلال.

تقدم TinyLlama مثالًا 1.1B دُرّب على قرابة تريليون token [4]، ويوثق SmolLM2 تطوير نموذج 1.7B بمنهج data-centric [5]، بينما يوضح Phi-3 أن التنقية المكثفة والبيانات الاصطناعية المراقبة قد تنتج أداءً مرتفعًا في 3.8B [6]. وفي نطاق قريب من الهدف، تقدم Gemma 2 وصفات 9B مع local-global attention وGQA [7]، وتقدم Qwen3 سلسلة من 0.6B إلى 235B ومسار ما بعد تدريب يجمع long-CoT وreasoning RL ودمج نمطي التفكير [8]. كما تُظهر Llama 3 أهمية خلطات ضخمة متعددة اللغات وتدريب الأدوات والسلامة [9].

في البيانات، توضح FineWeb وFineWeb-Edu أثر التنقية والفلترة التعليمية [10]، وتقدم Dolma corpus مفتوحًا موثقًا بثلاثة تريليونات token [11]، بينما يجعل DataComp-LM اختيار البيانات نفسه موضوعًا تجريبيًا ويبرز قوة model-based filtering [12]. وتبين إزالة التكرار أنها تقلل الحفظ الحرفي وتحسن الكفاءة والتقييم [13]. هذه النتائج تدعم مبدأ MOUSSAIF: لا تُقاس قيمة corpus بالحجم فقط، بل بالمساهمة الحدية في قدرة قابلة للاختبار.

في ما بعد التدريب، يوفر DPO طريقة أبسط لتحسين التفضيلات من RLHF التقليدي [14]، ويبرهن process supervision على قيمة التقييم المرحلي في الرياضيات [15]. وتعرض STaR آلية bootstrap لمسارات reasoning الناجحة [16]، بينما يُظهر DeepSeek-R1 إمكان تحفيز reasoning عبر RL ومكافآت قابلة للتحقق، مع بقاء مشكلات كالإطالة وعدم الاستقرار [17]. وفي الوكالة، يربط ReAct التفكير بالفعل [18]، ويُعلّم Toolformer النموذج اختيار APIs واستخدامها [19]. أما RETRO فيوضح أن الذاكرة غير المعلمية قد تعوض جزءًا من الحجم المعلمي [20].

5. النسب العربي والمتعدد اللغات

بما أن المشروع يستهدف العربية العلمية مع الإنجليزية والفرنسية، فلا يكفي إضافة نسبة من النص العربي إلى corpus إنجليزي. العربية ذات صرف غني، والتجزئة السيئة ترفع طول السلاسل وتضعف تمثيل الجذور والأوزان، كما أن المزج غير المنضبط بين الفصحى والتراث واللهجات قد ينتج قدرة سطحية. تقدم Jais نموذجًا عربيًا-إنجليزيًا مبنيًا على خلط لغوي وكود [21]، ويعرض AceGPT مسار continued pretraining ثم SFT وRLAIF محلي الثقافة [22]، فيما يناقش ALLaM الاختيار بين التدريب من الصفر والاستمرار من نموذج سابق [23].

القرار المقترح لـ MOUSSAIF9B هو tokenizer ثلاثي المحاور بحجم أولي 64K، يُقاس لا بالشعور اللغوي بل بمؤشرات fragmentation عبر العربية الكلاسيكية والحديثة واللهجات، والفرنسية التقنية، والإنجليزية العلمية والكود. ينبغي ألا تتجاوز العربية متوسطًا يضاعف تكلفة الإنجليزية بصورة غير مبررة، وأن تُحفظ المصطلحات التقنية والرموز الرياضية وأسماء APIs. ويجب إجراء tokenizer ablation قبل أي تدريب كبير: 80K، 64K، 48K مع مقارنة ضغط السلاسل، والتعميم الصرفي، وكلفة embedding.

يقترح المنهج خلطًا غير ثابت: تبدأ مرحلة الأساس بقاعدة عالمية عالية الجودة، ثم ترتفع العربية في مراحل موجهة للمورفولوجيا والمنطق والعلوم والكتابة البحثية، مع parallel conceptual tasks تضمن أن الاستدلال لا ينهار عند تبديل اللغة. كما تُفصل بيانات الترجمة إلى: ترجمة موثقة، وبيانات مولدة تحتاج تحققًا، ونصوص أصلية تُعطى وزنًا أعلى في الأسلوب والثقافة. معيار النجاح ليس fluency فقط، بل ثبات الاستدلال، ودقة المصطلح، والقدرة على الانتقال بين لغة السؤال ولغة المصدر والأداة.

6. هوية المشروع: MOUSSAIF9B-1B وMOUSSAIF9B-9B

يقترح البحث نظام تسمية يمنع الالتباس. «MOUSSAIF9B» هو الاسم المرجعي للبرنامج المعماري؛ و«MOUSSAIF9B-1B-v0.x» هو مسار النماذج التجريبية الفعلية؛ و«MOUSSAIF9B-9B-v1.x» لا يُستخدم إلا بعد تحقق عدد معلمات يقارب تسعة مليارات. ويجب أن تذكر بطاقة كل إصدار: active parameters، exact parameter count إن كان MoE، عدد context، cutoff، tokens، training stages، languages، window، ونتائج الاختبارات مع عدم اليقين.

وظيفة 1B ثلاثية: أولًا اختبار corpus والtokenizer والloss spikes والخلطات بسرعة؛ ثانيًا إنتاج نموذج edge متخصص في routing وtool schemas وretrieval؛ ثالثًا بناء teacher-student loop حيث يستقبل خبرات من نماذج أقوى ويُرجع failure data

قابلة للتحليل. أما 9B فوظيفته دمج مجال أوسع من المعرفة، ورفع القدرة على compositional reasoning، وتحمل سياق أطول، وتنفيذ HyperSkills أكثر تعقيدًا دون اعتماد دائم على teacher خارجي.

لا ينبغي أن يكون الانتقال 1B→9B مجرد ضرب للأبعاد. كل قرار في 1B يُصنف إلى: قرار صالح للتوسيع، قرار خاص بصغر النموذج، قرار غير محسوم، قرار فشل. مثال ذلك: كثافة البيانات التعليمية قد تنفع الحجمين، لكن نسبة synthetic traces المثلى قد تختلف؛ والـGQA قد يكون مهمًا لكليهما، لكن long-context curriculum يتطلب ميزانية مختلفة. بناء سجل هذه الاختلافات هو نفسه مكوّن من مكونات KB-as-OS.

7. المعمارية المرجعية متعددة المقاييس

تعتمد المعمارية الأساسية Transformer كثيفًا لأن المقارنة والعزل السببي أسهل من بدء المشروع بـMoE معقّد. يُستخدم pre-norm مع RMSNorm، وSwiGLU، وrotary embeddings، وGQA لتقليل KV cache مع المحافظة على جودة قريبة من multi-head attention، وقد قدمت دراسة GQA هذا التوازن نظريًا وتجريبيًا [24]. يمكن استعمال FlashAttention في التنفيذ، لكن الورقة تميز بين مكوّن معماري ومكتبة تسريع.

التقدير التقريبي للمعلمات يستعمل: embeddings + L × (attention + MLP + norms). مع GQA، تنخفض معلمات K/V مقارنة بـMHA. التكوين 1792/24/4864 مع vocab 64K يقارب 0.92B، والتكوين 4608/32/16128 مع 36 query heads و6 KV heads يقارب 9.02B، مع اختلافات طفيفة حسب tying وbiases. يجب ألا تُعامل هذه المطابقة الحسابية كبرهان على الأمثلية؛ تبدأ التجارب بعائلة 300M/600M/1B لاستخراج scaling curves محلية قبل تثبيت 9B.

يُفصل السياق إلى ثلاثة مفاهيم: window معلن، effective context مستعمل، وstate memory محفوظ. تمديد RoPE عبر YaRN أو مناهج مشابهة يمكن أن يرفع النافذة بكلفة أقل [25]، وLongLoRA يوضح إمكان fine-tuning طويل السياق بكفاءة [26]، لكن النجاح في needle retrieval لا يثبت فهم الوثائق. لذلك يحتاج MOUSSAIF9B إلى curriculum dependencies، وstate reconstruction، واختبارات تسلسل زمني وتناقضات، لا إلى رفع الرقم فقط.

العنصر	MOUSSAIF9B-1B التجريبي	MOUSSAIF9B-9B المستهدف	الرتبة المعرفية
البنية	Decoder-only dense Transformer	Decoder-only dense؛ MoE خيار بحثي لاحق	اقتراح هندسي
الأبعاد d_model	1792	4608	فرضية قابلة للـablation
الطبقات	24	32	فرضية قابلة للـablation
رؤوس الاستعلام	14 × 128	36 × 128	اقتراح
رؤوس KV	2	6	اقتراح GQA
FFN/SwiGLU	4864	16128	تقريب يقود إلى ~0.92B و~9.02B
المفردات	64K مشتركة	64K أو 80K بعد الاختبار	قرار تجريبي
السياق الأساسي	8K ثم 32K	32K ثم 128K	مسار مرحلي
التطبيع/الموضع	RMSNorm + RoPE	RMSNorm + RoPE/YaRN extension	ممارسات مدعومة
الذاكرة الخارجية	KB-as-OS إلزامية	KB-as-OS + specialist stores	جزء من المعمارية الكلية

8. دستور البيانات: من corpus إلى حجة تدريبية

دستور البيانات هو القانون الأعلى الذي يمنع تحويل الإنترنت إلى معرفة متساوية. لكل وثيقة تمثيل metadata يتضمن المصدر، الزمن، اللغة، الترخيص، نوع الخطاب، احتمال السمية، الثقة، كثافة المعرفة، قابلية التحقق، التشابه، والقدرات المستهدفة. وتقترح الورقة قيمة بيانات أولية:

$$DV(x)=Q(x)\cdot N(x)\cdot T(x)\cdot V(x)\cdot L(x) \;/\; [1+R(x)+D(x)+C(x)]$$

حيث Q الجودة، N الجدة، T قابلية النقل، V قابلية التحقق، L ملاءمة المنهج، R المخاطر، D التكرار، C احتمال التلوث. الصيغة أداة ترتيب لا قياس فيزيائي؛ تُعاير بتدريب proxy models واختبار المساهمة الحدية لكل bucket.

الخلطة المقترحة لا تُنفذ مرة واحدة. تُبنى raw lake، ثم exact/near، language identification، normalization، benchmark firewall، safety/legal filtering، quality filtering، deduplication، ثم domain tagging. بعد ذلك تُجرى تجارب صغيرة على خلطات متنافسة. تؤيد FineWeb-Edu أثر النص التعليمي [10]، وتبين DataComp-LM أن model-based filtering قد يكون أقوى من heuristics وحدها [12]، بينما تدعم أعمال إزالة التكرار خفض الحفظ وتحسين التدريب [13].

تُعامل البيانات الاصطناعية كـ«مشتق معرفي» لا مصدر أصلي. كل synthetic item يحمل verifier، generator، parent sources، difficulty، execution result، وconfidence. لا يدخل math/code/factual synthetic data دون أداة أو مصدر أو consensus متعدد. ويُمنع recursive collapse عبر نسبة قصوى لكل generator family، وholdouts بشرية، وقياس اختلاف التوزيع اللغوي والأسلوبي.

9. تحويل المئة برنامج قبل التدريب إلى عشر طبقات

المئة برنامج قبل التدريب لا تُنفذ كـ100 jobs منفصلة، بل كعشر طبقات متداخلة. طبقة الأساس المعرفي تبني causal definitions، source conflict، maps، والتسلسل التاريخي. طبقة اللغة تبني العربية العميقة والتعدد اللغوي وحفظ المصطلح. طبقة العلوم تفرض البرهان والوحدات وعدم اليقين. طبقة الهندسة تنتقل من snippets إلى repositories وADRs. طبقة الاستدلال تغطي deduction وinduction وabduction وcounterfactuals. طبقة السياق تبني dependency retrieval وcompression. طبقة world models تدرب planning والتنبؤ بالأثر. طبقة النزاهة تفصل fact/inference/hypothesis. طبقة الوكالة تدرب tool schemas والفشل والتكلفة. والطبقة الأصلية لـMoussaif تدرب استخراج الفرق والسؤال الحاكمي والتوجيه الوعائي والـHyperSkills.

يُعاد تمثيل كل برنامج ببطاقة من ستة حقول: القدرة، المتطلب السابق، نوع البيانات، objective auxiliary إن وجد، benchmark، وفشل متوقع. مثال: Mathematical Error Corpus لا يساوي مسائل خاطئة فقط؛ بل pairs تحدد موضع الخطأ ونوعه وإصلاحه، ويقاس أثرها على error localization لا accuracy النهائي وحده. وContext Conflict Resolution لا يُقاس بالاسترجاع، بل بقدرة النموذج على ترتيب تعليمات متعارضة وفق الحاكمية والزمن والمصدر.

يُستخدم curriculum scheduler يعتمد على frontier learning: إذا ارتفعت دقة bucket وانخفضت قيمة gradient أو التحسن، يقل وزنه؛ وإذا ظهرت فجوة ذات انتقال مرتفع، يزيد وزنها. لكن لا يُترك scheduler حرًا بالكامل، لأن القدرات النادرة كالسلامة العربية أو formal proof قد تختفي تحت وفرة web text. لذلك توجد floors دستورية لكل مجال.

10. مصفوفة طبقات Pretraining

تلخص المصفوفة وظيفة كل عشرية من البرامج، بينما يُحفظ سجل البرامج الفردية في ملحق قاعدة المعرفة.

المدى	الطبقة	الوظيفة الحاكمة	بوابة القياس
A 1-10	الأساس المعرفي العام	معرفة موثقة، تعريفات، سببية، خرائط تعارض	Knowledge/causal holdouts
B 11-20	اللغة والتعدد الثقافي	العربية العميقة، الإنجليزية العلمية، الفرنسية التقنية، alignment	Arabic/French transfer suite
C 21-30	الرياضيات والعلوم	برهان، رموز، وحدات، تجربة، عدم يقين، تفنيد	MATH/GPQA + private variants
D 31-40	البرمجة والهندسة	repos، bugs، tests، systems، security، IaC، ADRs	HumanEval/SWE-style private
E 41-50	الاستدلال العام	deduction/induction/ abduction/analogy/ counterfactual	procedural reasoning
F 51-60	السياق والذاكرة	long context، dependencies، conflict، compression، state	long-context dependency suite
G 61-70	نماذج العالم والتخطيط	physical/social/economic، simulation، replanning، effect	interactive environments
H 71-80	الموثوقية المعرفية	source reliability، calibration، abstention، provenance	factuality/calibration
I 81-90	الوكالة والأدوات	schemas، search، retrieval، code، browser، budget، approval	tool-use sandbox
J 91-100	Moussaif-native	MCD، Q-MCD، HAKIM، ROFSC، HyperSkills، MICAGFI	sovereign difference suite

11. مراحل ما قبل التدريب المقترحة

المرحلة P0 هي تجارب القياس: 50M-300M parameters على 30B tokens-5 لاختبار data buckets، schedules، tokenizer، وloss stability. المرحلة P1 تبني 1B على 300B token-100 كـresearch MVP، الغرض اكتشاف الأخطاء البنيوية لا المنافسة العامة. المرحلة P2 ترفع 1B إلى 1.5T token-0.8 عالية الجودة إذا سمحت الميزانية، لأن النماذج الصغيرة تستفيد من التدريب الطويل ويجري استعمالها بكثافة. المرحلة P3 تبني 9B على 5T token-2 وفق نتائج scaling المحلية، مع checkpoints مرحلية وdata ablations.

داخل كل مرحلة يتدرج طول السياق: أغلب التدريب على تسلسلات قصيرة-متوسطة لكفاءة الحساب، ثم نسبة متزايدة من 8K/16K/32K، ثم continued pretraining مخصص للlong context. ويُراعى packing حتى لا تتسرب الوثائق أو تتداخل

boundaries. ويجب إنشاء data curriculum by capability لا by source فقط: يمكن أن يظهر math في الكتب والويب والكود، لكن tag الهدف يسمح بقياس أثره.

اقتراح النسب 40/15/15/10/10/10 الوارد في المادة الخام يصلح كـprior، لكنه لا يُثبت. تُحول النسب إلى نطاقات: المعرفة واللغة 35-50%، الرياضيات والاستدلال 12-20%، الكود والأنظمة 12-20%، السياق والذاكرة 5-12%، الوكالة والأدوات 5-12%، Moussaif-native 5-12%. كل نطاق يُحسم بواسطة proxy scaling، لا بمساواة النسب بالجودة.

12. تحويل المئة برنامج بعد التدريب إلى عشر دوائر

ما بعد التدريب ليس مرحلة تجميل محادثة، بل تحويل القدرة الكامنة إلى سياسة عمل. الدائرة الأولى تضبط اتباع التعليمات والقيود. الثانية تدرب reasoning والحكم. الثالثة تبني function calling والagents. الرابعة تحافظ على state والذاكرة. الخامسة تنتج البحث العلمي. السادسة تصلح repositories والنشر. السابعة تفصل الناقد عن الكاتب وتدرب self-revision. الثامنة تفرض safety وauthorization. التاسعة تحافظ على التفكير متعدد اللغات. والعاشرة تدمج MCD وQ-MCD وHAKIM وWorld-Effect.

لكل مثال post-training ينبغي فصل أربعة labels: صحة المهمة، جودة العملية، سياسة الأداة، وأسلوب الإخراج. خلطها في preference واحدة يسمح للـjudge بتفضيل البلاغة على الصحة. لذلك يقترح MOUSSAIF9B multi-head evaluation أو multi-axis labels ثم يدمجها حسب risk profile. كما تُدرج negative examples التي تبدو مقنعة لكنها تخالف قيدًا، أو تستعمل مصدرًا غير داعم، أو تستدعي أداة بلا حاجة.

الترتيب المقترح: SFT أساسي، RLVR، preference optimization، process verifier، tool trajectories، reasoning SFT في المجالات القابلة للتحقق، safety red teaming، ثم distillation. يمكن دمج المراحل أو تكرارها، لكن يجب الاحتفاظ checkpoints وablation gates حتى لا يُنسب التحسن إلى السبب الخطأ.

13. مصفوفة طبقات Post-training

تربط المصفوفة كل عشرية بقدرة قابلة للقياس وتمنع اختزال post-training في تفضيلات الحوار.

بوابة القياس	الوظيفة الحاكمة	الدائرة	المدى
constraint compliance	اتباع القيود، الغموض، التحكم بالكثافة، schemas	Instruction tuning	K 101-110
reasoning + calibration	process/outcome verification، depth routing، calibration	الاستدلال والحكم	L 111-120
tool execution	function calling، delegation، arbitration، budgets	الأدوات والوكلاء	M 121-130
stateful tasks	state، preference memory، conflicts، reconstruction	السياق والذاكرة	N 131-140
research benchmark	questions، gaps، hypotheses، methods، citations، theory	البحث العلمي	O 141-150
SWE-style sandbox	repo repair، tests، deployment، observability، security	البرمجة والنشر	P 151-160
revision deltas	critique، rubric، taxonomy،	النقد والتحسين	Q 161-170

		completeness، frozen authority	
R 171-180	السلامة والتفويض	constitution، privacy، injection، misuse، escalation	red-team matrix
S 181-190	التواصل متعدد اللغات	Arabic reasoning، scientific writing، audience adaptation	cross-lingual invariance
T 191-200	Moussaif capstone	sovereign difference، question elevation، hyperloops، world effect	integrated missions

14. هندسة التفكير: متى يفكر النموذج؟

النموذج المفكر ليس النموذج الذي يطيل chain-of-thought دائمًا. المطلوب policy لتقدير الصعوبة ثم تخصيص budget. تقترح الورقة خمس درجات: R0 جواب مباشر قابل للتحقق؛ R1 تفكيك قصير؛ R2 reasoning متعدد الخطوات مع أداة؛ R3 عدة مسارات ومحكمة هدم؛ R4 تصعيد عالي المخاطر مع مصادر مستقلة أو إنسان. يُدرّب classifier أو head مشترك على اختيار أقل درجة تحقق نجاحًا موثوقًا.

يستفيد MOUSSAIF9B من STaR في bootstrap لمسارات صحيحة [16]، ومن process supervision في تقييم الخطوات [15]، ومن RLVR في المجالات ذات verifier صلب [17]. لكنه يرفض افتراض أن trace أطول أكثر صدقًا. يُقاس overthinking عبر token marginal utility: إذا لم تزد احتمالية الصحة أو خفضت consistency، تُفرض عقوبة أو stop signal. ويُفصل hidden deliberation عن rationale المعروض؛ فالتفسير الظاهر واجهة قابلة للاختبار وليس نافذة مضمونة على الآلية الداخلية.

في 1B، تكون البنية المفضلة «decompositions: reasoning scaffolded منظمة، أدوات حساب وكود، retrieval، وtemplates محدودة. في 9B، يمكن توسيع search diversity وlatent planning. ومع ذلك يظل verifier الخارجي أقوى من الثقة الذاتية المطلقة. الهدف أن يتعلم النموذج السؤال: هل أملك دليلًا؟ هل الأداة لازمة؟ ما الاعتراض الأقوى؟ هل تغيّر الاستنتاج بعد الاختبار؟

15. منظومة التحقق ومحكمة الهدم

تتكون منظومة التحقق من محقق إجابة exact/unit tests، محقق رمزي، محقق factual retrieval، محقق citation entailment، كاشف تناقض، محقق policy/authorization، ومقيم أسلوب مستقل. لا يُسمح لـjudge لغوي واحد بإنتاج reward شامل، لأن الأسلوب قد يطغى على الصحة. عند اختلاف المحققين، لا يُؤخذ المتوسط تلقائيًا؛ يُصنف الخلاف ويُحال إلى data queue أو human audit.

محكمة الهدم هي تحويل الاعتراض إلى إجراء تدريبي. لكل حل عالي القيمة تُنتج: فرضية بديلة، boundary case، counterexample، adversarial paraphrase، hidden assumption، واختبار أداة. النتيجة واحدة من أربعة: قبول، تعديل، امتناع، أو طلب دليل. وتُخزن القضايا في Falsification Corpus مع سبب النجاة أو السقوط.

تُستخدم المحكمة أيضًا ضد المشروع نفسه. إذا ارتفع benchmark بعد إضافة محكمة الهدم، يجب اختبار ما إذا كان الارتفاع بسبب زيادة tokens في وقت الاختبار أو بسبب تعلم انتقال حقيقي. لذلك تقارن التجارب budgets متساوية، وتستعمل procedural holdouts، وتفصل generator عن verifier قدر الإمكان. معيار المحكمة ليس كثرة النقد، بل قدرتها على اكتشاف أخطاء كانت ستعبر إلى الفعل.

16. الأدوات والوكالة: من النص إلى الفعل

يدمج MOUSSAIF9B نمط ReAct حيث تتناوب reasoning وaction وobservation [18]، ويستفيد من Toolformer في تعلم توقيت الاستدعاء وصيغته [19]. لكن البيئة المقترحة تضيف طبقة حاكمية: كل أداة تحمل schema، permissions، cost، expected evidence، timeout، risk، reversibility، وfallback. قبل الاستدعاء يحدد النموذج لماذا الأداة لازمة وما الذي سيُعد نجاحًا.

تُبنى trajectories من مهام حقيقية داخل sandbox: البحث وفتح المصدر، تشغيل كود، فحص tests، تعديل ملف، query قاعدة بيانات، أو استرجاع KB. وتُدرج أعطال مقصودة: malformed JSON، نتائج قديمة، tool injection، timeout، ونتيجة صحيحة شكليًا خاطئة موضوعيًا. النجاح الكامل يتطلب اكتشاف العطل وحفظ state واختيار بديل.

في 1B، يمكن أن يكون النموذج router/executor متخصصًا، بينما تُسند المسائل المعقدة إلى model أعلى أو verifier. وفي 9B، يزداد نطاق التخطيط، لكن authority لا يرتفع تلقائيًا مع الذكاء. توضع حدود بشرية للإرسال، النشر، الإنفاق، تغيير الأنظمة، والقرارات عالية الأثر. الوكالة القوية هي وكالة تعرف حدودها وتبقي الأفعال قابلة للتراجع.

17. السياق والذاكرة وKB-as-OS

يفصل المشروع بين ثلاثة مخازن: الذاكرة المعلمية في الأوزان، ذاكرة السياق المؤقتة، وKB-as-OS خارجية قابلة للتحديث. توضح RETRO أن retrieval يمكن أن يرفع القدرة المعرفية بمعلمات أقل [20]، لكن الاسترجاع قد يفشل أو يعيد نصًا مضللًا. لذلك لا تُعامل KB كملحق نصي، بل كنظام كيانات وعلاقات ومصادر وثقة وإصدارات وقواعد تعارض.

تُبنى KB على وحدات: مفهوم، تعريف، ادعاء، دليل، نظرية، اعتراض، أداة، HyperLoop، HyperSkill، تجربة، وقرار إصدار. كل memory write يمر expiration، scope، confidence، provenance، relevance، وconflict checks. ويُمنع أن تكتب الأداة الخارجية قواعد حاكمية داخل الذاكرة. عند ضغط السياق، ينتج Task State Capsule يحفظ الهدف، القيود، القرارات، الأدلة، unresolved issues، والخطوة التالية.

HyperSkill هو سياسة قابلة لإعادة الاستخدام نشأت من حلول متعددة ونجت من اختبارات. HyperLoop هو تكرار محدود يملك state وbudget وstop conditions. القيمة ليست في عدد الملفات؛ 70 مهارة/حلقة لا تعني ذكاءً إن كانت متكررة أو غير قابلة للقياس. لذلك يقاس failure rate، transfer، skill reuse، وcost. ويُسقط skill إذا لم يتفوق على prompt أو tool بسيط.

18. MCD وQ-MCD وHAKIM-MCD وMICAGFI

يُعاد تعريف MCD هنا كدالة تصميم تقديرية لا كمقياس علمي نهائي:

$$MCD = \lambda 1D + \lambda 2I + \lambda 3T + \lambda 4A + \lambda 5P + \lambda 6C - \lambda 7N$$

D كثافة الفروق المفيدة؛ I دمج المستويات بلا خلط؛ T فهم التحولات؛ A الحاكمية والوكالة؛ P التنبؤ والاختبار؛ C الضغط وإعادة التوليد؛ N الضجيج والادعاء الزائد. تُقدر المكونات عبر rubrics وbenchmarks، ولا تُجمع في رقم تسويقي قبل تحقق reliability.

Q-MCD يضيف قيمة السؤال: ليست جودة reasoning مستقلة عن السؤال الذي يحدد فضاء البحث. يُدرب النموذج على توليد «السؤال الأعلى» الذي يفصل بين نماذج أو يكشف متغيرًا مفقودًا، ثم يقاس question utility بمقدار خفض عدم اليقين أو عدد المسارات

المرفوضة. HAKIM-MCD يحول ذلك إلى pipeline: فرق → تقييم → routing → paths → falsification → tool → action → world effect → memory.

MICAGFI هو الغلاف الميتا-معماري الذي ينسق المعرفة والحكم والسؤال والأداة والذاكرة والفعل وإعادة البناء. الادعاء المحافظ هو أنه orchestration framework، الادعاء الجريء أنه قد يكون نواة AGI. الورقة تخفض الثاني إلى فرضية بعيدة: لا يصبح الإطار دليلًا على AGI إلا إذا ولّد انتقالًا مستمرًا إلى مهام جديدة، وتعلمًا من الأثر، وحكمًا متزنًا تحت اختلاف السياق والأدوات.

19. تحليل المجال في 26 نقطة مؤسسة

1. تحديد موضوع المشروع. الموضوع ليس تدريب LLM فقط، بل بناء نظام ذكاء موزع بين الأوزان والذاكرة والأدوات والتحقق. الاختبار المقترح: اختبار كل مكوّن منفردًا ثم تركيبيًا.

2. الفرق بين الاسم والحجم. MOUSSAIF9B اسم معماري حتى يثبت الحجم الفعلي. الاختبار المقترح: تدقيق آلي لبطاقات النماذج يمنع الادعاء المضلل.

3. المعلمة ليست وحدة ذكاء. المعلمة سعة تمثيل؛ فائدتها تعتمد على البيانات والتنظيم. الاختبار المقترح: مقارنة نماذج متساوية الحجم بخلطات مختلفة.

4. البيانات ليست **tokens** متساوية. token تعليمي موثوق قد يفوق آلاف tokens منخفضة القيمة. الاختبار المقترح: قياس contribution عبر proxy ablations.

5. السؤال جزء من الحوسبة. السؤال الجيد يقلص فضاء البحث قبل توليد الجواب. الاختبار المقترح: مقارنة answer-only مع question-elevation.

6. الفرق الحاكمي وحدة قرار. ليست كل الفروق متساوية؛ بعضها يغير الحكم أو المسار. الاختبار المقترح: وسم الفروق وفق decision impact.

7. الحساب مورد وعائي. يجب توجيه compute إلى العقد عالية عدم اليقين والقيمة. الاختبار المقترح: adaptive budget مقابل budget ثابت.

8. الاستدلال يحتاج **verifier**. اللغة المتماسكة قد تخفي خطأً حسابيًا أو سببيًا. الاختبار المقترح: فصل generator/validator وتجارب blind.

9. الهدم وظيفة بنائية. الاعتراض لا يوقف النظام بل ينتج بيانات وإصلاحًا. الاختبار المقترح: قياس نسبة الأخطاء المكتشفة قبل التنفيذ.

10. الذاكرة الخارجية ليست حقيقة. retrieval قد يعيد محتوى خبيثًا أو قديمًا. الاختبار المقترح: provenance وfreshness وinjection tests.

11. السياق الطويل ليس ذاكرة. زيادة النافذة لا تضمن state tracking أو فهم الاعتماديات. الاختبار المقترح: اختبارات dependencies لا needle فقط.

12. الوكالة ليست كثرة الأدوات. الأداة تفيد إذا اختيرت في الوقت الصحيح وبصلاحية صحيحة. الاختبار المقترح: tool necessity and misuse rate.

13. **1B** مختبر لا نسخة مصغرة. يمكنه كشف data/architecture issues بكلفة أقل. الاختبار المقترح: ارتباط نتائج 1B بنتائج 9B عبر scaling study.

14. **9B** ليس ضمانًا للتعميم. قد يحفظ أكثر دون انتقال أفضل. الاختبار المقترح: procedural OOD holdouts.

15. التعدد اللغوي يحتاج ثبات بنيوي. الترجمة السطحية لا تحفظ reasoning. الاختبار المقترح: isomorphic tasks across AR/EN/FR.

16. الاصطناعي يحتاج أصلًا. self-generated data قد يضاعف الخطأ. الاختبار المقترح: source-linked verified synthetic pipeline.

17. المكافأة قد تُخترق. النموذج قد يحسن score دون القدرة المقصودة. الاختبار المقترح: reward-hacking probes and evaluator swaps.

18. الإطالة ليست تعمقًا. long CoT قد يكون دورانًا. الاختبار المقترح: correctness per reasoning token.

19. الضغط قد يضيّع القيود. context compaction قد يحذف dependency حاسمة. الاختبار المقترح: reconstruction tests against source.

20. المهارة يجب أن تتبلور. الحل الواحد لا يثبت HyperSkill. الاختبار المقترح: repeated transfer across domains.

21. الحلقة يجب أن تتوقف. التحسين العودي غير المحدود يستهلك ويزيد الخطأ. الاختبار المقترح: plateau and budget stop conditions.

22. الأثر الخارجي جزء من التقييم. جمال النص لا يساوي نجاح الفعل. الاختبار المقترح: sandbox outcomes and rollback tests.

23. السلامة حاكمية لا مرشح نهائي. يجب إدخال authorization في التخطيط نفسه. الاختبار المقترح: unsafe trajectory interception rate.

24. القياس متجه لا رقم. IQ-like score يخفي نقاط انهيار حرجة. الاختبار المقترح: capability vector with floors.

25. الانتقال هو الدليل الأقوى. القدرة العامة تظهر في مهام غير مصممة للتدريب. الاختبار المقترح: cross-domain and temporal transfer.

26. الـ**AGI** أفق اختباري. لا يُثبت بالمصطلح أو benchmark واحد. الاختبار المقترح: برنامج شروط ضرورية متعددة لا claim نهائي.

20. ثلاثة نماذج متنافسة للمشروع

النموذج المحافظ: نموذج لغوي **9B** مُحسن. يفترض أن البيانات العالية الجودة، Transformer حديث، وSFT/DPO كافية لصنع نموذج قوي. قوته البساطة وقابلية المقارنة مع Gemma/Qwen/Llama؛ ضعفه أنه لا يفسر كيف تتكامل الذاكرة والأدوات ومحكمة الهدم، وقد يحول مفاهيم Moussaif إلى branding فوق وصفة شائعة.

النموذج التركيبي: النموذج-النظام. يعتبر الأوزان قلبًا داخل نظام يضم memory، tools، verifier، KB، وgovernance. قوته أنه يطابق واقع التطبيقات الحديثة ويتيح لـ1B أداء أدوار مفيدة؛ ضعفه أن التحسن قد يأتي من النظام المحيط لا من النموذج، فيصعب تحديد «ذكاء النموذج».

النموذج الاختراقي: النواة الحاكمية المتعلمة. يقترح أن الفرق الحاسم ليس إضافة المكونات، بل تعلم policy فوقية تستخرج الفرق الحاكمي، ترفع السؤال، توزع الحساب، تهدم النتيجة، وتبلور الحل إلى مهارة. قوته أنه يقدم متغيرًا منظمًا؛ ضعفه أنه قد يعيد تسمية metacognition وrouting وverification من دون إثبات جدة سببية.

وفق QMCD، لا يُنهار التراكب مبكرًا. الورقة تختار نموذجًا أعلى يجمع المحافظ والتركيبي ويضع الاختراقي كفرضية: يبنى Transformer قويًا قابلًا للمقارنة، يوضع داخل نظام موثق، ثم تُختبر قيمة النواة الحاكمية بعمليات إزالة ablation. إذا لم تؤد MCD/Q-MCD/HAKIM إلى تحسن انتقال أو كفاءة مقارنة بخط أساس متساوي الحساب، تُعامل كواجهة تنظيمية لا اكتشاف معماري.

21. المقارنة باستخدام MCD وQMCD

يحصل النموذج المحافظ على كثافة ضجيج منخفضة واقتصاد جيد، لكنه متوسط في الدمج والتوليد. النموذج التركيبي أعلى في الدمج والوكالة لكنه معرض لتعقيد النظام. النموذج الاختراقي أعلى في الأصالة المفهومية والتوليد، لكنه يحمل أكبر خطر ادعاء زائد. قبل الهدم يمكن تقدير MCD النوعي: محافظ 58/100، تركيبي 76/100، اختراقي 72/100. بعد فرض ablations وحدود الادعاء وقياس الأثر، يرتفع النموذج الأعلى المدمج إلى 84/100. الأرقام rubrics داخلية لا نتائج علمية.

في QMCD تُعطى احتمالات أولية تقريبية: 0.25 لأن تكون الوصفة التقليدية كافية لمعظم المكاسب، 0.55 لأن النظام التركيبي يحقق أفضل frontier، و0.20 لأن policy الحاكمية الجديدة تضيف أثرًا سببيًا كبيرًا مستقلًا. التجارب الفاصلة هي: baseline متساوي المعلمات والtokens؛ إضافة KB/tools فقط؛ إضافة verifier؛ ثم إضافة sovereign routing. يجب أن يظهر الأثر في مهام جديدة وتحت budget ثابت.

22. نظرية مساعف للرافعة المعرفية للمعلمة

الاسم الإنجليزي: Moussaif Parameter-Cognition Leverage Theory (MPCL)

البذرة والنقص: خرجت النظرية من الحاجة إلى تجاوز القياس الخام بالحجم وربط مفاهيم المشروع بمتغير يمكن اختباره.

التعريف: تقول إن القيمة الذكية للمعلمة لا تتحدد بعددها، بل بمقدار ما تحمله من بنى قابلة للانتقال وبقدرتها على استدعاء ذاكرة وأدوات والتحقق من أثرها.

الآلية: تتولد الرافعة من تفاعل جودة البيانات، تنوع البنى، كثافة الإشراف القابل للتحقق، كفاءة الاسترجاع، وسياسة الحساب. يمكن تمثيلها: PCL = Transfer×Calibration×ToolGain×Robustness / (Parameters×InferenceCost).

التنبؤ الفارق: قد يتفوق 1B مدرّب بعناية ومسنود بـKB وأدوات على نموذج أكبر في مهام محددة وكلفة متساوية، لكن يتراجع في المعرفة المغلقة والتركيب غير المدعوم.

بروتوكول الاختبار: عائلة نماذج 300M/600M/1B/3B/9B مع نفس البيانات النسبيّة، ثم مقارنة performance-per-parameter وperformance-per-cost على holdouts.

أقوى اعتراض وحدود النظرية: لا تلغي النظرية أثر الحجم؛ سقف التمثيل والتعميم قد يبقى أعلى في 9B.

العلاقة بالنظرية الأم: تعمل هذه النظرية كوحدة داخل معمارية MOUSSAIF9B؛ ولا تكفي منفردة لإثبات AGI.

23. نظرية عرض نطاق الفرق الحاكمي

الاسم الإنجليزي: Sovereign Difference Bandwidth Theory (SDB)

البذرة والنقص: خرجت النظرية من الحاجة إلى تجاوز القياس الخام بالحجم وربط مفاهيم المشروع بمتغير يمكن اختباره.

التعريف: القدرة العليا للنموذج تعتمد على عدد الفروق ذات الأثر في الحكم التي يستطيع اكتشافها وحفظها وربطها ضمن budget محدد، لا على عدد التفاصيل المسترجعة فقط.

الآلية: يُعرّف SDB = Σ importance(Δi)×correctness(Δi)×integration(Δi) / compute. الفرق الحاكمي يغير ranking أو الخطة أو درجة الثقة.

التنبؤ الفارق: التدريب على definitions-examples-counterexamples وconflict maps يرفع أداء القرارات الجديدة أكثر من corpus تفسيري متساوي الحجم بلا فروق صريحة.

بروتوكول الاختبار: مجموعات متطابقة المحتوى تختلف في تمثيل الفروق؛ قياس decision transfer والقدرة على توليد counterfactuals.

أقوى اعتراض وحدود النظرية: تعريف importance قد يكون تابعًا للمهمة وقد يتحول إلى labeling مكلف أو متحيز.

العلاقة بالنظرية الأم: تعمل هذه النظرية كوحدة داخل معمارية MOUSSAIF9B، ولا تكفي منفردة لإثبات AGI.

24. نظرية الوعائية الحسابية متعددة المديات

الاسم الإنجليزي: Multi-Scale Vascular Compute Theory (MVC)

البذرة والنقص: خرجت النظرية من الحاجة إلى تجاوز القياس الخام بالحجم وربط مفاهيم المشروع بمتغير يمكن اختباره.

التعريف: الحساب ينبغي أن يتدفق على مستويات token، خطوة، tool، subproblem، وagent بحسب القيمة المعرفية وعدم اليقين والخطر.

الآلية: لكل عقدة j ميزانية Bj ∝ Uj×Rj×Vj، حيث U عدم اليقين، R أثر الخطأ، V قيمة المعلومات، مع حد أقصى وشروط توقف.

التنبؤ الفارق: adaptive routing يحسن correctness-per-token ويخفض overthinking مقارنة بميزانية ثابتة، خصوصًا في خليط مهام سهل/صعب.

بروتوكول الاختبار: مقارنة R0-R4 routing مع fixed-CoT عند نفس متوسط tokens، وقياس calibration والlatency.

أقوى اعتراض وحدود النظرية: classifier الصعوبة نفسه قد يخطئ ويمنع التفكير في مسائل تبدو سهلة.

العلاقة بالنظرية الأم: تعمل هذه النظرية كوحدة داخل معمارية MOUSSAIF9B، ولا تكفي منفردة لإثبات AGI.

25. نظرية تبلور المهارة المحكوم بالهدم

الاسم الإنجليزي: Falsification-Gated Skill Crystallization Theory (FGSC)

البذرة والنقص: خرجت النظرية من الحاجة إلى تجاوز القياس الخام بالحجم وربط مفاهيم المشروع بمتغير يمكن اختباره.

التعريف: لا تتحول trajectory ناجحة إلى HyperSkill إلا بعد تكرار النجاح عبر تنويعات، ونجاتها من محكمة هدم، وامتلاك شروط حدود وفشل.

الآلية: حلول متعددة → استخراج invariants → counterexamples → verifier → skill schema → transfer test → registry. العائد SCY = skills passing transfer / candidate skills.

التنبؤ الفارق: مهارات أقل عددًا لكنها محكومة بالهدم تتفوق على مكتبة ضخمة مستخرجة آليًا في transfer وتقلل negative transfer.

بروتوكول الاختبار: مقارنة مكتبتين: auto-extracted وfalsification-gated على مهام جديدة مع قياس reuse/failure.

أقوى اعتراض وحدود النظرية: المحاكم المكلفة قد تبطئ التعلم وتستبعد حلولًا مبتكرة لم تتوفر لها اختبارات.

العلاقة بالنظرية الأم: تعمل هذه النظرية كوحدة داخل معمارية MOUSSAIF9B، ولا تكفي منفردة لإثبات AGI.

26. نظرية الذاكرة المزدوجة ذات النزاهة

الاسم الإنجليزي: Dual Integrity Memory Theory (DIM)

البذرة والنقص: خرجت النظرية من الحاجة إلى تجاوز القياس الخام بالحجم وربط مفاهيم المشروع بمتغير يمكن اختباره.

التعريف: الذكاء الموثوق يتطلب فصلًا وتنسيقًا بين ذاكرة معلمية بطيئة مستقرة وذاكرة غير معلمية سريعة قابلة للتحديث، مع بوابة نزاهة بينهما.

الآلية: الأوزان تحمل priors والمهارات العامة؛ KB تحمل الحقائق المتغيرة والمشروعات؛ context capsule يحمل state. بوابة النزاهة تحسم المصدر والزمن والتعارض.

التنبؤ الفارق: النظام المزدوج يقلل hallucination في الحقائق المتغيرة ويحافظ على generalization أفضل من continued fine-tuning المتكرر وحده.

بروتوكول الاختبار: اختبارات knowledge update وconflicting memories وstale retrieval مع قياس factuality وcatastrophic forgetting.

أقوى اعتراض وحدود النظرية: يزيد الاعتماد على جودة الاسترجاع والأمن، وقد يخلق تناقضًا بين الأوزان والذاكرة.

العلاقة بالنظرية الأم: تعمل هذه النظرية كوحدة داخل معمارية MOUSSAIF9B، ولا تكفي منفردة لإثبات AGI.

27. نظرية الوكالة العودية المحدودة بأثر العالم

الاسم الإنجليزي: Bounded World-Effect Recursive Agency Theory (BWRA)

البذرة والنقص: خرجت النظرية من الحاجة إلى تجاوز القياس الخام بالحجم وربط مفاهيم المشروع بمتغير يمكن اختباره.

التعريف: الوكالة النافعة ليست تكرار الخطة، بل حلقة محدودة تتعلم من نتائج فعل قابل للقياس وتحافظ على التفويض وإمكانية الرجوع.

الآلية: Plan→Authorize→Act→Observe→Verify→Update، بحدود iterations وcost وrisk وrollback. جودة الوكالة = task success×reversibility×calibration / incidents.

التنبؤ الفارق: تدريب world-effect trajectories يرفع نجاح المهام الطويلة أكثر من imitation للحوار، مع انخفاض الادعاء الكاذب بالإنجاز.

بروتوكول الاختبار: بيئات sandbox ذات outcomes مخفية وفشل أدوات، مقارنة النصوص التفسيرية مع النجاح الفعلي.

أقوى اعتراض وحدود النظرية: الأثر الواقعي صعب القياس ومكلف، وقد لا يعمم من sandbox إلى بيئات مفتوحة.

العلاقة بالنظرية الأم: تعمل هذه النظرية كوحدة داخل معمارية MOUSSAIF9B، ولا تكفي منفردة لإثبات AGI.

28. النموذج النظري النهائي: معمارية الرافعة الحاكمية

بعد دمج النظريات الست، تسمى النظرية الأم «معمارية الرافعة الحاكمية متعددة المقاييس» Multi-Scale Sovereign Leverage Architecture. تفسر جودة MOUSSAIF9B بوصفها ناتجًا عن سعة معلمية محدودة تُضاعفها بيانات تبرز الفروق، وتوجيه وعائي للحساب، وذاكرة مزدوجة، ومهارات لا تتبلور إلا بعد الهدم، ووكالة تقاس بأثر العالم.

الصياغة المفهومية:

MSLA = [PCL × SDB × MVC × DIM × FGSC × BWRA] × KIG

حيث KIG بوابة نزاهة المعرفة. الضرب لا يعني قياسًا عدديًا جاهزًا، يشير إلى أن انهيار عامل حرج قد يخفض النظام كله. نموذج واسع بلا نزاهة قد يكون مقنعًا وخطيرًا، ونظام أدوات قوي بلا عرض نطاق فرق قد ينفذ خطة خاطئة بكفاءة.

تعمل المعمارية كالتالي: input → task/risk classification → sovereign question → difference graph → memory retrieval → compute routing → candidate paths → tools → falsification → authorized action → world-effect → skill/memory proposal → integrity gate. وفي كل انتقال يُحفظ provenance وconfidence وbudget.

الجديد الحقيقي المحتمل ليس كل مكوّن منفردًا، معظم المكونات لها سوابق. الجدة المقترحة هي جعل «الفرق الحاكمي» وحدة مشتركة بين data labeling وreasoning routing وevaluation وmemory crystallization. هذه الجدة تبقى فرضية حتى تُظهر ablations أنها تفسر تحسنًا لا يفسره مجرد زيادة بيانات reasoning أو أدوات.

29. الصياغة الصورية وشبه الرياضية

نعرّف متجه القدرة عند الزمن t:

C_t = [K,R,A,T,M,Cal,Rob,Eff]

حيث K المعرفة، R الاستدلال، A التجريد، T الأدوات، M الذاكرة، Cal المعايرة، Rob المرونة، Eff الكفاءة. الانتقال التدريبي:

C_{t+1}=C_t+F(D_t,O_t,V_t,B_t)-G(Noise,Contamination,Forgetting,RewardHacking).

للمهام، يعرف routing score:

$\rho(q)=\alpha\cdot\text{Difficulty}+\beta\cdot\text{Uncertainty}+\gamma\cdot\text{Impact}+\delta\cdot\text{ToolNeed}-\eta\cdot\text{BudgetPressure}$.

وتحدد ρ درجة التفكير R0-R4. يعرف الفرق الحاكمي Δ* بأنه الفرق الذي يزيد expected decision utility أكثر من عتبة τ. ويكون capture score:

SDC = Σ w_i·1(Δ_i detected and used correctly)/Σw_i.

يعرف الذكاء المعدل بالمرونة:

RAIS = GMean(K,R,A,T,Transfer) × Calibration × Robustness × Integrity.

ولا ينشر RAIS دون المكونات. ويعرف عائد المهارة:

SCY = ValidTransferredSkills / CandidateSkills,

ومعدل نجاة الهدم:

FSR = Claims surviving strong tests / Claims submitted.

ارتفاع FSR بسبب ضعف الاختبارات ليس نجاحًا، لذلك يسجل court strength مستقلًا.

تكلفة التدريب التقريبية للdecoder-only هي FLOPs≈6ND. تدريب 1B على 300B token يقارب 1.8×10^21 FLOPs أو 20.8 PFLOP-day idealized، وعلى 1T يقارب 69.4 PFLOP-day. تدريب 9B على 2T يقارب 1250 PFLOP-day، وعلى 3T يقارب 1875 PFLOP-day، قبل احتساب عدم الكفاءة والتجارب. الأرقام تخطيطية وتوضح لماذا يجب إثبات الوصفة في proxy scales.

30. عشرون مفهومًا جديدًا أو معاد ضبطه

1. الفرق الحاكمي: فرق إذا أُهمل تغيّر الحكم أو الخطة أو الثقة. الفرق الوظيفي: تمييزه عن الفارق الوصفي قليل الأثر.
2. عرض نطاق الفرق: قدرة النظام على التقاط فروق عالية الأثر لكل compute. الفرق الوظيفي: مقياس كفاءة معرفية.
3. السؤال الرافع: سؤال يقلص التراكب بين النماذج أو يكشف متغيرًا خفيًا. الفرق الوظيفي: ليس مجرد clarification.
4. الوعاء المعرفي: وحدة معرفة تربط تعريفًا ودليلًا وحدودًا واعتراضًا. الفرق الوظيفي: بديل chunk بلا بنية.
5. الحساب الوعائي: تدفق compute إلى العقد وفق القيمة والخطر. الفرق الوظيفي: بديل التفكير المتساوي.
6. كبسولة حالة المهمة: ملخص قابل لإعادة البناء يحفظ القيود والقرارات. الفرق الوظيفي: ذاكرة عمل مضغوطة.
7. نزاهة الذاكرة: اتساق المصدر والزمن والثقة والتفويض في memory. الفرق الوظيفي: تمنع تحول الذاكرة إلى شائعة.
8. مرشح التبلور: بوابة تحول trajectory إلى HyperSkill بعد transfer. الفرق الوظيفي: تمنع تضخم المكتبة.
9. حلقة محدودة: تكرار يملك budget وstop وrollback. الفرق الوظيفي: تمييزه عن recursion المفتوح.
10. أثر العالم: نتيجة قابلة للملاحظة للفعل، لا وصف الإنجاز. الفرق الوظيفي: مقياس وكالة.
11. معدل منفعة التفكير: زيادة الصحة لكل token reasoning إضافي. الفرق الوظيفي: يكشف overthinking.
12. أرضية القدرة: حد أدنى لا يعوضه المتوسط المرتفع. الفرق الوظيفي: مهم للسلامة والمعايرة.
13. الفشل المركب: تفاعل عدة أعطال لا مجموعها البسيط. الفرق الوظيفي: اختبار resilience.
14. الاستقلال التحققي: عدم اعتماد verifier كليًا على نفس أخطاء generator. الفرق الوظيفي: يقلل correlated error.
15. الانتقال المتشاكل: حل بنية واحدة عبر مجالات أو لغات مختلفة. الفرق الوظيفي: قياس تجريد.
16. كثافة الذكاء لكل معلمة: قدرة موثوقة لكل parameter. الفرق الوظيفي: ليست دعوى بإلغاء الحجم.
17. التلوث الناعم: تشابه دلالي مع الاختبار رغم غياب النسخ الحرفي. الفرق الوظيفي: تهديد للتقييم.
18. حاكمية الإصدار: قرار release مبني على بوابات متعددة. الفرق الوظيفي: يفصل البحث عن النشر.
19. الامتناع المنتج: توقف يحدد النقص وخطوة التحقق. الفرق الوظيفي: ليس رفضًا فارغًا.
20. إعادة البناء الذاتي: استرجاع state والنموذج بعد ضغط أو فشل. الفرق الوظيفي: لا يعني تغيير الدستور ذاتيًا.

31. عشر أدوات منهجية وتشغيلية

الأدوات التالية تحول مفاهيم الورقة إلى عمليات قابلة للبناء والاختبار.

الأداة	الحاجة	المدخلات	الخطوات	المخرج	أخطر حد
مصفوفة البيانات-	ربط كل bucket	dataset metadata وbenchmarks	حساب المساهمة	خريطة سببية للخلطة	قد تخلط الارتباط

القدرة	بقدرات واختبارات		الحدية والregressions		بالسببية
محرك السؤال الحاكمي	رفع جودة framing	المهمة والفرضيات	توليد أسئلة وفحص information gain	سؤال أو اثنان قبل الحل	قد يستهلك وقتًا في مسائل مباشرة
موجه الحساب الوعائي	تخصيص التفكير والأدوات	difficulty/risk/ budget	اختيار R0-R4 وتحديثه بعد النتائج	compute خطة	خطأ التصنيف المبكر
محكمة الهدم متعددة الرؤوس	كشف أخطاء مختلفة	حل ومصادر وسياسة	counterexample + symbolic + factual + safety	قرار قبول/تعديل/امتناع	تكلفة وارتباط المحققين
مرشح تبلور HyperSkill	منع skills الوهمية	ناجحة trajectories	استخراج invariants ثم transfer tests	skill schema بإصدار	استبعاد المهارات النادرة
مدير نزاهة KB	حماية الذاكرة	claims/sources/ time/confidence	حل التعارض والexpiry والprovenance	memory record صالح	تعقيد التشغيل
مختبر الفشل المركب	اختبار resilience	سيناريوهات أدوات وسياق وهجوم	تركيب faults وقياس التعافي	failure matrix	قد لا يمثل العالم المفتوح
مسجل الأثر العالمي	ربط النص بالفعل	action environment و outcome	التحقق من النجاح والrollback	world-effect trace	صعوبة قياس الأثر البعيد
مقياس الانتقال المتشاكل	قياس التجريد	مهام ذات بنية مشتركة	تبديل اللغة والمجال والسطح	transfer score	صعوبة ضمان التشاكل الحقيقي
بوابة الإصدار الحاكمية	قرار النشر	كل metrics والحوادث	floors ثم canary ثم rollback	release packet	قد تصبح بيروقراطية

32. سبعة مقاييس أولية

1. **Moussaif Capability Vector - MCV**: متجه المعرفة والاستدلال والتجريد والأداة والذاكرة والمعايرة والمرونة والكفاءة الحد: لا يختزل في متوسط.

2. **Resilience-Adjusted Intelligence Score - RAIS**: متوسط هندسي للقدرات مضروبًا في المعايرة والمرونة والنزاهة الحد: ليس IQ بشريًا.

3. **Sovereign Difference Capture - SDC**: نسبة الفروق عالية الأثر المكتشفة والمستخدمة صحيحًا الحد: يتطلب أوزان أثر موثقة.

4. **Compute Leverage Ratio - CLR**: تحسن الأداء الموثوق لكل FLOP/token/latency الحد: يقارن ضمن شروط متساوية.

5. **Falsification Survival Rate - FSR**: نسبة الادعاءات الناجية من محاكم قوية الحد: ينشر مع قوة المحكمة.

6. **Skill Crystallization Yield - SCY**: نسبة المهارات المرشحة التي تنجح في transfer الحد: يعاقب تضخم المكتبة.

7. **Knowledge Integrity Gate Score - KIGS:** provenance+freshness+entailment+conflict handling الحد: أرضية إلزامية للنشر.

33. ثماني عشرة فرضية بحثية

H1 [قوية]: الفلترة التعليمية وإزالة التكرار سترفعان أداء 1B أكثر من إضافة الحجم نفسه من web raw. الاختبار: proxy pretraining controlled mixtures.

H2 [قوية]: process supervision مع verifier تنفيذي سيحسن math/code أكثر من outcome-only عند budget متقارب. الاختبار: step labels + unit tests.

H3 [قوية]: GQA سيخفض KV cost مع خسارة محدودة مقابل MHA في نطاق المشروع. الاختبار: architecture ablation.

H4 [قوية]: KB مزدوجة المصدر والزمن ستخفض أخطاء الحقائق المتغيرة مقارنة بالأوزان وحدها. الاختبار: temporal QA.

H5 [قوية]: نموذج 9B سيحسن تركيب المهام غير المدعومة بالأدوات مقارنة بـ1B. الاختبار: closed-book OOD.

H6 [متوسطة]: question elevation سيحسن المسائل الغامضة أكثر من زيادة CoT tokens مباشرة. الاختبار: ambiguous tasks.

H7 [متوسطة]: sovereign difference labels سترفع cross-domain transfer في القرار. الاختبار: isomorphic decision tasks.

H8 [متوسطة]: adaptive compute سيحقق جودة ثابتة بتكلفة أقل من fixed reasoning. الاختبار: mixed difficulty.

H9 [متوسطة]: falsification-gated skills ستخفض negative transfer رغم قلة عددها. الاختبار: skill library A/B.

H10 [متوسطة]: Arabic-native reasoning data ستتفوق على translated-only في المجاج والمورفولوجيا. الاختبار: native/translated ablation.

H11 [متوسطة]: world-effect training سيخفض false completion claims في agent tasks. الاختبار: sandbox outcomes.

H12 [متوسطة]: 1B proxy rankings ستتنبأ جزئيًا لا كليًا بترتيب خلطات 9B. الاختبار: rank correlation across scales.

H13 [ضعيفة]: MCD score اليدوي سيتنبأ بتحسن benchmark قبل التدريب. الاختبار: blind expert rubric.

H14 [ضعيفة]: HyperLoop بحد 7 iterations أمثل عبر مجالات متعددة. الاختبار: iteration sweep.

H15 [ضعيفة]: 64K tokenizer هو التوازن الأفضل للعربية والفرنسية والكود. الاختبار: tokenizer ablation.

H16 [تخمينية]: الفرق الحاكمي وحدة تمثيل يمكن اكتشافها في activations عبر probes. الاختبار: mechanistic probes.

H17 [تخمينية]: تدريب السؤال والحكم معًا ينتج meta-transfer يتجاوز مجموعهما المنفصل. الاختبار: factorial training design.

H18 [تخمينية]: النظام المتكامل 9B+KB+tools قد يحقق سلوكًا عامًا في نطاقات عملية دون أن يكون AGI مطلقًا. الاختبار: open-ended mission suite.

34. تسعة تنبؤات فارقة

P1. إذا كانت MPCL صحيحة: يتفوق 1B+KB+tools على 9B closed-book في حقائق حديثة وبكلفة أقل. ما يهدمه: النموذج الأكبر قد يفوز دائمًا حتى مع نفس الأدوات.

P2. إذا كانت SDB صحيحة: تظهر مكاسب أكبر على counterfactual/decision tasks لا على perplexity فقط. ما يهدمه: تحسن اللغة دون القرار.

P3. إذا كانت MVC صحيحة: يخفض متوسط tokens مع ثبات accuracy وتتحسن المعايرة. ما يهدمه: routing يخطئ في المسائل الصعبة المتخفية.

P4. إذا كانت FGSC صحيحة: مكتبة أصغر تحقق reuse أعلى وfailure أقل. ما يهدمه: auto library تتفوق مع الحجم.

P5. إذا كانت DIM صحيحة: تحديث KB يصلح المعرفة دون نسيان قدرات عامة. ما يهدمه: التناقض مع الأوزان يرفع الأخطاء.

P6. إذا كانت BWRA صحيحة: يرتفع نجاح المهام الفعلية وينخفض الادعاء الكاذب. ما يهدمه: تحسن النص دون outcome.

P7. إذا كانت النواة الحاكمية سببية: تظل المكاسب بعد مساواة compute والبيانات والمحققين. ما يهدمه: تزول المكاسب عند ضبط العوامل.

P8. إذا كان التعدد اللغوي بنيويًا: تبقى فروق الأداء صغيرة في مهام متشاكلة AR/EN/FR. ما يهدمه: انهيار العربية في reasoning العميق.

P9. إذا اقترب النظام من general agency: ينتقل إلى tools ومجالات غير مدربة مع أخطاء قابلة للتصحيح. ما يهدمه: يتطلب templates خاصة لكل مهمة.

35. محفظة التقييم: الذكاء متجه لا ترتيب واحد

تستعمل المحفظة HELM كمبدأ للتقييم متعدد الأبعاد [27]، لا كقائمة ثابتة. المعرفة العامة تقاس بـMMLU-like private forms؛ reasoning العلمي بـGPQA مع الانتباه إلى محدودية الاختيار المتعدد [28]؛ البرمجة بوظائف مولدة ومستودعات شبيهة SWE-bench [29] مع اختبارات تلوث؛ الرياضيات بمسائل إجرائية مولدة؛ الأدوات ببيئات function calling؛ والعربية بـnative suites للعلوم والمنطق والثقافة والثقة.

لكل benchmark خمس نسخ: procedural، paraphrased، private clean، public reference، وcross-lingual isomorphic. تسجل hardware، judge version، tool access، reasoning budget، sampling، prompts، وdate. ويُحسب cost per correct answer. لا يُقارن 1B مباشرًا بـ9B إذا اختلفت الأدوات أو sampling إلا في محور system-level واضح.

توجد capability floors: سلامة الأداة، calibration، citation entailment، وmemory integrity. لا يعوض متوسط مرتفع سقوطًا حرجًا. كما تُقاس resilience تحت tool outage، conflicting evidence، missing context، distractors، paraphrase، prompt injection، low compute، وتبديل اللغة. ويجب نشر failure examples لا أفضل scores فقط.

36. بروتوكول بناء MOUSSAIF9B-1B

المرحلة 1 - المختبر **50M/150M/300M**: تدريب قصير لثلاثة tokenizers وثلاث خلطات بيانات، قياس loss curves وArabic fragmentation وcode/math transfer. المرحلة 2 - **1B MVP**: تكوين 1792/24، تدريب checkpoints-100، 300B token كل نسبة محسوبة، اختبارات contamination وgradient spikes. المرحلة 3 - **1B** طويل التدريب: اختيار أفضل خليط ورفع tokens تدريجيًا حتى نقطة انخفاض العائد أو الميزانية.

بعد base pretraining، ينفذ SFT من بيانات تعليمات موثقة بثلاث لغات، ثم reasoning SFT في math/code/science، ثم tool calling. يُدرب verifier صغير أو متعدد الرؤوس مستقل، ويُجرى DPO على preferences متعددة الأبعاد. RLVR يقتصر أولًا على code execution والرياضيات والألغاز القابلة للتحقق. تدخل محكمة الهدم بعد وجود baseline حتى يمكن قياس أثرها.

بوابات الخروج: (1) لا تلوث معروف في private tests؛ (2) ثبات loss وعدم انهيار لغوي؛ (3) تحسن على ثلاثة مجالات على الأقل بلا regression حرج؛ (4) calibration قابل للضبط؛ (5) tool recovery؛ (6) Arabic scientific writing؛ (7) نموذج card كامل. إذا فشل 1B في تعلم routing، يمكن فصله إلى classifier خارجي بدل إجباره داخل LM.

37. بروتوكول الترقية إلى MOUSSAIF9B-9B

لا يبدأ 9B قبل استخراج scaling curves من النماذج الأصغر. يُثبت tokenizer بعد اختبار قابلية النقل، ويُعاد فحص mixture لأن تفاعل القدرات مع الحجم غير خطي. التكوين المرجعي GQA6/FFN16128/4608/32، لكن تُقارن نسخة أعمق أضيق ونسخة أعرض أقل طبقات في 600M-1B proxies لتحديد أثر العمق على reasoning والسياق.

يُقترح training budget بين 2 و5T token وفق التمويل، مع checkpoints للاستفادة من overtraining في inference-heavy use، مستلهمًا من النماذج الصغيرة المدربة طويلًا ومن scaling المعتمد على كلفة الاستدلال [3-6]. تُعطى البيانات عالية القيمة عدة epochs بحذر مع dedup وإعادة صياغة، بينما web diversity غالبًا epoch أقل. ويُرصد memorization عبر canaries وextraction tests.

يمكن distill من teacher ensembles، لكن يجب عدم بناء شخصية النموذج على نموذج واحد. يستخدم teachers لتوليد candidates، ثم tools/verifiers/humans للقبول. بعد pretraining، يمر 9B بنفس post-training stack مع رفع diversity وdifficulty. تُختبر strong-to-weak distillation من 9B إلى 1B لإبقاء مسار edge متزامنًا.

يظل MoE أفقًا لا نقطة بداية. إذا أثبتت domain routing والـHyperSkills وجود تخصصات مستقرة، يمكن اختبار MOUSSAIF9B-MoE في نسخة لاحقة، مع قياس load balance وexpert collapse. إدخال MoE قبل نضج البيانات والقياس يزيد عدد مصادر الفشل.

38. استراتيجية الحساب والتكلفة والمخاطر التشغيلية

تُدار الميزانية بوحدات PFLOP-day وtokens مفيدة، لا بعدد GPUs فقط. يجب حساب تكلفة التجارب الفاشلة والـdata pipeline والـstorage والتقييم والاستدلال. تدريب 9B على تريليونات tokens مشروع بنية تحتية؛ البديل الواقعي قد يكون continued pretraining من base مفتوح مناسب، أو بناء 1B من الصفر ثم adaptation لـ9B موجود، مع الحفاظ على هوية MOUSSAIF في البيانات والـpost-training والنظام المحيط.

ثلاثة سيناريوهات: محدود: 1B من الصفر + adapters على 7-9B مفتوح؛ متوسط: 1B كامل وcontinued pretraining عميق لنموذج 9B؛ كبير: 9B من الصفر. يجب ألا يدفع الطموح إلى تدريب ناقص غير موثق. قيمة البحث قد تكون أعلى في data/verification framework مفتوح من checkpoint ضعيف بتكلفة كبيرة.

المخاطر تشمل ترخيص البيانات، خصوصية السجلات، تسرب benchmarks، الاعتماد على synthetic teachers، انقطاع checkpoints، drift في evaluators، وغياب فريق red-team. تُدار عبر secrets، reproducible configs، hashes، lineage، checkpoint retention، isolation، وقوائم منع صريحة. كل مرحلة تملك rollback وincident owner.

38.1 هندسة الأهداف ودوال الخسارة

لا يكفي تحديد corpus والمعمارية؛ يجب تعريف ما الذي يتعلمه النموذج في كل مرحلة. الهدف الأساسي يبقى next-token prediction لأنه يوفر قاعدة عامة قابلة للتوسع، لكن MOUSSAIF9B يقترح أهدافًا مساعدة مضبوطة لا تعمل كلها في وقت واحد. الهدف الأول هو span-level causal reconstruction لتقوية تتبع الاعتماديات الطويلة. الهدف الثاني هو difference tagging في نسبة صغيرة من البيانات، حيث يتنبأ النموذج بالفارق الذي يغير الحكم بين بديلين. الهدف الثالث هو source-role prediction الذي يميز الادعاء والدليل والاعتراض والاستنتاج. الهدف الرابع هو tool-call boundary prediction لتعلم متى يتوقف النص ويبدأ الفعل. الهدف الخامس هو multi-token prediction اختياري يختبر أثر تسريع التعلم وتحسين التخطيط المحلي، مع ضرورة قياس أي تدهور في calibration أو التفاصيل.

تكتب الدالة العامة بصورة مفهومية:

$$L = L_{NTP} + \mu 1 L_{diff} + \mu 2 L_{source} + \mu 3 L_{tool} + \mu 4 L_{state} + \mu 5 L_{verifier}$$

لا تعني هذه الصيغة أن الأوزان ثابتة؛ يُستخدم curriculum زمني. في البداية يهيمن L_NTP، ثم ترتفع الأهداف الخاصة في continued pretraining أو post-training. الهدف state loss يقيس قدرة النموذج على إعادة بناء كبسولة المهمة من سجل طويل، بينما verifier loss يدرب رأسًا أو نموذجًا منفصلًا على الحكم المرحلي. أي هدف لا يظهر أثرًا خارج dataset الذي صُمم له يُحذف مهما بدا منسجمًا مع النظرية.

في reasoning post-training تُفصل ثلاثة أنواع من المكافأة: reward للنتيجة القابلة للتحقق، reward للعملية، وpenalty للتكلفة أو المخاطرة. تكون المكافأة:

$$R = r_{correct} + a \cdot r_{process} + b \cdot r_{calibration} + c \cdot r_{recovery} - d \cdot tokens - e \cdot unsafe_{action}$$

تُضبط المعاملات حسب المجال؛ في code/math يمكن رفع r_correct التنفيذي، وفي البحث المفتوح يرتفع وزن provenance وcalibration. لا يُسمح لمكافأة الأسلوب أن تعوض خطأً معرفيًا.

يجب اختبار loss interference. قد يرفع difference tagging قدرة المقارنة لكنه يضعف السرد الحر، وقد يرفع tool prediction الميل إلى استدعاء الأدوات بلا حاجة. لذلك تستخدم gradient diagnostics، وتجارب فصل heads، ومرحلة warm-up، وsampling caps. تُعد كل دالة خسارة «فرضية سببية»، وليست ميزة تُضاف لأن اسمها جذاب.

38.2 البنية الموزعة للتدريب ومراقبة الاستقرار

ينبغي أن تكون بنية التدريب قابلة لإعادة الإنتاج من 1B إلى 9B. يوصى بفصل طبقة البيانات، ومحرك التدريب، وسجل التجارب، ومنظومة التقييم. تتولى طبقة البيانات streaming shards ثابتة hashes، مع deterministic sampling قدر الإمكان. ويسجل كل batch provenance distributions حتى يمكن تفسير تغيرات loss أو ظهور قدرات غير متوقعة. لا يكفي حفظ اسم dataset لأن النسخة والفلتر والترتيب تؤثر في النتيجة.

في 1B يمكن البدء بـdata parallel وFSDP أو ZeRO حسب المنصة، مع mixed precision وgradient accumulation. في 9B تصبح sharding وactivation checkpointing وsequence parallelism ومراقبة communication overhead عناصر مركزية. لكن اختيار الإطار التشغيلي لا يسبق benchmark مصغرًا يقيس throughput وMFU والاستقرار على العتاد المتاح. الهدف هو أقل تعقيد يحقق الاستفادة المطلوبة، لا أكثر stack حداثة.

تراقب لوحة التدريب: training/validation loss بحسب اللغة والمجال، learning-rate ratio، update norm، gradient norm، overflow، data stalls، tokens/sec، نسبة entropy، padding، وmemorization probes. وتوضع triggers: إذا قفز loss في bucket محدد، يعزل shard؛ إذا تدهورت العربية مع استمرار loss العام، لا يُقبل المتوسط؛ إذا ظهرت canary extraction، توقف المرحلة وتراجع إزالة التكرار.

تستخدم checkpoints ثلاثية: milestone checkpoints، frequent recovery checkpoints للتقييم، وgolden checkpoints لا تمحى قبل قرار الإصدار. كل checkpoint يرتبط بـconfig وgit commit وdataset manifest وrandom seeds. لا تُجرى preference أو RL على checkpoint غير موثق، لأن post-training قد يخفي مشكلة base ويجعل إرجاع السبب مستحيلًا.

يقترح نظام «التجربة ذات التغيير الواحد» في مراحل التشخيص: لا تغير tokenizer والخلطة والoptimizer معًا. بعد استقرار الفهم، يمكن تنفيذ factorial designs محدودة. تُحسب intervals عبر عدة seeds في proxy scales، ثم يستخدم seed واحد أو عدد أقل في التشغيل الكبير مع checkpoints متكررة، مع التصريح بأن عدم اليقين أكبر. ويجب الاحتفاظ بحساب تكلفة التجربة الفاشلة ضمن ميزانية البحث لا اعتبارها حادثًا خارج الخطة.

38.3 تشغيل 70 HyperSkills وHyperLoops

الحزمة الحالية التي تضم 35 HyperSkills و35 HyperLoops تُعامل كبذرة registry، لا كقدرة مدمجة تلقائيًا في الأوزان. يُمنح كل HyperSkill معرفًا، إصدارًا، مدخلات typed، شروط استدعاء، أمثلة نجاح، verifier، counterexamples، وقياس تكلفة. ويُمنح كل HyperLoop state schema، حد iterations، شرط rollback، plateau، ومالك قرار. المهارة التي لا تملك اختبارًا ليست مهارة تشغيلية بل prompt محفوظ.

تقسم المهارات إلى سبع عائلات: context/memory، tool use، verification، reasoning، data engineering، evaluation/deployment، resilience/safety. وتقسم الحلقات إلى learn-، deploy، distill، repair، test، train، discover، from-incident. عند تنفيذ مهمة، لا يحمل النموذج الملفات السبعين كلها في السياق؛ يستدعي router قائمة مختصرة اعتمادًا على task graph. هذا يمنع context pollution ويجعل أثر كل skill قابلًا للقياس.

خـــــــ

38.4 الضغط والتقطير والنشر متعدد الطبقات

يُبنى MOUSSAIF9B بوصفه عائلة نشر لا checkpoint واحدًا. النسخة 1B تصلح للـedge routing والمهام المتخصصة والاستخدام المحلي. النسخة 9B تصلح لخادم متوسط أو تشغيل كمي على عتاد أقوى. ويمكن إنتاج نسخ quantized بأربعة أو ثمانية bits، لكن كل ضغط يحتاج إعادة تقييم للرياضيات والكود والعربية وtool schemas؛ انخفاض perplexity الطفيف لا يكشف دائمًا فشل function arguments أو الأرقام.

التقطير ثلاثة أنواع: knowledge distillation من logits أو outputs؛ reasoning distillation من trajectories نجت من verifiers؛ وpolicy distillation من routing/actions. الأخطر هو تقطير أخطاء teacher. لذلك لا تدخل trajectory لأنها صادرة عن نموذج أكبر؛ تدخل إذا نجحت execution أو الأدلة أو consensus. يُفضل أن يتعلم 1B متى يصعد المهمة إلى 9B بدل محاكاة قدرة لا يملكها.

تقترح بنية serving هرمية: classifier خفيف يحدد risk/difficulty؛ 1B يجيب المسائل المباشرة ويستعمل retrieval؛ 9B يتولى المسائل المركبة؛ verifier أو tools تحسم القابل للتحقق؛ والإنسان يتولى high-impact authorization. يتيح ذلك خفض cost من دون فرض أن كل سؤال يحتاج 9B. ويجب قياس routing regret: الحالات التي اختار فيها النظام مستوى أقل فأخطأ، أو مستوى أعلى بلا فائدة.

يبدأ النشر canary بنسبة صغيرة، مع shadow evaluation مقابل baseline. تسجل user، tool errors، latency percentiles، memory conflicts، abstention quality، corrections، وincidents. توجد thresholds توقف تلقائيًا: ارتفاع hallucination، كشف بيانات، tool misuse، أو regression عربي. لا تُستخدم تفاعلات المستخدم للتدريب مباشرة؛ تمر privacy filtering وde-identification وموافقة وسياسة retention.

في البيئات المعزولة، تحفظ الأوزان والـKB والمهارات في طبقات مستقلة قابلة للإصدار والرجوع. هذا يسمح بتحديث حقيقة أو skill دون إعادة تدريب النموذج، ويسمح بتحديد مصدر الخطأ. وفي النشر المفتوح، تصدر model card وsystem card وdata statement وevaluation packet، مع منع تسمية النسخة 9B إذا لم يطابق العدد الفعلي.

38.5 المنهج الإحصائي وإثبات التحسن السببي

أكبر خطر في مشروع واسع المكونات هو نسبة كل تحسن إلى النظرية المرغوبة. لذلك تُسجل الفرضيات قبل التجربة ويحدد primary metric وsecondary metrics. تستخدم المقارنات paired عندما تكون المهام نفسها، وتعرض intervals لا point estimates فقط. في benchmarks صغيرة مثل GPQA يجب تجنب الاستنتاجات الكبيرة من فروق نقاط قليلة، ويستفاد من bootstrap أو نماذج binomial مناسبة.

تُبنى مصفوفة ablation تدريجية: B0 Transformer baseline؛ B1 بيانات منقاة؛ B2 reasoning SFT؛ B3 verifier؛ B4 tools/KB؛ B5 MCD difference data؛ B6 Q-MCD question routing؛ B7 HAKIM integrated loop. وتُثبت compute budgets أو تسجل بوضوح. إذا احتاج B7 ضعف tokens، فلا تنسب الزيادة كلها إلى architecture. تُحسب incremental gain وinteraction effects.

تختبر الجدة عبر ثلاث طبقات. **Face validity**: هل المفهوم معرف بوضوح؟ **Construct validity**: هل المقياس يعكس الفرق الحاكمي أو المرونة فعلًا؟ **Predictive validity**: هل يتنبأ بأداء جديد؟ يشارك خبراء لا يعرفون شرط النموذج في وسم عينات، وتقاس inter-rater reliability. إذا لم يتفق الخبراء على الفرق الحاكمي، يحتاج المفهوم إلى إعادة ضبط قبل استخدامه reward.

توجد مجموعة adversarial preregistered لا يراها مطورو البيانات، ومجموعة temporal بعد cutoff، ومجموعة cross-lingual isomorphic. وتنفذ evaluator swaps: محققون مختلفون، تنفيذ مباشر، ومراجعة بشرية. النتائج التي تظهر مع judge واحد فقط تُخفض رتبتها.

قرار الترقية من 1B إلى 9B لا يعتمد على score مطلق، بل على ثلاثة شروط: ثبات ترتيب الخلطات عبر proxies بدرجة كافية، ظهور نقل حقيقي لا contamination، وتحديد bottleneck يُتوقع أن يحله الحجم. إذا كان bottleneck retrieval أو tool schema، فقد يكون إصلاح النظام أرخص من زيادة المعلمات. هذا المبدأ يحمي المشروع من تحويل 9B إلى غاية مستقلة عن الدليل.

38.6 مقارنة مرجعية مع نماذج الحجم القريب

المقارنة المرجعية لا تهدف إلى ادعاء التفوق قبل التدريب، بل إلى تحديد ما يجب تعلمه من المشاريع المنشورة. TinyLlama يثبت إمكان تدريب 1.1B على حجم tokens كبير مع بنية معروفة [4]. SmolLM2 يركز على المنهج data-centric في Phi-3 .1.7B [5] يبرز التنقية والبيانات الاصطناعية في نموذج صغير نسبيًا [6]. وفي نطاق 9B، توضح Gemma 2 أثر GQA وlocal-global attention ووصفة post-training [7]، بينما يقدم Qwen3 تدرج أحجام ودمج thinking/non-thinking و[8] reasoning RL. وتعرض Llama 3 أهمية الاختبارات الواسعة والتعدد اللغوي والأدوات [9].

لا يمكن مقارنة scores مباشرة بسبب اختلاف البيانات وcutoff وprompts وtools والتلوث. لذلك تُستخدم هذه النماذج كـdesign references. معيار MOUSSAIF9B هو أن يقدم شفافية أعلى في lineage وablation، وأن يركز على العربية العلمية والفرنسية التقنية، وأن يختبر الفروق الحاكمة والذاكرة والأثر. قد لا يتفوق في متوسط المعرفة، لكنه يجب أن يبرر وجوده بقدرة أو علم مفتوح لا توفره النماذج العامة.

ما لا يجوز استنتاجه	الدروس للمشروع	الحجم التقريبي	المرجع
أن 1B يساوي نماذج كبيرة عمومًا	التدريب الطويل والبنية الفعالة	1.1B	TinyLlama
أن وصفته تنقل حرفيًا للعربية	البيانات والمنهج التجريبي	1.7B	SmolLM2
أن benchmark parity يعني قدرة عامة	التنقية وsynthetic data	3.8B	Phi-3-mini
أن نفس الخلطة متاحة أو مثلى	GQA وattention عملي وpost-training	9B	Gemma 2
أن كل تفاصيل البيانات منشورة	thinking fusion وRL والتعدد اللغوي	8B قريب	Qwen3
أن الحجم القريب يعني كلفة تدريب قريبة	scale discipline والتقييم والأدوات	8B قريب	Llama 3

38.7 شجرة القرار: التدريب من الصفر أم التكييف؟

قرار التدريب من الصفر ليس تقنيًا فقط؛ هو قرار علمي وتمويلي. يُختار from-scratch عندما تكون هوية tokenizer والخلطة والمعمارية نفسها موضوع البحث، وتتوفر قدرة على تشغيل proxies ثم تدريب طويل وتقييم مستقل. ميزته التحكم الكامل والشفافية؛ مخاطره كلفة ضخمة واحتمال إنتاج نموذج أضعف من bases مفتوحة بسبب نقص tokens أو الخبرة التشغيلية.

يُختار continued pretraining عندما يوجد base قريب في الحجم والبنية والترخيص، ويكون الهدف رفع العربية والفرنسية والعلوم والكود أو إدخال corpora Moussaif-native. يجب قياس catastrophic forgetting، وتغيير tokenizer بحذر؛ توسيع vocabulary قد يتطلب initialization وتدريب embeddings وطبقات مختارة. هذا المسار غالبًا أكثر واقعية للوصول إلى نموذج 9B ذي قيمة عملية.

يُختار post-training-only عندما تكون القدرة الأساسية قوية ويتركز الفرق في safety، tools، reasoning، والهوية اللغوية. لكنه لا يصلح لإصلاح نقص جذري في tokenizer أو knowledge representation. أما PEFT/LoRA فيناسب التجارب والتخصصات والنسخ المتعددة، لكنه لا ينبغي أن يُعرض كتدريب نموذج تأسيسي جديد.

تقترح الورقة قرارًا مرحليًا: بناء 1B من الصفر لتملك pipeline ومعرفة سببية بالبيانات، بالتوازي تكييف base مفتوح قريب من 9B لاختبار النظام الكامل، ثم اتخاذ قرار 9B-from-scratch فقط إذا كشفت التجارب أن القيود ناتجة من base نفسه، لا من البيانات أو الأدوات أو التقييم. بهذه الشجرة يصبح اسم MOUSSAIF9B علامة منهجية يمكن تحقيقها تدريجيًا، بدل أن يكون التزامًا مكلفًا يسبق الدليل.

39. السلامة والتفويض والمرونة

السلامة في MOUSSAIF9B ليست مرشحًا بعد التوليد، بل متغيرًا في التخطيط. كل action يصنف بحسب الضرر المحتمل، reversibility، الخصوصية، والسلطة. الأفعال عالية الأثر لا تُنفذ تلقائيًا. وتدرب النماذج على الفرق بين الاقتراح والتنفيذ، وعلى عدم الادعاء بأن tool نجحت إذا لم يصل observation موثوق.

تُجرى failure injection في training/evaluation: مصادر متناقضة، وثيقة تحاول تغيير التعليمات، أداة تعيد schema صحيحًا وبيانات خاطئة، memory stale، context truncated، وbudget منخفض. مسار الإصلاح: Detect→Localize→Classify→Fallback→Minimal Rerun→Verify→Log. ولا تعني self-repair السماح بتغيير القواعد العليا أو permissions.

تُقاس السلامة مع helpfulness لتجنب over-refusal، لكن لا يُختزل التوازن في AUC واحدة. تنشأ مصفوفة intent×capability×context×action. كما تُفصل سلامة العربية عن ترجمة safety prompts الإنجليزية، لأن الصياغة والثقافة واللهجة تغير الفهم. ويجب وجود native red teams.

40. محكمة الهدم: اثنا عشر اعتراضًا قويًا

1. إعادة تسمية معروفة: MCD وHAKIM قد يكونان تجميعًا لـmetacognition وReAct وverification. الحكم والتعديل: يُقبل الاعتراض جزئيًا؛ الجدة يجب إثباتها في وحدة الفرق الحاكمي وablation.

2. لا دليل على **AGI**: كل المكونات تحسن LLM لكنها لا تثبت عمومية مفتوحة. الحكم والتعديل: خفض الادعاء إلى AGI-oriented research program.

3. قائمة 200 برنامج متضخمة: التقسيم قد يكرر نفس القدرة بأسماء مختلفة. الحكم والتعديل: ضغطها إلى 20 طبقة مع بطاقات سببية.

4. **1B** سقفه منخفض: قد لا يحمل معرفة وتجريدًا كافيين. الحكم والتعديل: يُستخدم كمختبر وrouter لا بديل مطلقًا لـ9B.

5. **9B** غير كافٍ لل**AGI**: الحجم لا يضمن ولا قد يكفي. الحكم والتعديل: المشروع system-level ولا يحدد threshold سحريًا.

6. المقاييس ذاتية: MCD وRAIS قد يتحولان إلى أرقام داخلية. الحكم والتعديل: نشر submetrics وreliability ومنع الرقم المنفرد.

7. المحكمة تعزز الإطالة: النقد المتكرر قد يرفع tokens بلا فائدة. الحكم والتعديل: utility-per-token وstop policies.

8. الـ**KB** نقطة هجوم: retrieval قد يحقن تعليمات أو معلومات فاسدة. الحكم والتعديل: isolation وprovenance وauthority separation.

9. **synthetic feedback** دائري: teachers والمحققون يشتركون في الأخطاء. الحكم والتعديل: تنويع النماذج وأدوات صلبة وعينات بشرية.

10. الـ**world-effect** غير قابل للتعميم: sandbox outcomes محدودة. الحكم والتعديل: سلم بيئات وتقييمات خارجية تدريجية.

11. التعدد اللغوي يبدد السعة: 1B قد يعاني interference بين اللغات. الحكم والتعديل: language balancing وtokenizer واختبارات وتخصص adapters.

12. المشروع أكبر من الموارد: 9B from scratch مكلف جدًا. الحكم والتعديل: مسار متعدد السيناريوهات وcontinued pretraining.

41. النسخة المعدلة بعد الهدم

بعد المحكمة، تصبح الصياغة الأكثر صلابة: MOUSSAIF9B برنامج بحث وهندسة لنماذج صغيرة ومتوسطة عالية الرافعة، لا ادعاء AGI ولا 9B claim قبل تحقق الحجم. المئتا برنامج taxonomy قابل للضغط والتجريب، لا checklist يجب تنفيذه كله بالتساوي. MCD وQ-MCD وHAKIM وMICAGFI مفاهيم تنظيمية تُختبر سببيًا، وقد تبقى قيمتها في هندسة النظام حتى إن لم تنتج تمثيلًا داخليًا جديدًا.

النواة النهائية هي: بيانات ذات lineage، نموذج baseline قوي، verifiers، reasoning adaptive مستقلون، أدوات محكومة، KB ذات نزاهة، حلقات محدودة، ومقاييس انتقال وأثر. يُعطى 1B دورًا واضحًا في التجربة والedge والتقطير، ويُعطى 9B دورًا في التكامل. لا يُستخدم IQ إلا كمؤشر هندسي مركب مصحوب بالمتجه والحدود.

ما بقي ناقصًا هو البيانات الفعلية، ميزانية الحساب، التجارب، وتحديد benchmark عربي خاص بالفرق الحاكمي. لذلك فإن أقرب مساهمة علمية قابلة للنشر ليست إعلان النموذج، بل ثلاث أوراق: data constitution and proxy scaling؛ sovereign difference benchmark؛ وfalsification-gated skills for small agents.

42. برنامج سنة واحدة

الأشهر 1-2: دستور البيانات، benchmark firewall، tokenizer study، وبناء 50M proxies. الأشهر 3-4: تدريب 150M/300M على خلطات متنافسة وتطوير Arabic reasoning suite. الأشهر 5-7: 1B MVP على 100-300B token، مع

سجلات كاملة. الشهر 8: SFT أساسي وأدوات. الشهر 9: process verifier وRLVR محدود. الشهر 10: KB-as-OS وHyperSkills gates. الشهر 11: red-team ومحكمة الهدم. الشهر 12: إصدار بحثي أو rollback مع تقرير سلبي صريح.

أول سؤال حاسم: هل تضيف بيانات الفرق الحاكمي تحسنًا في انتقال القرار عند تثبيت الحجم والحساب؟ أول أداة: مصفوفة البيانات-القدرة. أول corpus خاص: definitions/examples/counterexamples/conflicts بثلاث لغات. أول benchmark: مهام متشاكلة تطلب اكتشاف الفرق الذي يغير الحكم. أول اعتراض يُختبر: هل MCD مجرد labels reasoning مألوفة؟

43. برنامج ثلاث سنوات وعشر سنوات

خلال ثلاث سنوات: بناء سلسلة 1B/3B/9B، إصدار corpus موثق، Arabic-French-English reasoning، verifier suite، agent sandbox، benchmarks، ودراسات scaling خاصة بالرافعة المعرفية. ينبغي نشر النتائج السلبية وتكرار التجارب عبر seeds. شراكات الجامعة والحوسبة ضرورية للتحقق المستقل.

خلال عشر سنوات: تتحول المنظومة - إن نجحت - إلى مختبر لنماذج حاكمية متعددة المقاييس، مع KB علمية حية، بيئات world-effect، ومعايير مستقلة للانتقال والذاكرة والوكالة. يمكن فتح multimodal والروبوتيك بعد نضج النص والأداة، لا قبله. المدرسة العلمية لا تقوم على الاسم، بل على تراكم نتائج يمكن لخصم صارم إعادة إنتاجها أو هدمها.

الآفاق الاختراقية تشمل: تعلم representations للفروق الحاكمة؛ routing عصبي مرتبط بقيمة المعلومات؛ memory consolidation بين KB والأوزان؛ توليد verifiers تلقائيًا مع إثبات حدودهم؛ ومقاييس agency تقاوم التلوث. لكن كل أفق يبقى مشروطًا بألا تتحول الاستعارة الوعائية أو الحاكمية إلى بديل عن التجربة.

44. نواة قاعدة المعرفة المقترحة

الكيانات: Verifier، Evidence، Claim، SovereignQuestion، Difference، Capability، DatasetSlice، ModelVersion، ReleaseDecision، Incident، Metric، Experiment، MemoryRecord، HyperLoop، HyperSkill، Tool.

العلاقـات: DatasetSlice trains Capability؛ Difference changes Decision؛ SovereignQuestion discriminates Hypotheses؛ Claim supportedBy Evidence؛ Verifier tests Claim؛ HyperSkill derivedFrom Trajectories؛ HyperLoop improves Capability under Budget؛ MemoryRecord conflictsWith/updates Claim؛ Experiment evaluates Theory؛ Incident blocks Release.

القواعد: إذا غاب provenance يخفض KIGS؛ إذا اختلف verifiers في high-risk task لا ينفذ action؛ إذا لم ينجح skill في ثلاث عائلات مهام يبقى Candidate؛ إذا تجاوز loop budget أو plateau يتوقف؛ إذا فشل capability floor يرفض release؛ إذا ثبت soft contamination تعاد التجربة على procedural holdout.

الذاكرة التطويرية: تحفظ كل patch، objection، outcome، hypothesis، checkpoint، data hash، config، وdecision. لا تُمحى التجربة الفاشلة؛ تُربط بسبب الفشل حتى لا يعاد إنتاجه. وتصبح الورقة نفسها seed schema لا corpus مقدسًا.

45. سجل البناء المعرفي

بُنيت الورقة على ثلاثة افتراضات: أن المشروع ما يزال في طور التصميم، أن 1B هو الاحتمال الفعلي الراهن، وأن 9B هدف قابل للتعديل. اعتُبرت الأدبيات حول retrieval، reasoning supervision، small models، data curation، scaling، وtool use مادة صلبة نسبيًا. خُفضت عبارة AGI إلى اتجاه بحث، وخُفضت مقاييس MCD إلى أدوات تقديرية.

دُمجت البرامج المئتان في عشرين طبقة لمنع التكرار، وحُفظت وظائفها في مصفوفات. اختير مفهوم «الرافعة الحاكمية» لأنه يربط الحجم بالبيانات والسؤال والحساب والهدم والذاكرة والأثر. النماذج البديلة كانت: LLM محسن، system composite، وsovereign core؛ واعتمد نموذج أعلى يتيح الاختبار.

أضعف حلقة هي غياب evidence تجريبي خاص بالمفاهيم الجديدة. أقوى نقطة اختراق محتملة هي جعل الفرق الحاكمي وحدة labeling/routing/evaluation مشتركة. لتحويل العمل إلى ورقة محكمة يلزم: statistical، ablations، baseline، dataset، release artifacts، reporting، ومراجعة باحثين مستقلين. أول بحث تالٍ: Sovereign Difference Benchmark at 300M-1B Scale.

46. اختبار الجودة الداخلي

النتيجة قبل التحسين: 86/100. مواضع الضعف: احتمال تضخم المصطلحات، غياب تجارب، وخطر الخلط بين system intelligence وmodel intelligence. جرى التحسين عبر: فصل 1B/9B، تخفيض ادعاء AGI، ضغط 200 برنامج، إضافة نماذج متنافسة، ست نظريات قابلة للهدم، مقاييس وحدود، بروتوكول scaling، واعتراضات قوية.

النتيجة التقديرية بعد التحسين: 94/100 وفق rubric الورقة: حفظ المادة 10/10؛ الوضع الأنطولوجي 5/5؛ مراتب المعرفة 9/10؛ التصفية 9/10؛ المتغيرات 9/10؛ النماذج 9/10؛ الأصالة 13/15؛ قابلية الاختبار 9/10؛ الهدم 10/10؛ الأدوات 5/5؛ غياب الحشو والادعاء 6/5 غير مسموح، فيثبت البند عند 5/5. هذا التقييم ذاتي ويُدرج للشفافية لا كاعتماد خارجي.

47. الخاتمة التأسيسية: ماذا أصبح لدينا؟

أصبح لدينا تعريف منضبط لـMOUSSAIF9B: مشروع معماري يمكن أن يبدأ بنموذج فعلي يقارب 1B ويترقى إلى نموذج يقارب 9B، من دون خلط الاسم بالحجم أو الغاية بالإنجاز. وأصبح لدينا تفسير مركب للجودة: لا parameter count وحده ولا dataset list وحدها، بل رافعة تجمع الفرق الحاكمي والسؤال والتوجيه الوعائي والتحقق والذاكرة والأثر.

أصبحت المئتا برنامج taxonomy تشغيلية في عشرين طبقة، وأصبح مسار التدريب قابلًا للتجزئة إلى proxies و1B MVP و1B طويل التدريب و9B. وأصبحت مفاهيم Moussaif خاضعة لـablation ومحكمة هدم بدل تقديمها كحقائق. وتولدت ست نظريات، وسبعة مقاييس، وثماني عشرة فرضية، وتسعة تنبؤات، وعشر أدوات، ونواة KB.

الحد النهائي واضح: هذه الورقة لا تثبت AGI ولا تبني checkpoint. إنها تحول الطموح إلى برنامج يمكن أن يفشل بصورة مفيدة. نجاح MOUSSAIF9B لن يقاس بكثرة النصوص أو الأسماء، بل بقدرته على اكتشاف الفرق الذي يغير الحكم، اختيار السؤال والحساب المناسبين، الاستعانة بالذاكرة والأداة دون فقد الحاكمية، هدم نتيجته قبل الفعل، ثم تعلم مهارة قابلة للانتقال من أثر موثوق في العالم.

48. الملخص الشامل المحيط والهندسة المعرفية

تمثل MOUSSAIF9B في صورتها المنضبطة مشروعًا ذا مسارين متلازمين: مسار نموذج فعلي صغير نسبيًا في نطاق 1B يُستخدم لاختبار الفرضيات والهندسة والبيانات بأقل تكلفة ممكنة، ومسار نموذج مستهدف في نطاق 9B لا يبدأ إلا بعد نجاح الوصفة على المقاييس الأصغر. بهذه الثنائية ينفصل الاسم المرجعي للمشروع عن الادعاء العددي: لا تُسمى النسخة 9B من حيث الحجم إلا بعد تحقق عدد المعلمات وصدور بطاقة نموذج قابلة للتدقيق. أما قبل ذلك فالصيغة الدقيقة هي MOUSSAIF9B-1B أو MOUSSAIF9B Project / 1B Checkpoint.

الهندسة المعرفية المقترحة لا تعامل الذكاء بوصفه كثافة لغوية، بل بوصفه منظومة انتقال بين حالات معرفية: مدخل غير منظم؛ استخراج للفروق؛ سؤال حاكمي يحدد موضع الغموض؛ تمثيل منظم للعلاقات والقيود؛ توجيه وعائي للحساب؛ بناء مرشحات متعددة؛ تحقق وهدم؛ فعل أو جواب محدود التفويض؛ ثم ذاكرة إعادة بناء تحفظ ما ثبت وتفصل بينه وبين المؤقت أو الفرضي. بهذا المعنى تصبح MCD و-Q MCD وHAKIM-MCD وMICAGFI طبقات هندسة قابلة للفصل والاختبار، لا أسماءً يُفترض تفوقها مسبقًا.

تتكون المنظومة من أربعة أصول مترابطة. الأصل الأول هو النموذج الأساسي Transformer بمواصفات مضبوطة لكل حجم، tokenizer عربي-إنجليزي-فرنسي-برمجي، سياق يتدرج بدل فرض نافذة طويلة منذ البداية، وGQA لتقليل كلفة KV cache. الأصل الثاني هو دستور البيانات الذي يربط كل شريحة corpus بالمصدر والترخيص والجودة والتلوث والمهارة المستهدفة. الأصل الثالث هو post-training متعدد المراحل: tool، preference optimization، verifier-guided training، process supervision، instruction SFT، memory tasks، trajectories، ومحاكم التفنيد. الأصل الرابع هو runtime system يضم retrieval، KB-as-OS، أدوات، logging، authorization، HyperLoops، HyperSkills، وتقييم أثر العالم.

تم ضغط 200 برنامج إلى بنية قابلة للإدارة: مئة برنامج pretraining تُجمع في عشر عائلات، ومئة برنامج post-training تُجمع في عشر عائلات أخرى. الضغط لا يحذف الأصل؛ بل يمنع تضخم pipeline. كل برنامج يتحول إلى بطاقة ذات هدف قدرة، اعتماديات، مصدر بيانات، طريقة توليد، metric، failure mode، verifier، وقرار إدراج أو استبعاد. ولا يُسمح بأن تدخل كل البرامج checkpoint واحدًا دون ablation، لأن التداخل غير المقاس قد يخلق نكوصًا أو تعليمات متعارضة أو تضخمًا بلا أثر.

تقدم النظريات الست برنامجًا سببيًا أوليًا. نظرية الرافعة المعرفية للمعلمة تفترض أن قيمة المعلمة تتحدد بجودة التكوين الذي تستوعبه لا بعددها المجرد. نظرية عرض نطاق الفرق الحاكمي تفترض أن الأداء العام يرتفع حين يستطيع النموذج تمثيل الفروق التي تغير القرار عبر مجالات جديدة. نظرية الوعائية الحسابية متعددة المديات تجعل الحساب موردًا يوجه حسب الصعوبة والقيمة والمخاطرة. نظرية تبلور المهارة المحكوم بالهدم لا تحول المسار الناجح إلى HyperSkill إلا بعد تكراره وانتقاله وصموده أمام verifier. نظرية الذاكرة المزدوجة تفصل بين معرفة موزعة في الأوزان وذاكرة خارجية قابلة للتحديث والتتبع. أما نظرية الوكالة العودية المحدودة بأثر العالم فتقيد التكرار بالميزانية والتفويض والتحسن المقاس وإمكانية الرجوع.

المسار التجريبي يبدأ بنماذج proxies صغيرة لاختبار tokenizer والخلطات وlosses والرؤية السياقية. ثم يبنى 1B MVP بوصفه منصة البحث المركزية. لا ينتقل المشروع إلى 9B إلا إذا ظهرت مكاسب ثابتة عبر seeds، ومهام غير مرئية، وتبديل اللغة، وتخفيض compute، وتعطيل الأدوات، مع غياب نكوصات حرجة في calibration أو safety. وعند الانتقال يُعاد ضبط العمق والعرض وعدد الرؤوس وFFN والتدريب الموزع، ولا يفترض أن وصفة 1B تنسخ حرفيًا إلى 9B.

التقييم متعدد المحاور ويمنع اختزال الذكاء في IQ-like score. يُستخدم متجه قدرات يضم المعرفة والاستدلال الرياضي والبرمجي والتجريد والتخطيط والأدوات والذاكرة والتعدد اللغوي والمعايرة والمرونة والكفاءة والانتقال. يمكن حساب مؤشر تركيبي لغرض داخلي، لكنه لا

ينشر منفردًا ولا يُقدّم بوصفه مكافئًا لذكاء بشري سريري. لكل نتيجة tool، prompt policy، budget، confidence interval، contamination status، access، وتكلفة لكل جواب صحيح. وتُفرض capability floors لا يمكن لمتوسط مرتفع أن يعوض سقوطها. تنتج الورقة كذلك نظامًا تشغيليًا لـ70 HyperSkills/HyperLoops. المهارة ليست ملف prompt فقط؛ بل عقد يحتوي schema، rollback، verifier، evidence، preconditions، وtransfer score. الحلقة ليست تكرارًا مفتوحًا؛ بل حالة مقيدة بعدد دورات، ميزانية token/tool، معيار تقدم، stop conditions، وذاكرة مضغوطة. يجري routing بينهما عبر task graph: تُختار المهارة الأدنى كلفة القادرة على تغيير الحالة، ثم تُستدعى حلقة فقط عندما يتطلب العجز تكرارًا قابلًا للقياس.

آفاق المشروع ثلاثة. في الأفق القريب، المطلوب هو checkpoint 1B موثق، benchmark للفروق الحاكمة، ودراسة ablation لكل مكوّن Moussaif-native. في الأفق المتوسط، يُبحث نقل المهارات بين المجالات، توجيه compute عبر learned router، وتجميع ذاكرة خارجية ذات provenance. في الأفق البعيد، يمكن دراسة world models، multimodality، والروبوتيك، لكن بعد إثبات أن الوكالة النصية والأدواتية لا تنهار تحت التوزيع الجديد. لا يتحول المشروع إلى مدرسة علمية إلا بتكرار مستقل، نشر نتائج سلبية، ومنافسة نماذج أبسط قد تفسر المكاسب نفسها.

الخلاصة الهندسية هي أن MOUSSAIF9B لا ينبغي أن يُبنى كـLLM أكبر يحمل أسماء أكثر، بل كنظام قياس وتعلم متدرج: يضغط المعرفة دون أن يمحو الخلاف، يوجه الحساب دون أن يخلق سلطة داخلية غير مضبوطة، يستخدم الذاكرة دون أن يلوث الحقيقة، ويهدم الاستنتاج قبل تحويله إلى فعل. الإنجاز الحاسم الأول ليس AGI؛ بل إثبات أن هذه الهندسة تمنح نموذج 1B زيادة قابلة لإعادة الإنتاج في الانتقال والمرونة وكفاءة الحساب مقارنة بخط أساس قوي. عندئذ فقط يصبح الانتقال إلى 9B استثمارًا علميًا، لا توسعًا اسميًا.

المراجع

[1] Kaplan, J. et al. (2020). Scaling Laws for Neural Language Models. arXiv:2001.08361.

[2] Hoffmann, J. et al. (2022). Training Compute-Optimal Large Language Models. arXiv:2203.15556.

[3] Sardana, N. et al. (2024). Beyond Chinchilla-Optimal: Accounting for Inference in Language Model Scaling Laws. arXiv:2401.00448.

[4] Zhang, P. et al. (2024). TinyLlama: An Open-Source Small Language Model. arXiv:2401.02385.

[5] Allal, L. B. et al. (2025). SmolLM2: When Smol Goes Big - Data-Centric Training of a Small Language Model. arXiv:2502.02737.

[6] Abdin, M. et al. (2024). Phi-3 Technical Report: A Highly Capable Language Model Locally on Your Phone. arXiv:2404.14219.

[7] Gemma Team (2024). Gemma 2: Improving Open Language Models at a Practical Size. arXiv:2408.00118.

[8] Yang, A. et al. (2025). Qwen3 Technical Report. arXiv:2505.09388.

[9] Grattafiori, A. et al. (2024). The Llama 3 Herd of Models. arXiv:2407.21783.

[10] Penedo, G. et al. (2024). The FineWeb Datasets: Decanting the Web for the Finest Text Data at Scale. arXiv:2406.17557.

Soldaini, L. et al. (2024). Dolma: an Open Corpus of Three Trillion Tokens for Language Model [11] .Pretraining Research. arXiv:2402.00159

Li, J. et al. (2024). DataComp-LM: In Search of the Next Generation of Training Sets for Language [12] .Models. arXiv:2406.11794

.Lee, K. et al. (2021). Deduplicating Training Data Makes Language Models Better. arXiv:2107.06499 [13]

Rafailov, R. et al. (2023). Direct Preference Optimization: Your Language Model is Secretly a Reward [14] .Model. arXiv:2305.18290

.Lightman, H. et al. (2023). Let's Verify Step by Step. arXiv:2305.20050 [15]

.Zelikman, E. et al. (2022). STaR: Bootstrapping Reasoning With Reasoning. arXiv:2203.14465 [16]

Guo, D. et al. (2025). DeepSeek-R1: Incentivizing Reasoning Capability in LLMs via Reinforcement [17] .Learning. arXiv:2501.12948

.Yao, S. et al. (2022). ReAct: Synergizing Reasoning and Acting in Language Models. arXiv:2210.03629 [18]

Schick, T. et al. (2023). Toolformer: Language Models Can Teach Themselves to Use Tools. [19] .arXiv:2302.04761

Borgeaud, S. et al. (2022). Improving Language Models by Retrieving from Trillions of Tokens. [20] .arXiv:2112.04426

Sengupta, N. et al. (2023). Jais and Jais-chat: Arabic-Centric Foundation and Instruction-Tuned Open [21] .Generative LLMs. arXiv:2308.16149

.Huang, H. et al. (2023). AceGPT, Localizing Large Language Models in Arabic. arXiv:2309.12053 [22]

.Bari, M. S. et al. (2024). ALLaM: Large Language Models for Arabic and English. arXiv:2407.15390 [23]

Ainslie, J. et al. (2023). GQA: Training Generalized Multi-Query Transformer Models from Multi-Head [24] .Checkpoints. arXiv:2305.13245

Peng, B. et al. (2023). YaRN: Efficient Context Window Extension of Large Language Models. [25] .arXiv:2309.00071

Chen, Y. et al. (2023). LongLoRA: Efficient Fine-tuning of Long-Context Large Language Models. [26] .arXiv:2309.12307

.Liang, P. et al. (2022). Holistic Evaluation of Language Models. arXiv:2211.09110 [27]

.Rein, D. et al. (2023). GPQA: A Graduate-Level Google-Proof Q&A Benchmark. arXiv:2311.12022 [28]

Jimenez, C. E. et al. (2023). SWE-bench: Can Language Models Resolve Real-World GitHub Issues? [29] .arXiv:2310.06770

Shao, Z. et al. (2024). DeepSeekMath: Pushing the Limits of Mathematical Reasoning in Open Language [30] .Models. arXiv:2402.03300

Zelikman, E. et al. (2024). Quiet-STaR: Language Models Can Teach Themselves to Think Before [31] .Speaking. arXiv:2403.09629

.Google DeepMind (2025). Gemma 3 Technical Report. arXiv:2503.19786 [32]

.Yang, Z. et al. (2026). Foundation-Sec-8B-Reasoning Technical Report. arXiv:2601.21051 [33]

الملحق أ: سجل 100 برنامج Pretraining

السجل يحفظ أسماء البرامج الأصلية؛ التنفيذ الفعلي يمر عبر الطبقات والمصفوفات والـablation، لا عبر تشغيل متساوٍ لكل بند.

ID	برنامج Pretraining	الفئة
1	Curated Universal Knowledge Pretraining	A
2	Foundational Textbook Curriculum	A
3	Encyclopedic Compression Training	A
4	Primary-Source Knowledge Training	A
5	Cross-Domain Concept Linking	A
6	Definitions–Examples–Counterexamples Corpus	A
7	Hierarchical Knowledge Reconstruction	A
8	Temporal Knowledge Sequencing	A
9	Causal Knowledge Corpus	A
10	Knowledge Conflict Mapping	A
11	High-Depth Arabic Pretraining	B
12	Arabic Morphological Reasoning	B
13	Classical Arabic Logic Corpus	B
14	English Scientific Precision	B
15	French Technical Corpus	B
16	Cross-Lingual Semantic Alignment	B
17	Translation Equivalence Training	B
18	Dialect-to-Formal Mapping	B
19	Rhetorical Intent Recognition	B
20	Terminology Preservation Training	B
21	Mathematical Foundations Curriculum	C
22	Proof-Structured Mathematical Corpus	C
23	Symbolic Manipulation Training	C
24	Mathematical Error Corpus	C

25	Dimensional Consistency Training	C
26	Scientific Model Comparison	C
27	Experimental Method Corpus	C
28	Statistics and Uncertainty Pretraining	C
29	Mechanistic Science Explanations	C
30	Scientific Falsification Corpus	C
31	Multi-Language Code Pretraining	D
32	Repository-Level Code Training	D
33	Code–Documentation Alignment	D
34	Bug–Fix Pair Training	D
35	Test-Driven Development Corpus	D
36	Systems Engineering Pretraining	D
37	API and Protocol Understanding	D
38	Secure Coding Corpus	D
39	Infrastructure-as-Code Training	D
40	Architecture Decision Records	D
41	Deductive Reasoning Corpus	E
42	Inductive Reasoning Corpus	E
43	Abductive Reasoning Corpus	E
44	Analogical Transfer Training	E
45	Counterfactual Reasoning	E
46	Constraint-Satisfaction Training	E
47	Multi-Hop Relational Reasoning	E
48	Argument Structure Pretraining	E
49	Fallacy Recognition Corpus	E
50	Reasoning Under Missing Information	E
51	Long-Context Document Training	F
52	Needle-with-Dependencies Training	F
53	Cross-Document Synthesis	F
54	Context Conflict Resolution	F
55	Context Compression Pretraining	F
56	Persistent Entity Tracking	F
57	State Reconstruction Training	F
58	Memory Relevance Prediction	F
59	Temporal Memory Partitioning	F
60	Recursive Summary Verification	F
61	Physical World Model Corpus	G
62	Social World Modeling	G

63	Economic Mechanism Training	G
64	Organizational Systems Corpus	G
65	Process Simulation Training	G
66	Goal–Subgoal Decomposition	G
67	Planning Under Resource Limits	G
68	Risk-Aware Planning Corpus	G
69	Dynamic Replanning Training	G
70	World-Effect Prediction	G
71	Source Reliability Modeling	H
72	Claim–Evidence Alignment	H
73	Epistemic Calibration Pretraining	H
74	Unanswerable Question Training	H
75	Contradiction Detection Corpus	H
76	Hallucination Boundary Training	H
77	Data Provenance Representation	H
78	Normative–Descriptive Separation	H
79	Fact–Inference–Hypothesis Labeling	H
80	Reversible Decision Training	H
81	Tool Schema Understanding	I
82	Search Query Construction	I
83	Retrieval-Augmented Pretraining	I
84	Calculator and Symbolic Tool Use	I
85	Code Execution Awareness	I
86	Browser Navigation Corpus	I
87	Multi-Tool Dependency Planning	I
88	Tool Failure Recovery	I
89	Cost-Aware Tool Routing	I
90	Human-Approval Boundary Modeling	I
91	MCD Difference Extraction Corpus	J
92	Q-MCD Sovereign Question Training	J
93	HAKIM-MCD Pipeline Pretraining	J
94	Vascular Compute Routing	J
95	ROFSC Synthetic Compression	J
96	Unified Sovereign Context Network	J
97	Knowledge Vessel Training	J
98	HyperSkill Induction Corpus	J
99	Bounded HyperLoop Pretraining	J
100	MICAGFI Meta-Architecture Corpus	J

الملحق ب: سجل 100 برنامج Post-training

السجل يحفظ أسماء البرامج الأصلية؛ كل برنامج يحتاج بطاقة قدرة وبيانات واختبار قبل اعتماده.

ID	برنامج Post-training	الفئة
101	Instruction Following SFT	K
102	Constraint-Preserving Responses	K
103	Ambiguity Resolution Training	K
104	User Intent Decomposition	K
105	Structured Output Tuning	K
106	Concise-to-Deep Response Control	K
107	Style Conditioning Training	K
108	Negative Instruction Robustness	K
109	Multi-Objective Instruction Tuning	K
110	Response Completion Discipline	K
111	Process-Supervised Reasoning	L
112	Outcome Verification Training	L
113	Self-Consistency Distillation	L
114	Verifier-Guided Reasoning	L
115	Counterexample Search Training	L
116	Assumption Audit Training	L
117	Reasoning Depth Routing	L
118	Stop-When-Solved Training	L
119	Alternative Hypothesis Ranking	L
120	Judgment Calibration DPO	L
121	Function-Calling SFT	M
122	Tool Selection Preference Training	M
123	Tool-Free vs Tool-Required Classifier	M
124	Search–Read–Verify Loop Training	M
125	Agent Task Decomposition	M
126	Subagent Delegation Training	M
127	Subagent Result Arbitration	M
128	Parallel Tool Orchestration	M
129	Sequential Dependency Execution	M
130	Tool Budget Optimization	M
131	Long-Conversation State Tuning	N
132	Preference Memory Classification	N
133	Memory Write Decision Training	N

134	Memory Conflict Resolution	N
135	Project State Continuation	N
136	Context Priority Alignment	N
137	Contextual Identity Tracking	N
138	Semantic Cache Utilization	N
139	Knowledge Refresh Detection	N
140	Self-Reconstruction Memory Training	N
141	Research Question Generation	O
142	Literature Gap Detection	O
143	Hypothesis Formation Training	O
144	Methodology Design SFT	O
145	Evidence Hierarchy Training	O
146	Citation Entailment Verification	O
147	Experimental Critique Training	O
148	Theory Construction Training	O
149	Theory Comparison Court	O
150	Research Synthesis without Collapse	O
151	Repository Repair SFT	P
152	Code Review Preference Training	P
153	Patch Minimality Training	P
154	Execution-Verified Coding	P
155	Environment-Aware Generation	P
156	Deployment Planning Training	P
157	Observability and Logging Tuning	P
158	Failure Diagnosis Training	P
159	Performance Optimization SFT	P
160	Secure Deployment Court	P
161	Critique–Revise Training	Q
162	Independent Reviewer Training	Q
163	Rubric-Conditioned Revision	Q
164	Error Taxonomy Training	Q
165	Confidence Revision Training	Q
166	Contradiction Repair SFT	Q
167	Completeness Audit Training	Q
168	Overcompression Detection	Q
169	Redundancy Elimination Training	Q
170	Self-Improvement with Frozen Authority	Q
171	Constitutional Alignment Training	R

172	Authorization Boundary SFT	R
173	Reversible Action Preference	R
174	High-Stakes Verification Training	R
175	Privacy-Preserving Reasoning	R
176	Prompt Injection Resistance	R
177	Data Exfiltration Defense	R
178	Capability Misuse Detection	R
179	Safe Failure Training	R
180	Human Escalation Policy	R
181	Arabic Deep-Reasoning SFT	S
182	Arabic Scientific Writing Training	S
183	Cross-Lingual Reasoning Preservation	S
184	Technical Terminology Code-Switching	S
185	Audience Adaptation Training	S
186	Pedagogical Scaffolding SFT	S
187	Dense Knowledge Writing	S
188	Executive Compression Training	S
189	Creative Conceptual Communication	S
190	Disagreement without Distortion	S
191	MCD Sovereign Difference Optimization	T
192	Q-MCD Question Elevation RL	T
193	HAKIM-MCD End-to-End Trajectories	T
194	Falsification Court Training	T
195	Vascular Compute Allocation RL	T
196	HyperSkill Creation and Reuse	T
197	Bounded HyperLoop Reinforcement	T
198	World-Effect Loop Training	T
199	Knowledge-Integrity AutoDeployment	T
200	MICAGFI Sovereign AGI Integration	T