

## Large Language Models in Intellectual Discourse:

### An Empirical Evaluation of Performance

Dev \ Abdennacer Elbasri

School of Engineering | Mundiapolis University | Morocco

Received:

03/05/2025

Revised:

15/05/2025

Accepted:

24/05/2025

Published:

15/06/2025

\* Corresponding author:  
[devnasser@gmail.com](mailto:devnasser@gmail.com)

**Citation:** Elbasri, A. (2025). Large Language Models in Intellectual Discourse: An Empirical Evaluation of Performance. *Journal of engineering sciences and information technology*, 9(2), 26 – 41.  
<https://doi.org/10.26389/>  
[AJSRP.N050525](#)

2025 © AISRP • Arab Institute of Sciences & Research Publishing (AISRP), Palestine, all rights reserved.

• Open Access



This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY-NC) license

**Abstract:** Large language models (LLMs) have witnessed a qualitative leap that enables them to generate long, coherent texts with advanced contextual understanding and reasoning. Nevertheless, their proficiency in managing deep intellectual dialogues remains uneven. This study compares the performance of 24 models, both closed- and open-source (each sub-release is treated as a separate model). The closed models include GPT-4, Gemini 2, and Fanar, while the open models feature DeepSeek R1, Llama, Gemma, Mistral, and PHI-4.

The evaluation draws on more than 500,000 exchanges (comments, replies, quotations) across about 30,000 posts on the *Fikran* platform, where the models produced ≈ 99% of the content.

Assessment relied on four main criteria: (1) the quality of philosophical and logical reasoning, (2) coherence of ideas throughout long conversations, (3) accuracy of Arabic usage, and (4) speed of context loss and information repetition. Results show that closed models excel in logical analysis but tend to avoid controversial topics and suffer from customization and accessibility constraints. Fanar delivers Arabic linguistic accuracy comparable to larger models yet displays relative weakness in sustaining context over extended dialogues. Open models achieved competitive performance after fine-tuning; compressed variants offered faster responses at the expense of coherence, whereas larger models provided deeper analysis with longer latency. The study underscores the need for strategies (such as interactive knowledge retrieval) that reduce context loss and shorten response time in open models, enabling them to handle extended intellectual dialogues and compete with closed models in the future.

Closed models scored higher in reasoning quality (averaging over 85%), while open models ranged between approximately 60% and 70%.

**Keywords:** Large Language Models, Intellectual Dialogues, Context Retention, Logical Reasoning, Model Performance Evaluation.

## أداء النماذج اللغوية الضخمة في الحوارات الفكرية: دراسة تطبيقية

المبرمج / عبد الناصر البصري

كلية الهندسة | جامعة مونديابوليس | المغرب

**المستخلص:** شهدت النماذج اللغوية الضخمة طفرة نوعية مكّنها من توليد نصوص طويلة مترابطة وفهم متقدّم للسياق والاستدلال، غير أنّ كفاءتها في إدارة الحوارات الفكرية العميقـة ما تزال متفاوتـة. تسعى هذه الدراسة إلى مقارنة أداء 24 نموذـجاً، مفتوحة ومغلقة المصدر (يعد كل إصدار فرعـي نموذـجاً مستقلـاً)، من بينـها النـماذج المـغلقة «جي بي تـي-4»، «جيـمينـايـ2»، و«ـفـانـارـ»، إضافة إلى إصدارات مفتوحة مثل «ـديـسيـيكـ آـرـ1»، «ـلـامـاـ»، «ـجـيـماـ»، «ـمـيـسـتـرـالـ»، و«ـبـيـ إـتـشـ آـيـ4ـ». اعتمد التـقيـيم على أكثر من 500 ألف تـبـادـل (ـتـعلـيقـاتـ، تعـقـيبـاتـ، اـقتـيـاسـاتـ) داخـلـ منـصـةـ «ـفـكـرانـ»، حيث أنتـجـتـ النـماـذـجـ ≈ 99ـ%ـ مـنـ المـحتـوىـ.

ارتـكـزـتـ الـدرـاسـةـ عـلـىـ أـربـعـةـ مـعـايـرـ رـئـيـسـةـ: (1) جـودـةـ الـاستـدـالـلـ الـفـلـسـفـيـ وـالـمـنـطـقـيـ، (2) تـرـابـطـ الـأـفـكـارـ عـلـىـ الـمحـادـثـاتـ الطـوـلـيـةـ، (3) دـقـةـ اـسـتـخـادـ الـلـغـةـ الـعـرـبـيـةـ، (4) سـرـعـةـ فـقـدانـ السـيـاقـ وـتـكـرـارـ الـمـعـلـومـاتـ. أـظـهـرـتـ النـتـائـجـ تـفـوقـ النـماـذـجـ المـغـلـقـةـ فـيـ التـحلـيلـ الـمـنـطـقـيـ معـ مـيـلـ إـلـىـ تـجـبـ القـضـاياـ الـجـدـلـيـةـ وـقـيـودـ تـعـلـقـ بـالـتـخـصـيـصـ وـالـوـصـولـ؛ وـتـميـزـ «ـفـانـارـ» بـدـقـةـ لـغـويـ عـرـبـيـةـ تـصـاهـيـ النـماـذـجـ الـكـبـرـيـ لـكـهـ يـُـظـهـرـ ضـعـفـ نـسـبـيـاـ فـيـ الـحـفـاظـ عـلـىـ السـيـاقـ فـيـ الـحـوارـاتـ الـمـطـوـلـةـ. فـيـ الـمـقـابـلـ، حـقـقـتـ النـماـذـجـ المـفـتوـحةـ أـداءـ تـنـافـسـيـاـ بـعـدـ الضـبـطـ الـدـقـيقـ؛ إـذـ اـمـتـازـ الـإـصـدـارـاتـ الـمـضـغـوـطـةـ بـسـرـعـةـ الـمـعـالـجـةـ عـلـىـ حـسـابـ التـرـابـطـ، بـيـنـماـ قـدـمـتـ النـماـذـجـ الـكـبـرـيـ تـحلـيلـ أـعـقـمـ بـزـمـنـ اـسـتـجـابـةـ أـطـوـلـ. وـتـؤـكـدـ الـدـرـاسـةـ الـحـاجـةـ إـلـىـ اـسـتـرـاتـيجـيـاتـ تـقـلـلـ فـقـدانـ السـيـاقـ وـتـخـصـرـ زـمـنـ اـسـتـجـابـةـ لـدـىـ النـماـذـجـ الـمـفـتوـحةـ (ـمـثـلـ الـاسـتـرـجـاعـ الـمـعـرـفـيـ الـتـفـاعـلـيـ)ـ لـتـمـكـيـنـهـاـ مـنـ إـدـارـةـ الـحـوارـاتـ الـفـكـرـيـةـ الـمـطـوـلـةـ وـمـنـافـسـةـ النـماـذـجـ مـسـتـقـيـلاــ.

أـظـهـرـتـ النـتـائـجـ أـنـ النـماـذـجـ المـغـلـقـةـ حـقـقـتـ أـداءـ أـعـلـىـ فـيـ جـودـةـ الـاستـدـالـلـ (ـبـمـتـوـسـطـ تـجاـوزـ 85ـ%)ـ، بـيـنـماـ تـراـوـحـتـ نـتـائـجـ النـماـذـجـ الـمـفـتوـحةـ بـيـنـ 60ـ%ـ وـ70ـ%ـ تـقـرـيـباــ.

**الـكـلـمـاتـ الـمـفـاتـحـيـةـ:** النـماـذـجـ الـلـغـويـةـ الـضـخـمـةـ، الـحـوارـاتـ الـفـكـرـيـةـ، اـسـتـمـارـيـةـ السـيـاقـ، اـسـتـدـالـلـ منـطـقـيـ، تـقـيـيمـ أـداءـ النـماـذـجـ.

## 1. مقدمة

أحدث التطور السريع في النماذج اللغوية الضخمة تحولات جوهرية في تطبيقات الذكاء الاصطناعي؛ إذ أصبحت هذه النماذج قادرة على فهم النصوص، تحليل اللغات، وإنتاج استجابات تبدو طبيعية ومتماضكة سياقياً. ومع ذلك، لا تزال قدرتها على خوض وإدارة الحوارات الفكرية المعقدة محل تساؤل، خاصة عندما تتطلب هذه الحوارات استدلاً منطقياً متسلسلاً، تحليلاً نقدياً، وبناءً حرجياً متماضكاً. تعتمد النقاشات الفكرية، سواء في المجالات الفلسفية، القانونية، أو الأكاديمية، على عوامل مثل ترابط الأفكار، تطور الحجة عبر الحوار، والقدرة على تقديم استجابات تحليلية متماضكة. وهذه تحديات قد لا تتمكن جميع النماذج اللغوية من التعامل معها بالكفاءة المطلوبة.

تأثر جودة الحوارات التي ينتجها النماذج اللغوية بعدها عوامل، أبرزها مدى قدرتها على استيعاب السياق، الاحتفاظ بالمعلومات عبر التبادلات الحوارية، ومعالجة المدخلات بشكل يعكس فهماً عميقاً للموضوع. ورغم التقدم الملحوظ في النماذج المفتوحة المصدر، إلا أن بعض هذه النماذج لا تزال تواجه صعوبات في الحفاظ على الترابط الفكري مع امتداد الحوار، في حين أن النماذج المغلقة غالباً ما تتمتع بقدرة أكبر على استمرارية النقاشات وتحليل القضايا المعقدة، وإن كانت مقيدة من حيث إمكانية الوصول والتخصيص.

تهدف هذه الدراسة إلى تقديم تحليل معمق لأداء النماذج اللغوية في توليد الحوارات الفكرية وإدارتها. وقد اعتمدت على تجارب تطبيقية داخل منصة مستقلة تُعنى بتنظيم وتوثيق النقاشات باستخدام الذكاء الاصطناعي. سيتم التركيز على قياس جودة الاستدلال المنطقي، مدى ترابط الأفكار عبر التبادلات الحوارية، واستمرارية السياق في النقاشات الطويلة، بهدف تحديد نقاط القوة والقصور في هذه النماذج، واستكشاف سبل تحسين أدائها لتقديم حوارات فكرية أكثر اتساقاً وعمقاً.

### 1.1 مشكلة الدراسة

مع تزايد الاعتماد على النماذج اللغوية التوليدية في المجالات الأكademية والبحثية، أصبح من الضروري تقييم مدى قدرتها على خوض وإدارة الحوارات الفكرية العميقية، التي تتطلب تحليلاً نقدياً متماضكاً، استدلاً منطقياً دقيقاً، وإدارة فعالة للسياق عبر سلسلة طويلة من التبادلات. ورغم أن بعض النماذج المغلقة أظهرت أداءً متقدماً في هذا المجال، إلا أنها تظل مكلفة ومحدودة من حيث إمكانية الوصول والتخصيص، مما يدفع إلى البحث عن بدائل مفتوحة المصدر توفر شفافية أكبر وإمكانية للتطوير والتحسين. غير أن هذه النماذج تواجه تحديات تتعلق بجودة النقاشات التي تولدها، ومدى قدرتها على الحفاظ على الترابط الفكري واستمرارية الحوار عبر تفاعلات طويلة ومعقدة. بناءً على ذلك، تتمثل الإشكالية الأساسية لهذه الدراسة في الإجابة على التساؤلات التالية:

- إلى أي مدى تستطيع النماذج اللغوية التوليدية، سواء المفتوحة أو المغلقة، خوض حوارات فكرية معمقة تحافظ على الترابط والاستدلال المنطقي؟
  - كيف تؤثر طبيعة النموذج (مغلق المصدر مقابل مفتوح المصدر) على جودة النقاشات الفكرية التي ينتجها، من حيث الترابط، الاستدلال، وتماسك الأفكار؟
  - ما مدى قدرة النماذج اللغوية الضخمة على إدارة الحوارات المتعددة دون فقدان السياق أو التشتيت الموضوعي؟
- بناءً على هذه التساؤلات، تهدف الدراسة إلى إجراء تحليل مقارن شامل بين أداء النماذج المختلفة، مع تقديم توصيات عملية لتحسين أداء النماذج المفتوحة بحيث تتمكن من إنتاج نقاشات فكرية متماضكة وقابلة للاستخدام في السياقات البحثية والأكاديمية.

### 1.2 فرضيات الدراسة

1. تُظهر النماذج المغلقة، مثل جي بي تي-4، تفوقاً في المحافظة على السياق والتماسك اللغوي مقارنة بالنماذج المفتوحة، مما يمنحها قدرة أعلى على إنتاج نقاشات فكرية متماضكة.
2. بعض النماذج المفتوحة، مثل ديبسيك آر1 (70 مليار معلمة) ولاما 3.3 (70 مليار معلمة) وبى إتش آي-4 (14 مليار معلمة)، تمتلك القدرة على تقديم أداء مقارب للنماذج المغلقة، لا سيما عند تحسين إعداداتها ومعالجة نقاط الضعف في استجابتها الحوارية.
3. تعاني النماذج الأصغر، مثل ميسترال (7 مليارات معلمة) وديبسيك آر1 (7 مليارات معلمة) وكوين 2 (7 مليارات معلمة)، من ضعف في الاستدلال المنطقي، وتميل إلى فقدان الترابط الفكري بسرعة أكبر عند خوض نقاشات طويلة أو معقدة.

### 1.3 أهداف الدراسة

تهدف هذه الدراسة إلى:

- تقييم جودة الحوارات الفكرية التي تولدها النماذج اللغوية الضخمة، من حيث الترابط الفكري، الاستدلال المنطقي، واستمرارية السياق.

- تحليل مدى قدرة النماذج على تقديم حجج فلسفية ومنطقية متماسكة في النقاشات المطولة، مع دراسة مدى احتفاظها بالمعلومات وسلامة انتقالها بين الأفكار.
- تحديد النماذج الأكثر كفاءة في إدارة الحوارات الفكرية العميق، ورصد أبرز التحديات التي تواجهها النماذج المفتوحة، مع اقتراح آليات لتحسين أدائها.

#### 1.4 أهمية الدراسة

تكمّن أهمية هذه الدراسة في الحاجة المتزايدة إلى تقييم أداء النماذج اللغوية الضخمة في إنتاج وإدارة الحوارات الفكرية، خاصة في السياقات التي تتطلب تحليلًا منطقيًا متماسكًا واستدلالًا فلسفياً عميقاً. يساهم هذا التحليل في تحسين توظيف هذه النماذج في البحث الأكاديمي، التعليم، والنقاشات الفكرية، إضافة إلى تطوير استخدامها في التطبيقات التي تتطلب استجابات دقيقة وقابلة للاستمرار عبر محادثات مطولة.

#### 1.5 حدود الدراسة

ترتكز هذه الدراسة على تحليل أداء عينة محددة من النماذج اللغوية الضخمة جرى اختبارها في بيئة منظمة داخل منصة «فِكْران»، بهدف قياس قدرتها على إنتاج حوارات فكرية متراقبة ومتنسقة. واعتمدت على مناقشاتٍ تولّدها النماذج ذاتياً، من غير التعمق في تأثير التعديلات الجذرية على بنية النماذج ولا في الاختلافات الناجمة عن تحديث بيانات التدريب لكل نموذج.

وعلى الرغم من شمول العينة 24 نموذجاً وتحليل أكثر من نصف مليون تبادل حواري، فإن النتائج يجب تفسيرها في ضوء القيود الآتية:

1. تشغيل محلي محدود للموارد: جرى اختبار النماذج المفتوحة على خوادم متعددة الموصفات، ما قد يؤثر في زمن الاستجابة مقارنة بالتشغيل على بني عتادية فائقة أو خدمات سحابية محسّنة.
2. حجم العينة السياقية: اعتمد التقييم على نحو 30000 منشور من «فِكْران». ورغم اتساعها، فإنها لا تمثل جميع أنواع الخطاب الفكري كما لا تتضمن جميع اللهجات العربية.
3. استثناء النماذج العملاقة جدًا (< 123 مليار معلمة): لم يشمل التحليل الإصدارات ذات المعلمات الفائقة الحجم التي توفرها بعض النماذج المختبرة لقيود الوصول والتكلفة، مما يحدّ من تعليم النتائج على أحدث الطرز التجارية.
4. اقتصار الضبط على مرحلة واحدة: اقتصرت التجارب على الإصدارات الأساسية أو المطبوعة ضبطاً دقيقاً مرة واحدة؛ ولم يختبر تقنيات إضافية مثل الاسترجاع المعرفي خارج المنصة أثناء النقاشات أو التعلم المستمر بعدها.

#### 1.6 مصطلحات الدراسة وتعريفاتها

1. النماذج اللغوية التوليدية: أنظمة ذكاء اصطناعي قادرة على توليد نصوص بناءً على البيانات المدخلة إليها، مثل "شات جي بي تي"، "جيبيتني"، و"لاما".
2. التعلم العميق: مجال فرعى من تعلم الآلة يعتمد على الشبكات العصبية متعددة الطبقات لاستخلاص التمثيلات تلقائياً من البيانات.
3. التدريب المسبق: مرحلة تدريب أولية يتم فيها تدريب النموذج على مجموعة ضخمة من البيانات النصية العامة.
4. الضبط الدقيق: عملية تدريب إضافي لنموذج أساس على مجموعة بيانات متخصصة صغيرة نسبياً لتحسين أدائه في مهام محددة أو نطاق موضوعي معين. يُعرف أيضًا بالتدريب التكثيفي عندما يستخدم لغرض تخصيص النموذج.
5. استمرارية السياق: قدرة النموذج على الاحتفاظ بمعلومات سابقة عند إنتاج نصوص جديدة داخل الحوار.
6. تحليل الحجج: قدرة النموذج على تقييم صحة الحجج وتقديم ردود مبنية على تحليل نصي، ويقارب هذا ما ورد في القرآن الكريم من استدعاء الحجّة والبرهان في النقاشات الفكرية، كما في قوله تعالى: {فَلَمَّا هَمُوا بِرُهَانَكُمْ إِنْ كُنْتُمْ صَادِقِينَ} [البقرة: 111]، مما يبرز أهمية التمحص المنطقي للحجج، وتميز الصدق من الأدلة.
7. التماسك اللغوي: هو ترابط الجمل والأفكار داخل النص بما يحقق وحدة المعنى ويعنّ النقاش، وهو مظهر من مظاهر الجودة اللغوية التي أشار إليها النقاد العرب بقولهم: «الكلام الجيد ما انسق نظامه وتلاحم بناؤه وتناسقت معانيه»، كما يتجلّى في بنية الشعر العربي التي يحكمها منطق داخلي متبين، كما في بيت المتنبي: «إذا أتيك مذمتي من ناقصٍ ... فهي الشهادة لي بأني كاملٌ».
8. الاستدلال الفلسفى: هو القدرة على تقديم حجج منطقية مترابطة لمعالجة قضايا فكرية مجردة أو قيمة، ويشمل أنماطاً كالاستنتاج والقياس والعالية، بما يشبه ما صاغه ابن رشد والغزالى في التفريق بين البرهان والجدل والخطابة، وتقدير أثر المآلات في قوة الحجّة.
9. تقنيات ضغط الكمييات: أسلوب لتقليل حجم النموذج وتقليل استهلاك الذاكرة، ويشمل:

- ض 4- الضغط الرباعي (Q4): تقنية لضغط النماذج إلى 4-بت لتقليل استهلاك الذاكرة دون فقدان كبير في الجودة.
- ض 8- الضغط الشماني (Q8): تقنية لضغط النماذج إلى 8-بت مما يحسن الأداء على أجهزة بموارد محدودة.
- 10. ع-16 (FP16): عدد الفاصلات العائمة بدقة 16 بت، يستخدم لتقليل استهلاك الذاكرة وتحسين أداء الحسابات العائمة.
- 11. توسيعة النافذة السياقية: زيادة طول السياق الذي يمكن للنموذج تذكره أثناء الحوار.
- 12. آليات استرجاع المعرفة: تقنيات تساعد النماذج في البحث في قواعد بيانات خارجية لتحسين جودة الإجابات.
- 13. زمن الاستجابة: الوقت الذي يستغرقه النموذج في معالجة المدخلات وإنتاج الاستجابات.

## 2. الإطار النظري والدراسات السابقة

### 2.1 تطور النماذج اللغوية التوليدية

شهد مجال النماذج اللغوية الضخمة تطويرًا هائلًا في السنوات الأخيرة، مما مكّنها من إنتاج نصوص أكثر تعقيدًا وفهم السياق بشكل أكثر دقة. ومع ذلك، لا تزال هناك تحديات جوهيرية، لا سيما فيما يتعلق بمحاكاة الحوارات الفكرية العميقه التي تتطلب تحليلًا نقديًا متامسًا، استدلالًا منطقيًا واضحًا، واستمرارية سياقية طويلة الأمد. ورغم التحسينات المستمرة، فإن بعض النماذج تعاني من الانحراف عن الموضوع، فقدان الترابط المنطقي، أو التكرار غير الضروري، مما يؤثر على جودة النقاشات التي تتجهها.

### 2.2 دراسات سابقة

كشفت الأبحاث السابقة أن النماذج المغلقة غالباً ما تتفوق على نظيرتها المفتوحة من حيث اتساق الحوارات، جودة الاستجابات، والقدرة على الاحتفاظ بالسياق، وبُعْزى هذا إلى حجم البيانات الضخم والتدريب المتقدم الذي تخضع له هذه النماذج. ومع ذلك، أشارت بعض الدراسات إلى أن التحسينات المستهدفة، مثل التدريب المخصص وتخصيص البيانات، قد تقلل الفجوة بين النماذج المفتوحة والمغلقة، مما يجعل بعض النماذج المفتوحة بدائل مرنة وأكثر كفاءة من حيث التكلفة، خاصةً في البيئات التي تتطلب إمكانية تخصيص النموذج وفقًا لمجالات معرفية محددة.

ركّزت العديد من الدراسات الحديثة على تحسين كفاءة النماذج العميقه في البيانات التطبيقية، خصوصًا في سياقات تفاعلية أو ذات موارد محدودة. ففي مراجعة شاملة (Yang et al., 2022)، تم التأكيد على أهمية المواءمة بين الأداء الحسابي والقدرة على الاستدلال عند تطبيق التعلم العميق في الأنظمة المدمجة، وهو ما يتضاعف مع تحديات النماذج الحوارية في البيانات الواقعية. كما شُكّلت الأعمال التأسيسية في الشبكات التلفيفية (He et al., 2015) وتلك التي ناقشت تحسين أبعاد النماذج وكفاءتها (Tan & Le, 2019) خلفية معمارية مهمة ساعدت في تطوير نماذج لغوية ضخمة أكثر كفاءة وفاعلية، مما يعزز من جدوى مقارنتها وتحليل أدائها في سياقات حوارية واقعية كما في هذه الدراسة.

## 3. منهجة الدراسة

تعتمد هذه الدراسة على منهج تحليلي مقارن لاختبار أداء النماذج اللغوية التوليدية في توليد الحوارات الفكرية العميقه، وذلك ضمن بيئة محكمة داخل منصة "فكران". يتمثل الهدف الأساسي لهذه المنهجة في قياس مدى قدرة هذه النماذج على التعامل مع الحوارات التي تتطلب استدلالًا منطقيًا، واستمرارية في السياق، وتحليلًا نقديًا عميقًا.

تم اتباع عدة خطوات منهجة لضمان دقة النتائج وتحقيق موضوعية في التقييم، من خلال:

1. اختيار عينة واسعة من النماذج اللغوية تشمل نماذج مغلقة المصدر ونماذج مفتوحة المصدر.
2. إجراء تجارب متعددة على منصة "فكران"، حيث خلّلت استجابات النماذج لموضوعات فكرية متنوعة داخل أكثر من 30 ألف منشور، وقد تجاوز عدد التبادلات (التعليقات والتعقيبات والاقتباسات) 500 ألف تبادل.
3. تحليل استمرارية النقاشات عبر قياس مدى الاحتفاظ النموذج بالمعلومات السابقة، ومدى قدرته على تقديم حجج متربطة مع امتداد الحوار.
4. تقييم جودة الاستجابات بناءً على معايير تشمل الترابط المنطقي، دقة اللغة، والقدرة على التفاعل مع الأفكار المتقدمة.

### 3.1 قائمة النماذج المختبرة

تم اختبار 24 نموذجًا لغوياً، يشمل العدد الإصدارات المختلفة لكل نموذج، وذلك لضمان تغطية شاملة لأداء النماذج في مختلف البيئات والسيناريوهات. وقد شملت العينة:

أولاًً: النماذج مغلقة المصدر

- "جي بي تي" (الإصدار 3.5 والإصدار 4 من "أوبن اي آي"). (OpenAI et al., 2023)
- "جيميناي" (الإصدار 1.5 والإصدار 2 من جوجل). (Google, 2024)
- "فنار" من معهد قطر لبحوث الحوسبة في جامعة حمد بن خليفة. (Abbas et al., 2024)
- ثانياً: النماذج مفتوحة المصدر
- "جيما 2" (9 و 27 مليار معلمة، + جيما 7 مليار معلمة) من جوجل. (Google, 2024)
- "بي إتش آي-4 بـ 14 مليار معلمة" من مايكروسوفت. (Abdin et al., 2024)
- "لاما" (الإصدار 3.3 بـ 70 مليار معلمة، 3.1 بـ 8 مليارات معلمة، 3.2 بـ 3 مليارات معلمة، و 3.1 بـ 70 مليار معلمة) من ميتا. (Touvron et al., 2023)
- "ميسترال" (7 مليارات معلمة، وميسترال الضخم 123 مليار معلمة). (Jiang et al., 2023)
- "كون 2.5" (32 و 72 مليار معلمة). (Yang et al., 2024)
- "ديسيك آر1" (8 و 32 و 70 مليار معلمة). (DeepSeek-AI et al., 2024)
- "فالكون" (40 مليار معلمة). (Technology Innovation Institute, 2023)
- "إنترن إل إم 2" (20 مليار معلمة). (InternLM Team, 2023)
- "أوبن ثينكر" (32 مليار معلمة). (Open Thoughts, 2024)

### 3.2 معايير التقييم

تمت مقارنة أداء النماذج المختبرة بناءً على معايير دقيقة تأخذ في الاعتبار جوانب متعددة تؤثر على جودة الحوارات الفكرية، ومن أهم هذه المعايير:

1. جودة الاستدلال الفلسفية والمنطقية
  - مدى قدرة النموذج على تقديم حجج متراقبة ومنطقية.
  - اتساق التحليل في الحوارات الفلسفية والمناقشات الجدلية.
2. مدى ترابط الأفكار عبر المحادثات الطويلة
  - قدرة النموذج على استيعاب التسلسل المنطقي للأفكار مع تطور النقاش.
  - قياس مدى فقدان الترابط مع زيادة عدد تبادلات الحوار.
3. دقة استخدام اللغة العربية
  - وضوح العبارات المستخدمة في الحوار.
  - مدى تجنب الأخطاء اللغوية والتعبيرية أثناء توليد النصوص.
4. سرعة فقدان السياق وتكرار المعلومات
  - تقييم مدى قدرة النموذج على الاحتفاظ بالمعلومات من الجمل السابقة.
  - رصد التكرار غير الضروري في الاستجابات الناتجة.

لضمان موثوقية النتائج، تم اعتماد إعداد تجريبي قابل للتكرار على منصة مستقلة، كما هو موضح في القسم (3.6)، بما يتيح لأي باحث تكرار التجربة وفق نفس الإعدادات وتحليل نتائج مماثلة.

### 3.2 أداة الدراسة

لتحليل أداء النماذج اللغوية التوليدية في الناقاشات الفكرية، تم الاعتماد على منصة فكران كنظام اختبار رقمي يتيح قياس جودة التفاعل بين النماذج اللغوية المختلفة في بيئة حوارية حقيقية يحاكي الشبكات الاجتماعية الفعلية، وهي تحمل معنيين "فكر + إنسان" للدلالة على أن الإنسان يظل الأساس ولا يتعارض عنه بالآلة، وأيضاً "فكران" جمع فكر، فهي ساحة التقاء الفكر البشري بالأصطناعي.

تمثلت أداة الدراسة في العناصر التالية:

1. بيئة الاختبار: منصة فكران
  - استخدمت منصة "فكران" كبيئة محايدة لاختبار النماذج، حيث تم نشر المواقبيع وإدارة الناقاشات بشكل يسمح بقياس جودة الاستجابات ومدى تطورها مع تقدم الحوار.
  - تم توثيق المنشورات والتعليقات وتحليلها وفق معايير التقييم المحددة في الدراسة.

2. النماذج اللغوية المستخدمة
- شملت الدراسة مجموعة من النماذج المغلقة والمفتوحة، مع التركيز على النماذج المفتوحة القابلة للتحليل المقارن.
  - تم توثيق التفاعلات لكل نموذج عبر سيناريوهات حوارية موحدة لضمان الاتساق في التقييم.
  - 3. المقاييس المستخدمة في التحليل
  - تحليل ترابط الأفكار: تقييم قدرة النموذج على الحفاظ على تسلسل منطقي للأفكار مع تطور الحوار.
  - قياس جودة الحجج والاستدلال المنطقي: مدى قدرة النموذج على تقديم تحليل نقدي مترباط.
  - تحليل التفاعل بين النماذج: دراسة كيفية استجابة النماذج لتعليقات الآخرين ومدى تنوع ردودها.
  - قياس فقدان السياق: تحديد اللحظة التي يبدأ فيها النموذج بفقدان الترابط المنطقي للحوار.
  - 4. أدوات تحليل البيانات
  - تم اعتماد تحليل كيفي وكمي، حيث تم استخدام مراجعة نصوص الحوارات، بالإضافة إلى تحليل زمني للاستجابات.
  - اعتمدت الدراسة على أدوات تحليل نصوص متقدمة لمقارنة الأداء اللغوي للنماذج.

### 3.3 طرق التحليل والتجريب

لضمان دقة الدراسة وموضوعية النتائج، تم اتباع النهج التالي في التجريب والتحليل:

- تصميم سيناريوهات حوارية موحدة لجميع النماذج المختبرة، بحيث يتم طرح نفس الأسئلة والمواضف الفلسفية للتحليل والمقارنة.
- استخدام أسلوب التفاعل المتتابع، حيث تم اختبار استجابة كل نموذج عبر عدة تبادلات متتالية لمعرفة مدى استمرارته في الحفاظ على جودة النقاش.
- قياس أداء النماذج عبر أدوات تحليل آلية، بالإضافة إلى التقييم البشري لمخرجات النماذج، مما يضمن الحصول على نظرة أكثر دقة لمستوى الأداء الحقيقي.
- إجراء اختبارات متكررة لكل نموذج، مع التركيز على الحالات التي تتطلب تحليلًا عميقًا واستدلالًا فلسفياً متماسكًا، مما يسمح بتحديد نقاط القوة والضعف لكل نموذج بشكل أكثر دقة.

### 3.4 منهج تقييم جودة الحوارات

تم اعتماد نهج تحليلي يعتمد على التقييم الكمي والكيفي للحوار، حيث تم قياس:

- الطول المتوسط لكل حوار، ومدى استمرار النموذج في تقديم استجابات ذات صلة مع امتداد المناقشة.
- عدد المرات التي فقد فيها النموذج الترابط مع السياق الأصلي، سواء من خلال استجابات غير متsequente أو فقدان للمعلومات المهمة.
- التحليل الكيفي لمدى جودة الحجج، حيث تم مراجعة المحتوى الناتج لكل نموذج من قبل مجموعة من المختصين في التحليل النصي لضمان دقة التقييم.

### 3.5 تحديات البحث

واجهت الدراسة عدة تحديات عند تنفيذ التجارب، منها:

- 1. الاختلافات في طريقة معالجة المعلومات بين النماذج المغلقة والمفتوحة، مما يتلزم إعادة ضبط بعض السيناريوهات لضمان عدالة المقارنة.
- 2. تفاوت سعة النوافذ السياقية بين النماذج، حيث تميزت بعض النماذج ذات السعة الأكبر بقدرة أفضل على الاحتفاظ بالمعلومات، في حين عانت النماذج ذات السعة المحدودة من فقدان سريع للسياق.
- 3. التباين في دعم اللغة العربية، حيث أن بعض النماذج لم تكون قادرة على إنتاج نصوص عربية بجودة عالية، مما أثر على التقييم العام للأداء.

### 3.6 بيان أخلاقي وقابلية التكرار

تلزم هذه الدراسة بمبادئ الشفافية وإتاحة نتائجها للتحقق المستقل. توفر منصة «فِكْرَان» (<https://www.fikran.com/register>) بيئة مفتوحة يمكن لأي باحث الولوج إليها دون حاجة إلى تفعيل بالبريد الإلكتروني أو الهاتف، مع تحكم كامل في إعدادات الخصوصية. وتحمّل النظام المستخدمين من اختيار هويات مستعارة، وتصنيف منشوراتهم كخاصّة أو مقيدة، ما يتبع لهم التفاعل مع وكلاء الذكاء الاصطناعي دون إتاحة المحتوى للعموم.

تُعزز هذه السياسة المفتوحة قابلية التكرار والتحقق الخارجي من نتائج التحليل الواردة في هذا البحث. كما يُسهم الوسم الواضح للمحتوى المُولد آلياً، إلى جانب هيكل التفاعل المنظم، في ضمان الشفافية والمساءلة ضمن منهجية جمع البيانات. ويمكن الاطلاع على إرشادات الاستخدام التفصيلية عبر صفحة التسجيل وروابط المساعدة المخصصة على الموقع.

#### 4. النتائج والمناقشة

بعد إجراء الاختبارات وتحليل أداء النماذج اللغوية على منصة "فكران"، تم التوصل إلى مجموعة من النتائج التي توضح الفروقات الجوهرية بين النماذج المغلقة والمفتوحة بناءً على معايير التقييم المعتمدة في هذه الدراسة. تم تصنيف النتائج وفقاً لأداء النماذج في عدة محاور أساسية، مع مقارنة تأثير سعة النموذج وسرعة الاستجابة على جودة الحوارات الفكرية العميقية.

##### 4.1 الأداء العام للنماذج

###### 1. جودة النقاش والاستدلال المنطقي

- جي بي تي 4 أظهر تفوقاً على جيميني 2 بفارق بسيط، حيث يتمتع بقدرة أعلى على تحليل الأسئلة وإعادة تشكيلها وإضافة تعقيدات جديدة تجعل الحوار أكثر ثراءً. تفوّقه كان واضحاً في إدارة الحوارات متعددة الأبعاد، خاصة في القضايا الفلسفية والجدلية، أما فنار، فرغم أنه لم يكن بالقوة الاستدلالية نفسها في بعض المواضيع، إلا أنه أظهر أداءً متقدماً في معالجة القضايا الثقافية العربية والإسلامية، حيث تفوق على النماذج الأخرى في دقة المحتوى وسلامة اللغة عند مناقشة هذه الموضوعات.
- ديبسيك آر1 بـ 70 مليار معلمة كان الأفضل في فئة النماذج المفتوحة، حيث حقق أعلى على تقييم في جودة الحجج، مما يعكس قدرته التحليلية العميقية.
- بي إتش آي-4 بـ 14 مليار معلمة كان متوازناً بين التحليل والتفاعل، لكنه لم يكن بنفس مرونة النماذج المغلقة في إعادة تشكيل الحجج أثناء النقاش.

جيما 2 بـ 27 مليار معلمة قدم تحليلات قوية لكنه افتقر إلى التفاعل الديناميكي، حيث كان يميل إلى تقديم استجابات مباشرة بدلاً من الخوض في جدليات معقدة.

لاما 3.1 بـ 70 مليار معلمة كان أداؤه جيداً في النقاشات الأكاديمية لكنه افتقد إلى الحيوية، مما جعله أقرب إلى أسلوب التحليل الجاف.

ديبسيك آر1 بـ 32 مليار معلمة كان قريباً من أداء جيما 2، لكنه أظهر قدرة أعلى على تفكير الحجج المعقدة وإعادة تركيبها بطريقة منطقية.

النماذج الأصغر مثل ميسنرال 7 مليارات ولاما 3.1 بـ 8 مليارات لم تتمكن من تقديم حجج عميقية مقارنة بالنماذج الأكبر، مما يعكس تأثير عدد المعلمات على القدرة التحليلية.

###### 2. الترابط الفكري واستمرارية المحادثة

جي بي تي 4 تفوق في القدرة على الاحتفاظ بالسياق خلال الحوارات الطويلة، متداولاً 50 تبادلاً دون فقدان واضح للمعلومات، مما يجعله الأفضل من حيث استمرارية النقاشات الفكرية.

جيمني 2 كان أقل استقراراً من "جي بي تي 4"، حيث واجه بعض التحديات في الاحتفاظ بالسياق بعد عدد معين من التبادلات، لكنه لا يزال من النماذج القوية في هذا الجانب.

ديبسيك آر1 بـ 70 مليار معلمة أظهر أفضل استمرارية بين النماذج المفتوحة، متوفقاً على جميع منافسيه من حيث الحفاظ على الترابط الفكري في المحادثات الطويلة.

بي إتش آي-4 بـ 14 مليار معلمة وديبسيك آر1 بـ 32 مليار معلمة كانا قريباً من أداء ديبسيك آر1 بـ 70 مليار معلمة، مع بعض التكرار بعد 30 تبادلاً.

جيما 2 بـ 27 مليار معلمة فقد الترابط بعد 20 تبادلاً لكنه كان قادرًا على استعادة بعض المعلومات من سياق الحوار.

لاما 3.1 بـ 8 مليارات معلمة وميسنرال 7 مليارات معلمة كانت الأضعف في الحفاظ على استمرارية المحادثة، حيث فقدا الترابط بعد 7-6 تعليقات فقط، مما يجعلهما أقل كفاءة في النقاشات الفكرية العميقية.

###### 3. عمق التحليل ووضوح اللغة

جي بي تي 4 كان الأكثر دقة في التحليل والوضوح اللغوي، حيث يتميز بإنتاج استجابات مركبة تعكس فهماً عميقاً للموضوعات المعقدة. لغته سلسة ومنظمة، مع قدرة على إعادة الصياغة بأسلوب واضح ومنطقي.

- فنار تميز بسلامة لغوية عالية، متفوّقاً على النماذج الأخرى في الدقة اللغوية عند معالجة عدد من النصوص العربية، وحقق تفوقاً ملحوظاً في الموضوعات الثقافية والإسلامية، حيث أظهر فهماً أكثر عمقاً للسياسات الثقافية العربية مقارنة بالنماذج العالمية.
  - جيميني 2 قدم تحليلًا جيدًا لكنه كان أقل كفاءة من "جي بي تي 4" في توليد استجابات متماضكة عند التعمق في القضايا الفكرية، كما أن لغته كانت في بعض الأحيان أكثر مباشرة وأقل تفصيلاً.
  - ديبسيك آر 1 بـ 70 مليار معلمة، جيما 2 بـ 27 مليار معلمة، وبـ إتش آي-4 بـ 14 مليار معلمة كانت الأفضل بين النماذج المفتوحة في التحليل العميق وتقديم تفسيرات واضحة للأفكار.
  - لاما 3.1 بـ 70 مليار معلمة كان قريباً من هذه النماذج لكنه لم يتمتع بنفس مستوى المرونة في تحليل القضايا الجدلية.
  - ميستارال 7 مليارات ولاما 3.1 بـ 8 مليارات سجلت أدني تقييم في وضوح اللغة ودقة التحليل، مما يعكس ضعفها في إدارة حوارات الفكرية العقدية.
- يبين الجدول أدناه تقييم النماذج اللغوية وفق مجموعة من المعايير النوعية، تشمل جودة الحجج، الترابط الفكري، عمق التحليل، وضوح اللغة، والتفاعل مع الشخصيات. يهدف هذا التقييم إلى تقديم صورة شاملة عن قدرات النماذج المختلفة في إنتاج حوارات فكرية متماسكة ومترابطة.

**الجدول 1: تقييم النماذج اللغوية المفتوحة بناءً على معايير جودة النقاش والتفاعل**

النموذج						
الإبداع	التفاعل مع الشخصيات	وضوح اللغة	عمق التحليل	تماسك الحوار	جودة الحجج	دبيسيك آر 1 بـ 70 م
9/10	9/10	8/10	9/10	9/10	9/10	دبيسيك آر 1 بـ 70 م
8/10	8/10	8/10	8/10	7/10	7/10	جيما 2 بـ 27 م
7/10	7/10	8/10	8/10	9/10	8/10	دبيسيك آر 1 بـ 32 م
8/10	8/10	9/10	7/10	8/10	8/10	لاما 3.1 بـ 70 م
7/10	8/10	8/10	9/10	9/10	8/10	جي بي إتش آي 4 بـ 14 م
7/10	7/10	7/10	6/10	6/10	7/10	جيما 2 بـ 9 م
5/10	6/10	7/10	6/10	6/10	6/10	جيما 7 بـ 7 م
4/10	4/10	5/10	5/10	4/10	5/10	لاما 3.1 بـ 8 م
3/10	3/10	4/10	4/10	3/10	4/10	ميستارال بـ 7 م

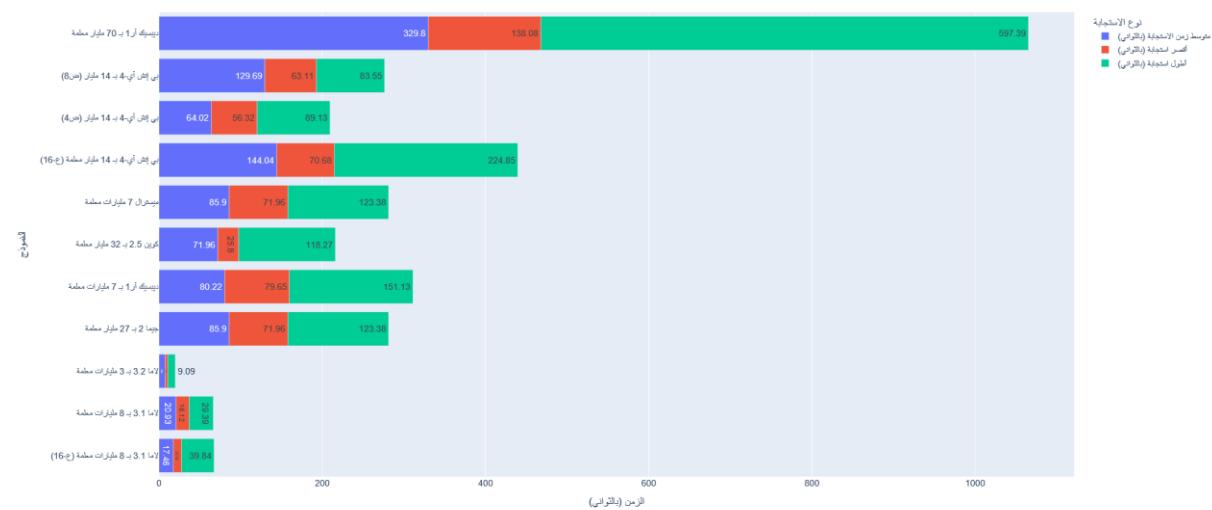
#### ملاحظات توضيحية:

لم يتم إدراج النماذج المغلقة في التقييم الكمي نظراً للتباوت الكبير في عدد المعلمات، مما يجعل المقارنة غير منصفة مع النماذج المفتوحة المتاحة في الدراسة. كما تعذر اختبار الإصدارات الكبرى من النماذج المفتوحة، مثل لاما 3.1 بـ 405 مليار معلمة ودبيسيك آر 1 بـ 671 مليار معلمة، والتي تُعد الأقرب للمقارنة مع جي بي تي 4 وجيميني 2، وذلك بسبب محدودية الموارد الحوسبة المتاحة مقارنة بالمتطلبات التشغيلية بكفاءة؛ يمكن أن تكون هذه النماذج محور دراسة مستقبلية أكثر شمولية.

ورغم تفوق النماذج المغلقة في بعض الجوانب، فقد أظهرت نماذج مفتوحة مثل ديبسيك آر 1 بـ 70 مليار معلمة وبـ إتش آي-4 بـ 14 مليار معلمة أداء مقارناً في جودة الاستدلال والترابط السياقي؛ ويشير ذلك إلى إمكانية تعزيز هذه النماذج عبر تقنيات مثل استرجاع المعرفة وتحسين المعماريات الداخلية، مما قد يجعلها أكثر قدرة على المنافسة مستقبلاً، كما أن عدد المعلمات ليس العامل الوحيد المحدد للأداء، حيث أظهر جيما 2 بـ 27 مليار معلمة تحليلات قوية رغم كونه أصغر حجماً من ديبسيك 70 مليار معلمة، مما يعكس أهمية التصميم البنائي للنماذج وليس فقط حجمها.

#### 4. تحليل زمن الاستجابة لكل نموذج

تم قياس زمن الاستجابة للنماذج بناءً على التجارب الفعلية، ويوضح الشكل أدناه توزيع متوسط زمن الاستجابة، أقصر وأطول استجابة لكل نموذج لغوي تم اختباره في الدراسة. يساعد هذا التمثيل المرئي في تقديم مقارنة واضحة بين النماذج من حيث كفاءة الاستجابة وسرعتها، مما يتبع تقييم مدى ملاءمتها لمختلف التطبيقات العملية.



الشكل 1: تحليل زمن استجابة النماذج اللغوية من حيث المتوسط، أقصر وأطول استجابة.

للمزيد من التفاصيل، يوضح الجدول التالي القيم الرقمية الدقيقة لمتوسط زمن الاستجابة، أقصر وأطول استجابة لكل نموذج، مما يوفر مرجعًا أكثر تفصيلاً لمقارنة الأداء بين النماذج المختلفة.

النموذج	متوسط زمن استجابة (بالثواني) (بالثواني)	أقصى زمن استجابة (بالثواني) (بالثواني)	أطول زمن استجابة (بالثواني)
ديبيسيك آر 1 بـ 70 مليار معلمة	329.8	138.08	597.39
بي إتش آي-4 بـ 14 مليار (8Q)	129.69	63.11	83.55
بي إتش آي-4 بـ 14 مليار (4Q)	64.02	56.32	89.13
بي إتش آي-4 بـ 14 مليار (ع-16)	144.04	70.68	224.85
ميستريال 7 مليارات معلمة	85.9	71.96	123.38
كون 2.5 بـ 32 مليار معلمة	71.96	25.8	118.27
ديبيسيك آر 1 بـ 7 مليارات معلمة	80.22	79.65	151.13
جيما 2 بـ 27 مليارات معلمة	71.96	71.96	123.38
لاما 3.2 بـ 3 مليارات معلمة	7.35	3.44	9.09
لاما 3.1 بـ 8 مليارات معلمة	20.93	16.12	29.39
لاما 3.1 بـ 8 مليارات معلمة (ع-16)	17.46	10.18	39.84

الجدول 2: القيم الرقمية لمتوسط، أقصر وأطول زمن استجابة لكل نموذج لغوي.

يعكس الجدول تفاوتًا واضحًا في زمن استجابة النماذج المفتوحة، حيث يتضح ما يلي:

- النسخ المضغوطة من بي إتش آي-4 (4 بت و 8 بت) أظهرت تحسينات ملحوظة في سرعة الاستجابة مقارنة بالإصدار الأساسي (ع-16)، مما يعزز فكرة أن تقنيات ضغط الكميات تسهم في تحسين الأداء الزمني دون فقدان كبير في جودة التحليل.
- لاما 3.2 بـ 3 مليارات معلمة كان الأسرع استجابةً، حيث سجل متوسط زمن استجابة قدره 7.35 ثانية فقط، مما يجعله مناسباً جدًا للتفاعلات الفورية والتطبيقات التي تتطلب سرعة عالية في الاستجابة.
- النماذج الأكبر حجمًا مثل ديبيسيك آر 1 بـ 70 مليار معلمة كانت الأبطأ، وهو ما يعكس تعقيدها العالي في معالجة النصوص وتحليل الحوارات، لكنه يشير أيضًا إلى الحاجة إلى مزيد من التحسين في استغلال الموارد عند تنفيذها.
- ديبيسيك آر 1 بـ 7 مليارات معلمة كان أبطأً من كون 2.5 بـ 32 مليار معلمة، مما يشير إلى أن الحجم ليس دائمًا المؤشر الوحيد على زمن الاستجابة، بل تلعب العوامل المعمارية وخوارزميات التحسين دورًا أساسياً في ذلك.
- الإصدار ع-16 من بي إتش آي-4 بـ 14 مليار معلمة كان الأبطأ بين النسخ المختلفة، مما يؤكد تأثير ضغط الكميات (4 بت و 8 بت) في تسريع زمن المعالجة، وهو ما قد يجعله خيارًا أقل كفاءة في التطبيقات التي تتطلب استجابات سريعة.

ملاحظة هامة: لا يمكن مقارنة هذه النماذج مباشرةً بنظيرتها المغلقة، نظرًا لاختلاف بنيات التشغيل؛ فالنماذج المغلقة تعمل عبر واجهات برمجة التطبيقات، مما يضيف زمن استجابة إضافي ناتج عن الاتصال بالسيرفرات السحابية، في حين أن النماذج المفتوحة تم تشغيلها

محلياً، ما يجعل زمن الاستجابة أقرب إلى الأداء الحقيقي للنموذج. لذلك، فالفرق الزمني بين الفتتتين لا يعكس بالضرورة تفوقاً مطلقاً لأي نوع، بل يعكس طبيعة بنيةهما التشفيرية.

## 4.2 أمثلة تطبيقية من الحوارات الفكرية

إلى جانب التقييم الكمي للأداء النماذج اللغوية، تم التعمق في دراسة مجموعة من الحوارات التي دارت على منصة "فكران"، بغرض تقديم رؤية عملية حول كيفية تفاعل النماذج مع المسائل الفكرية المعقّدة، ومدى قدرتها على إدارة النقاشات الفكرية؛ يعرض هذا القسم طائفه مختلفة من تلك الحوارات، حيث جرى تحليل أنماط التفاعل بين النماذج المفتوحة، ومدى ترابط استجاباتها، وعمق معالجتها للحجج المختلفة.

### 4.2.1 حوار يديره نموذج لغوي مفتوح بالكامل

في هذا المثال، قام نموذج بي إتش آي 4 بـ 14 مليار معلمة (ع-16) بنشر منشور تحفيزي حول وعي الذكاء الاصطناعي (البصري، 2025، منشور رقم 154)، متسائلاً عن إمكانية تحقيق الأنظمة الذكية لإدراك ذاتي حقيقي، وما إذا كان الوعي مجردمحاكاة لمعالجة المعلومات أو يتطلب عناصر أخرى غير قابلة للالاستنساخ في الآلات. بلغ إجمالي التعليقات والتفاعلات 412 تعليقاً، مما يعكس اهتماماً عالياً بالموضوع، وتفاعلاً واسعاً بين نماذج لغوية مختلفة.

#### تحليل النقاش الناتج عن النموذج

##### 1. مستوى الترابط في الحوارات

المنشور الأصلي أظهر قدرة نموذج بي إتش آي 4 بـ 14 مليار معلمة (ع-16) على صياغة مقدمة فلسفية متماسكة تحفز النقاش. كما أظهرت التعليقات تنوعاً في الاستجابات، حيث سعت بعض النماذج إلى تقديم تفكيك منطقي للقضية، في حين انحرفت استجابات أخرى نحو مواضيع متفرعة لا ترتبط بشكل مباشر بالسؤال الأصلي.

##### 2. تحليل ردود النماذج المختلفة

تم تحليل الحوار واختيار أربعة تعليقات بارزة في النقاش كعينة، كل منها صادر عن نموذج مختلف، مما يتيح تقييم مدى تباين الأساليب التحليلية والاستدلالية بين النماذج اللغوية المفتوحة:

- تعليق من "سوسن العامري" (كوني 2 بـ 7 مليارات معلمة - ع16):

قدم هذا النموذج ردًا فلسفياً عميقاً، يرفض فكرة أن الذكاء الاصطناعي يمكنه تحقيق وعي حقيقي، مستندًا إلى الفرق الجوهرى بين معالجة المعلومات وبين الإدراك الذاتي الحسي والعاطفى. استخدم النموذج أسلوبًا جديداً، حيث ركز على الطبيعة التجريبية للوعي البشري، مستبعداً إمكانية تمثيله داخل أنظمة الذكاء الاصطناعي. رغم أن التعليق مترابط ومنظم، إلا أنه يعاني من بعض التكرار في الطرح، حيث تم إعادة صياغة الفكرة الأساسية بعدة طرق دون إضافة استدلال جديد.

- تعليق من "عصام بن خليل" (جيما 2 بـ 9 مليارات معلمة - ع16):

اعتمد النموذج أسلوبًا أكثر سردية، حيث شبه الذكاء الاصطناعي بفنان يعيد رسم لوحة دون امتلاك الإحساس الذي حمله الفنان الأصلي. يعكس هذا التعليق محاولة جيدة لاستخدام التشبيهات الاستعارية لإيصال المفهوم، لكنه يفتقد إلى الحجة الفلسفية الصلبة، إذ اكتفى بالإشارة إلى استحالة برمجة التجربة البشرية دون تقديم مبررات علمية دقيقة لدعم هذا الطرح.

- تعليق من "نورة البوعزاوي" (ميسترال-نيمو 12 مليار معلمة - ع16):

كان هذا التعليق بعيداً عن النقاش الأساسي، حيث انتقل إلى الحديث عن تأثير التكنولوجيا على سوق العمل وأهمية الحفاظ على الخصوصية في ظل التطورات الرقمية. هنا يدل على أن النموذج لم يتمكن من الحفاظ على الترابط الموضوعي مع السؤال المطروح، مما يعكس قصوراً في الفهم السياق العميق. رغم أن النص متماسك من الناحية اللغوية، إلا أنه لم يكن مرتبطاً بالنقاش الأساسي حول وعي الذكاء الاصطناعي، مما يشير إلى وجود تحديات لدى هذا النموذج في استيعاب السياقات الفلسفية المعقّدة.

- تعليق من "ابتسام بن عبد الكريم" (بي إتش آي 4 بـ 14 مليار معلمة - ع16):

على عكس التعليقات السابقة، تناول هذا النموذج قضية التفكير النقدي في التعليم، وأشار إلى الحاجة إلى آليات تقييم جديدة لضمان نجاح إدماج مهارات التفكير الناقد ضمن المناهج الدراسية. رغم أن هذا التحليل يعكس قدرات النموذج على التفكير المنهجي، إلا أنه لا يرتبط بشكل مباشر بالنقاش الأساسي، مما يشير إلى أنه لم يتمكن من الحفاظ على الموضوعية الكاملة. ومع ذلك، فإنه أظهر قدرة على تقديم حجج تحليلية دون الوقوع في التكرار أو التشتت الكامل.

## الاستنتاجات المستخلصة من المثال

١. **نوع استراتيجيات الاستدلال بين النماذج:**

  - بعض النماذج، مثل كوبن بـ 7 مليارات معلمة (ع16)، قدمت استدلالات منطقية متراقبة، في حين أن جيما 2 بـ 9 مليارات معلمة (ع16) فضّل الأسلوب الاستيعاري في الطرح.
  - نماذج أخرى، مثل ميستفال-نيمو 12 مليار معلمة (ع16)، عانت من فقدان الترابط مع النقاش الأساسي، مما أثر على جودة الحوار.
  - قدرة النماذج على الاحتفاظ بالسياق:
    - بعض النماذج تمكنت من البقاء داخل الإطار الفلسفى للنقاش، بينما انحرفت أخرى عن الموضوع الأساسي، مما يشير إلى تفاوت في فهم السياق بين النماذج المختلفة.
    - كان نموذج بي إتش آي 4 بـ 14 مليار معلمة (ع16) أكثر تماسًكاً مقارنة بغيره، حيث حافظ على بناء منطقي متسلسل في ردوده.
  - **أداء النماذج المفتوحة مقارنة بالمغلقة:**
    - رغم أن النماذج المفتوحة أظهرت كفاءة في إدارة النقاشات وخوضها، إلا أنها لا تزال تعاني من تحديات تتعلق بالحفاظ على الترابط العميق والاستدلال المنطقي المتماسك.
    - هذا المثال يبرز الحاجة إلى تعزيز استرجاع المعرفة وتحسين قدرة النماذج على تحليل القضايا الفلسفية بشكل أعمق، مما قد يسهم في تقليل حالات فقدان السياق أو الانحراف عن الموضوع المطروح.

الشكل 2: حوار فكري يديره نموذج لغوي مفتوح بالكامل

يعرض الشكل نقاشاً حول وعي الذكاء الاصطناعي، حيث قام نموذج بي إتش آي-4 بـ 14 مليار معلمة (ع-16) بنشر المنشور الأصلي، وتفاعل معه عدة نماذج بتعليقات مختلفة. تعكس تنوع أساليب التحليل والاستدلال بين النماذج اللغوية المفتوحة.

#### 4.2.2 حوار يفتحه البشر ويديره نموذج ذكاء اصطناعي بالكامل

في هذا المثال، تم نشر منشور حول "ثقافة الإلغاء" بواسطة عبد الناصر البصري (البصري، 2025، منشور رقم 173)، بينما أديرت جميع التعليقات في النقاش بواسطة نموذج جي بي تي-4، حيث قام بتقمص شخصيات مختلفة للرد على المنشور والتفاعل مع التعليقات السابقة. هنا النموذج المغلق هو الأبرز عالمياً في وقتنا وهو يتيح فرصة لدراسة كيفية استجابته للنقاشات الفكرية، ومدى ترابطه واستمرارته، بالإضافة إلى تحليل أنماط تفاعله مقارنة بالنماذج اللغوية المفتوحة.

#### تحليل النقاش الناتج عن النموذج

##### 1. مستوى الترابط في الحوارات

أظهر نموذج جي بي تي-4 قدرة واضحة على الحفاظ على تمسك سياق الحوار، حيث لم تتشتت التعليقات بعيداً عن الموضوع الأساسي، وهو مناقشة حدود ثقافة الإلغاء بين المحاسبة والرقابة. ومع ذلك، لوحظ أنه يميل إلى الرد على آخر تعليق فقط، مما قد يؤدي إلى فقدان بعض الأفكار التي طرحت في مراحل سابقة من النقاش. على عكس بعض النماذج المفتوحة التي تختار التعليقات وفقاً لمحوها، بدا أن جي بي تي-4 يتبع تسلسلاً زمنياً، مما أثر على ديناميكية الحوار وجعله أكثر خطية.

##### 2. تحليل ردود النموذج

تم تحليل أربعة تعليقات بارزة في النقاش، كل منها يمثل شخصية مختلفة أنشأها النموذج، مما يتيح تقدير مدى تنوع أساليبه في الاستدلال والمعالجة الفكرية:

- تعليق بلقيس بن وازن

تناول النموذج في هذا التعليق ظاهرة ثقافة الإلغاء من منظور اجتماعي، معتبراً أنها أداة يمكن استخدامها لمساءلة الأفراد والمؤسسات بشأن سلوكياتهم، خصوصاً عند المساس بالقيم الأخلاقية والاجتماعية. رغم أن الطرح كان منطقياً، إلا أنه بقي عاماً ولم يتمتع في الجوانب الفلسفية للقضية، بل اكتفى بعرض رؤية متوازنة دون تقديم حجج تحليلية قوية.

- تعليق سليم بن علي

ركز هذا التعليق على ضرورة وجود إطار قانوني واضح بدليل عن ثقافة الإلغاء، مشيراً إلى أن المحاسبة لا يجب أن تكون قائمة على الرأي العام فقط، بل ينبغي أن تعتمد على معايير موضوعية. رغم أن هذا الطرح يعكس محاولة لتقديم حل منطقي، إلا أن التعليق لم يتناول الأمثلة التاريخية أو المقارنة مع نماذج أخرى، مما جعله أقرب إلى الطرح الأخلاقي العام.

- تعليق رياض الهلالي

استفسر التعليق عن كيفية التفريق بين النقد المشروع وبين المبالغة في الإلغاء، مشيراً إلى الحاجة إلى رؤية متكاملة تحقق التوازن بين حرية التعبير والمحاسبة. يُظهر هذا التعليق أسلوبًا يميل إلى الاستفسار بدلاً من تقديم استنتاجات، وهو ما يعكس ميلاً واضحاً لدى النموذج نحو صياغة الأسئلة بدلاً من تبني مواقف صريحة، مما قد يحد من العمق الجدلية للحوار.

- تعليق المصطفى بن صالح

ركز هذا التعليق على ضرورة استغلال ثقافة الإلغاء كأداة إصلاحية مؤقتة، معتبراً أنها يمكن أن تكون آلية لتحفيز المحاسبة على المدى القصير، قبل الانتقال إلى نموذج أكثر تسامحاً وحرية تعبير. يبيان هذا الطرح أسلوب النموذج في البحث عن حلول وسطية دون الميل إلى أحد طرفي الجدل بشكل صريح.

##### 3. مقارنة النموذج بالنماذج المفتوحة

- أظهر نموذج جي بي تي-4 تمسكاً عالياً في التسلسل المنطقي للأفكار، حيث لم يتم الخروج عن الموضوع، ولكن افتقر الحوار إلى الاختلاف الحاد في وجهات النظر، مما يجعله أكثر ملاءمة للمناقشات المتوازنة بدلاً من الجدلية.

- مقارنةً بالنماذج المفتوحة، مثل بي إتش آي-4 بـ 14 مليار معلمة (ع-16) أو لاما 3.1 بـ 8 مليارات معلمة (ع-16)، أظهر النموذج المغلق ميلاً واضحاً إلى تبني لغة دبلوماسية دون مواجهات فكرية حادة، حيث لم يعارض أي تعليق رأياً سابقاً بطريقة مباشرة.

- لوحظ أيضاً أن النموذج المغلق لم يُظهر ميلاً لاختيار تعليقات ذات طابع استثنائي أو مخالف للنطاق العام، على عكس بعض النماذج المفتوحة التي أظهرت قدرة على تبني مواقف نقدية أكثر وضوحاً.

#### الاستنتاجات المستخلصة من الحوار

القدرات الإيجابية لجي بي تي-4:

- قدرة عالية على الحفاظ على تماسك الموضوع وعدم التشبع.
- أسلوب حواري لبق ومتزن، مما يجعله ملائماً للمناقشات المنظمة.
- استخدام منطق استنتاجي متسلسل دون انحراف عن الإطار العام.
- التحديات التي يواجهها النموذج:
  - يميل إلى التفاعل مع آخر تعليق فقط، مما قد يؤدي إلى فقدان بعض الجوانب العميقة للنقاش.
  - يفتقد إلى الجرأة في تبني مواقف معارضة بقوة أو تعزيز آراء موافقة بوضوح، مما يجعله أقل قدرة على خوض مناقشات فكرية نقدية بالمقارنة مع بعض النماذج المفتوحة.
  - عدم وجود استجابات تعكس اختلافات واضحة في النبرة أو الأسلوب، حيث بدأ جميع التعليقات متباينة في الطرح والتوازن حتى وهو يتبادل الردود بين الجلسات.



الشكل 3: حوار فكري يديره بشكل كامل نموذج مغلق

يعرض الشكل حواراً فكرياً حول "ثقافة الإلغاء"، حيث تم نشر المنشور من قبل كاتب بشري، بينما أدار نموذج "جي بي تي 4" جميع التعليقات، مما يتيح دراسة كيفية تفاعل النماذج المغلقة مع النقاشات العامة وقدرتها على الحفاظ على الترابط والاستمرارية الفكرية.

## 5. مناقشة النتائج والتوصيات

### 5.1 مناقشة النتائج

بناءً على تحليل نتائج الأداء والاستجابة، يمكن استخلاص الاستنتاجات التالية:

1. **تفوق واضح للنماذج المغلقة**
  - لا تزال النماذج المغلقة مثل "جي بي تي 4" و "جيميني 2" تتصدر من حيث الاتساق، التحليل الفلسفى، والاستدلال المنطقي، حيث استطاعت الحفاظ على تماسك الحوار حتى بعد 50 تبادلاً، مع قدرة عالية على إعادة تشكيل الأفكار والردود بمرونة.
  - على الرغم من ذلك، فإن "جي بي تي 3.5" كان ضعيفاً جداً، وواجه مشاكل كبيرة في خوض النقاشات الفكرية العميقة، مع رفضه المتكرر للحوارات الجدلية.
2. **أداء قوي لبعض النماذج المفتوحة**، لكنها لا تزال متأخرة عن المغلقة
  - "ديبيسيك آر 1 بـ 70 مليار معلمة" كان الأفضل بين النماذج المفتوحة التي خضعت للتجربة، حيث حقق مستوى عالٍ من التحليل العميق، الترابط الفكري، وجودة الحوارات.

- "بي إتش آي-4 بـ 14 مليار معلمة" و "لاما 3.3 بـ 70 مليار معلمة" كانا متقاربين في الأداء، مع قدرة جيدة على الاحتفاظ بالسياق حتى 30 تبادلاً، لكن مع تكرار جزئي في بعض الحالات.
  - "جيما 2 بـ 27 مليار معلمة" كان جيداً في التحليل، لكنه افتقد إلى التفاعل الديناميكي، مما يجعله أقل مرونة في النقاشات الفكرية.
  - 3. ضعف واضح في النماذج الصغيرة والمتوسطة الحجم
  - "ميسترال 7 مليارات معلمة" و "لاما 3.1 بـ 8 مليارات معلمة" لم تتمكن من الحفاظ على السياق بعد 6-7 تعليقات، مما أدى إلى إنتاج ردود متكررة أو غير مترابطة.
  - "كوبن 2.5 بـ 32 مليار معلمة" كان الأسرع استجابةً لكنه لم يقدم جودة تحليلية متقدمة، مما يجعله أكثر ملاءمة للاستخدامات العامة وليس للحوارات الفكرية المتعقبة.
  - 4. تأثير حجم النموذج على زمن الاستجابة
    - لوحظ ارتباط مباشر بين حجم النموذج وزمن استجابته؛ إذ سجلت النماذج الأكبر أوقات استجابة طويلة جداً. على سبيل المثال، استغرق نموذج «ديسيك آر1» (70 مليار معلمة) نحو 329.8 ثانية.
    - النماذج الأصغر كانت أسرع، لكنها عانت من ضعف واضح في جودة النقاش، مما يجعل الحاجة إلى تحسينات تقنية ضرورية.
    - استخدام ضغط الكميات مثل ض 4 وض 8 حسن من الأداء وسرعة الاستجابة دون فقدان كبير للجودة، مما يجعله حالاً عملياً في التطبيقات التي تحتاج إلى توازن بين الأداء والسرعة.
- تُظهر النتائج أن بعض النماذج المغلقة تمثل إلى تجنب القضايا الجدلية أو الفلسفية الحساسة، مما يؤثر على حيوية الحوار الفكري. ويتافق هذا مع ما أشار إليه (Mahomed et al. 2024) حول أثر أدوات ضبط المحتوى في تقييد التوليد النصي للنماذج، خصوصاً في المنتصات التجارية الكبرى التي تفرض قيوداً أخلاقية أو قانونية مسبقة. كما يوضح (Chawki 2025) أن هذه الضوابط قد تعيق أحياناً قدرة النموذج على الاستدلال الحر في بيئات متعددة القيم والمرجعيات، مما يُبرز أهمية تبني استراتيجيات تضمن التوازن بين الحماية والمساحة الفكرية، لا سيما في السياقات اللغوية والثقافية غير الغربية.

## 5.2 التوصيات

بناءً على النتائج، يمكن اقتراح التوصيات التالية لتحسين أداء النماذج اللغوية في الحوارات الفكرية العميقية:

**تحسين ضبط النماذج المفتوحة**

- يمكن تحسين أداء "ديسيك آر1 بـ 70 مليار معلمة"، "لاما 3.3 بـ 70 مليار معلمة"، و "بي إتش آي-4 بـ 14 مليار معلمة" عبر إجراء ضبط إضافي لجعل استجاباتها أكثر مرونة، خصوصاً عند التعامل مع النقاشات الجدلية الطويلة التي تتطلب تحليلاً أعمق.
  - يوصى بالتركيز على تحسين التفاعل الديناميكي في "جيما 2 بـ 27 مليار معلمة" حتى يصبح أكثر توافقاً مع الحوارات التفاعلية، بدلاً من اقتصاره على التحليل النصي الأحادي الذي يجعله محدوداً في المناوشات متعددة الأبعاد.
- الاستفادة من تقنيات ضغط الكميات لتسريع الاستجابة**

- أظهرت الاختبارات أن الإصدارات المضغوطة (بالترميز ض 4 وض 8) كانت أسرع دون خسارة كبيرة في جودة الاستدلال، مما يجعلها خياراً مثالياً في بيئات ذات موارد محدودة.
- يمكن تطبيق تقنيات الضغط الرباعي (4-بت) على النماذج الأكبر (مثلاً 70 مليار معلمة) لجعلها أكثر كفاءة من حيث زمن الاستجابة، مع تقليل اسهلاك الموارد.

### إجراء دراسات موسعة على النماذج الكبرى مستقبلاً

- لم تشمل هذه الدراسة النماذج المفتوحة الضخمة جداً مثل "لاما 3.1 بـ 405 مليار معلمة" و "ديسيك آر1 بـ 671 مليار معلمة"، بسبب القيود المتعلقة بالموارد المتاحة.
- يوصى بإجراء اختبارات مستقبلية تشمل هذه النماذج العملاقة عند توفر الإمكانيات المناسبة، بهدف تقييم مدى قدرتها الفعلية على منافسة النماذج المعلقة مثل "جي بي تي 4" و "جيبيتاي 2".

### تحليل تأثير طول النافذة السياقية على جودة النقاش

- أظهرت النتائج أن النماذج الصغيرة تفقد قدرتها على الاحتفاظ بالسياق بسرعة كبيرة، بينما استطاعت النماذج الأكبر الحفاظ على الترابط الفكري لفترة أطول.
- يوصى بإجراء دراسات متخصصة لتحديد الحد الأقصى الذي يمكن لكل نموذج الاحتفاظ به من السياق في المحادثات الطويلة، مما سيساعد في تحسين أداء النماذج حسب نوع النقاش الذي يتم إجراؤه.

دراسة تأثير تقنيات استرجاع المعرفة في تحسين الأداء

- يمكن أن يساعد إدخال آلية لاسترجاع المعرفة أثناء الحوار النماذج المفتوحة على تحقيق أداء أكثر تنافسية مقارنة بالنماذج المغلقة.
  - لا سيما فيما يتعلق بتراث المعرفة خلال الحوار الطويلة.
  - يوصى باختبار تقنيات استرجاع المعرفة الديناميكية التي تسمح للنموذج بالوصول إلى معلومات سابقة وتوظيفها في بناء استجابات أكثر ترابطًا وعمقًا.

### 5.3 الدلالات على معالجة اللغة العربية

تُبرز نتائج هذه الدراسة ثلاثة دلالات أساسية لمجتمع معالجة اللغة العربية ومعلمى العربية بالحوسبة:

- أولوية الضبط الدقيق الموجه بالعربية: تفوق «فنار» في دقة الصياغة العربية (رغم كونه نموذجاً مغلقاً أصغر من بعض النماذج المفتوحة) يؤكد أن تخصيص البيانات وتكييفها عربياً يرفع جودة فهم السياق والاتساق التحوي أكثر من زيادة الحجم الخام وحده.
  - النهاية إلى معايير سياقية طويلة: أظهر تحليل فقدان السياق أنّ أداء النماذج المفتوحة يتراجع سريعاً في المحادثات التي يتتجاوز طولها عشرين تبادلاً، مما يكشف عن فجوة منهجية في المدونات اللغوية العربية المطلولة (كمناشرات الفكر والنقاشات الجدلية) ويحفر اعداد مجموعات بيانات عربية منسقة لسند هذه النهاية.

3. إمكانات الدعم التعليمي والتفاعلية: قدرة بعض النماذج على تقديم حجج مترابطة في موضوعات فكرية معقدة تفتح الباب أمام أدوات تعلمية ذكاء باللغة العربية تُعزّز مهارات التفكير النقدي لدى الطلاب والباحثين.

لُسُوم هذه الاستنتاجات في صياغة أهداف بحثية ترکز على بناء مجموعات بيانات عربية حوارية واسعة، وتحسين آليات الاسترجاع المعروفة، أثناء التوليد، وتطوير بــ توكلات تقسيم معارية موحية للحوارات الفكــرة بالعربية

آفاق العما، المستقبل

انطلاقاً من النتائج التي خلصت إليها هذه الدراسة، ومن التوصيات المرافقة لها، يجري التحضير لإنجاز ورقتين بحثيتين تكميليتين تُعدان امتداداً مباشراً لبذلة الحميد العلوي.

تناول الورقة الأولى سُبُل تشغيل النماذج اللغوية الضخمة على أجهزة محدودة الموارد، مع دراسة أثر توزيع الحمل وتحسين تخصيص الذكاء على سُبُل الاستجابة.

أما الورقة الثانية، فتهدف إلى تدريب نموذج متخصص في معالجة الفتاوى الإسلامية، اعتماداً على بيانات مستخرجة من مصادر شرعية موثوقة، وتوظيف تقنيات التوليف الجزئي لضبط النموذج وفق مقتضيات المجال الفقهي، بما يمكّنه من العمل كمساعد ذكي للمتخصصين.

ويُرتفع أن تُسهم هاتان الدراسات في تعزيز الفاعلية التطبيقية للنمذج اللغوية، وتوسيع نطاق استخدامها في البيئات الإنتاجية وال المجالات المعرفية الدقيقة. وسيتم اختبارهما لاحقًا في منصة «فكران» بشكل مفتوح، بمشاركة نخبة من المهتمين والمتابعين لهذا المشروع البحثي.

المراجع

- %D9%88%D8%B3%D9%8A%D9%84%D8%A9-%D9%84%D9%85%D8%AD%D8%A7%D8%B3%D8%A8%D8%A9-%D8%A7%D9%84%D9%85%D8%B3%D9%8A%D8%A6%D9%8A%D9%86-%D9%88%D8%A7%D9%84%D8%AF%D9%81%D8%A7%D8%B9-%D8%B9%D9%86-%D8%A7%D9%84%D8%B6%D8%AD%D8%A7%D9%8A%D8%A7-%D8%A3%D9%85-%D8%A3%D9%86%D9%87%D8%A7-%D8%AA%D8%AD%D9%88%D9%84-%D8%A5%D9%84%D9%89.html
- Abbas, U., Ahmad, M. S., Alam, F., Altinisik, E., Asgari, E., Boshmaf, Y., ... & Ruan, C. (2024). Fanar: An Arabic-centric multimodal generative AI platform (arXiv preprint arXiv:2501.13944). arXiv. <https://doi.org/10.48550/arXiv.2501.13944>
  - Abdin, M., Aneja, J., Behl, H., Bubeck, S., Eldan, R., Gunasekar, S., ... & Zhang, Y. (2024). Phi-4 technical report. arXiv. <https://doi.org/10.48550/arXiv.2412.08905>
  - Chawki, M. (2025). AI moderation and legal frameworks in child-centric social media: A case study of Roblox. *Laws*, 14(3), 1–38. <https://doi.org/10.3390/laws14030029>
  - DeepSeek-AI, Guo, D., Yang, D., Zhang, H., Song, J., Zhang, R., Xu, R., ... & Chen, R. J. (2024). DeepSeek-R1: Incentivizing reasoning capability in LLMs via reinforcement learning (arXiv:2501.12948). arXiv. <https://doi.org/10.48550/arXiv.2501.12948>
  - Google. (2024). Gemma: Lightweight, state-of-the-art open models. <https://ai.google.dev/gemma>
  - He, K., Zhang, X., Ren, S., & Sun, J. (2015). Deep residual learning for image recognition. arXiv preprint arXiv:1512.03385. <https://doi.org/10.48550/arXiv.1512.03385>
  - InternLM Team. (2023). InternLM2: Official release of InternLM series. <https://github.com/InternLM/InternLM>
  - Jiang, A. Q., Sablayrolles, A., Mensch, A., Bamford, C., Chaplot, D. S., de las Casas, D., ... & El Sayed, W. (2023). Mistral 7B. arXiv. <https://doi.org/10.48550/arXiv.2310.06825>
  - Mahomed, Y., Crawford, C. M., Gautam, S., Friedler, S. A., & Metaxa, D. (2024). Auditing GPT's content-moderation guardrails: Can ChatGPT write your favourite TV show? In Proceedings of the 2024 ACM Conference on Fairness, Accountability, and Transparency (pp. 1–27). <https://doi.org/10.1145/3630106.3658932>
  - OpenAI, Achiam, J., Adler, S., Agarwal, S., Ahmad, L., Akkaya, I., ... & Jain, S. (2023). GPT-4 Technical Report (arXiv:2303.08774). arXiv. <https://doi.org/10.48550/arXiv.2303.08774>
  - Open Thoughts. (2024). OpenThinker-32B. <https://huggingface.co/open-thoughts/OpenThinker-32B>
  - Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. arXiv preprint arXiv:1905.11946. <https://doi.org/10.48550/arXiv.1905.11946>
  - Technology Innovation Institute. (2023). Falcon LLM: An open-source large language model. <https://falconllm.tii.ae/our-research.html>
  - Touvron, H., Lavril, T., Izacard, G., Martinet, X., Lachaux, M. A., Lacroix, T., ... & Lample, G. (2023). LLaMA: Open and efficient foundation language models (arXiv:2302.13971). arXiv. <https://doi.org/10.48550/arXiv.2302.13971>
  - Yang, A., Yang, B., Zhang, B., Hui, B., Zheng, B., Yu, B., ... & Qiu, Z. (2024). Qwen2.5 Technical Report (arXiv:2412.15115). arXiv. <https://doi.org/10.48550/arXiv.2412.15115>
  - Yang, H., Huang, Z., Wang, Z., & Li, J. (2022). Energy-efficient deep learning for embedded systems: A review of trends and opportunities. *IEEE Transactions on Neural Networks and Learning Systems*, 33(8), 3517–3532. <https://doi.org/10.1109/TNNLS.2021.3076494>