

---

## Large Language Models and Information Retrieval in the Digital Environment: a theoretical analytical study

**Mohammed Abdullah Saeed Al-Amri**

PhD Researcher, Knowledge Management, King Abdulaziz University, Saudi Arabia  
masalamri@kau.edu.sa

### Abstract

This study explores the role of Large Language Models (LLMs) in information retrieval within the digital environment through a theoretical analysis of their concepts, operational mechanisms, and a comparison with traditional methods, alongside identifying key challenges and contemporary applications. The findings reveal that LLMs represent a qualitative shift in processing natural language due to their ability to understand context and generate precise responses. The study highlights their superiority in enhancing retrieval systems through integration with cognitive technologies such as Retrieval-Augmented Generation (RAG) and Knowledge Graphs (KGs), thereby improving the reliability and effectiveness of results, especially in specialized domains. Despite these capabilities, the study identifies technical and methodological challenges, including hallucination and limited interpretability. It emphasizes that LLMs do not replace traditional retrieval methods but complement them, depending on task nature and user behavior. The study recommends developing hybrid models, enhancing multimodal capabilities, and expanding real-world evaluations—particularly in low-resource languages and specialized fields. It concludes that integrating LLMs with structured knowledge representations offers a promising path toward building more accurate, equitable, and intelligent information retrieval systems.

**Keywords:** Large Language Models, Smart Language Models, Information Retrieval, Information Retrieval Systems, Information Retrieval in the Digital Environment.

## النماذج اللغوية الكبيرة واسترجاع المعلومات في البيئة الرقمية: دراسة تحليلية نظرية

محمد عبدالله سعيد العمري

باحث دكتوراه، إدارة المعرفة، جامعة الملك عبدالعزيز، المملكة العربية السعودية  
masalamri@kau.edu.sa

### ملخص البحث

تهدف هذه الدراسة إلى استكشاف دور النماذج اللغوية الكبيرة (LLMs) في استرجاع المعلومات داخل البيئة الرقمية، من خلال تحليل نظري لمفاهيمها وآليات عملها، ومقارنتها بالأساليب التقليدية، واستجلاء أبرز التحديات والتطبيقات المعاصرة. كشفت النتائج أن النماذج اللغوية الكبيرة تمثل نقلة نوعية في التعامل مع اللغة الطبيعية بفضل قدرتها على فهم السياق وتوليد استجابات دقيقة. كما أظهرت الدراسة تفوقها في دعم أنظمة الاسترجاع من خلال تكاملها مع تقنيات معرفية مثل الاسترجاع المعزز بالتوليد (RAG) والرسوم البيانية المعرفية (KGs)، مما يعزز موثوقية النتائج وفعاليتها في المجالات المتخصصة. وعلى الرغم من هذه الإمكانيات، بيّنت الدراسة وجود تحديات تقنية ومنهجية مثل الهلوسة المعلوماتية وصعوبة التفسير. وأكدت أن النماذج اللغوية الكبيرة لا تُغني عن النماذج التقليدية، بل تكملها بحسب طبيعة المهمة وسلوك المستخدم. توصي الدراسة بتطوير نماذج هجينة، وتحسين تقنيات الوسائط المتعددة، وتوسيع نطاق التقييم الواقعي، خاصة في البيئات اللغوية محدودة الموارد. وتخلص إلى أن التكامل بين النماذج اللغوية الكبيرة والبنى المعرفية يمثل مسارًا واعدًا لتطوير نظم استرجاع معلومات أكثر دقة وعدالة وذكاء.

**الكلمات المفتاحية:** النماذج اللغوية الكبيرة، النماذج اللغوية الذكية، استرجاع المعلومات، نظم استرجاع المعلومات، استرجاع المعلومات في البيئة الرقمية.

## المقدمة

شهدت بيئة المعلومات الرقمية في العقود الأخيرة تحولات عميقة، فرضتها الزيادة الهائلة في حجم البيانات وتعقيد احتياجات المستخدمين في الوصول إلى المعلومات ذات الصلة. وقد برز استرجاع المعلومات كأحد الحقول المركزية في علوم الحاسب والمعلومات، خاصة مع تزايد الاعتماد على محركات البحث ومنصات التفاعل الرقمي. في هذا السياق، تطورت أساليب الاسترجاع من نماذج تعتمد على مطابقة الكلمات المفتاحية إلى نماذج أكثر تعقيداً تستخدم تمثيلات دلالية وفهماً للسياق.

يُعد ظهور النماذج اللغوية الكبيرة (LLMs) نقطة تحول جوهريّة في هذا المجال، لما أظهرته من قدرة على فهم اللغة الطبيعية، وتفسير النيات، ومعالجة السياقات المختلفة بطريقة تتجاوز محدودية النماذج التقليدية. وقد تم توظيف هذه النماذج في مجموعة متنوعة من المهام، بدءاً من إعادة كتابة الاستعلامات، مروراً بالاسترجاع وفق السياق وإعادة ترتيب النتائج، وانتهاءً بتوليد الإجابات القائمة على المعرفة. كما أظهرت قدرتها على التفاعل مع البيانات غير النصية من خلال دعم القدرات الوسائطية.

ومع اتساع نطاق استخدام النماذج اللغوية الكبيرة في نظم استرجاع المعلومات، بدأت تظهر تساؤلات جديدة حول فاعليتها، ودقتها، والتحديات المصاحبة لها، سواء كانت تقنية أو معرفية أو منهجية. وتشير المعالجات النظرية الحديثة إلى أن هذه النماذج، رغم تفوقها في بعض الجوانب، لا تزال تواجه إشكالات في قابلية التفسير، والتحيزات المضمنة، ودقة النتائج في البيئات المتخصصة. كما أن تكاملها مع تقنيات أخرى يفتح لها الطريق لتطوير أنظمة أكثر ذكاءً واستجابة.

بناءً على ذلك، تسعى هذه الدراسة إلى تحليل الدور الذي تلعبه النماذج اللغوية الكبيرة في استرجاع المعلومات، من خلال تقديم معالجة نظرية لمفاهيمها، وآليات عملها، وأساليب الاسترجاع المرتبطة بها، مقارنةً بالأنظمة التقليدية، واستكشاف النظم المتقدمة المعززة بها. كما تحاول الدراسة استخلاص فرص التحسين والتطوير المستقبلي في ضوء ما تكشفه التحليلات.

## مشكلة الدراسة

في ظل النمو المتسارع للتقنيات الذكية، برزت النماذج اللغوية الكبيرة بوصفها أدوات واعدة في دعم الوصول إلى المعرفة واسترجاع المعلومات. ومع هذا التحول، لم يعد استرجاع المعلومات قائماً فقط على مطابقة الكلمات، بل أصبح يعتمد على فهم السياق والتفاعل اللغوي المتقدم. غير أن هذا التطور يثير جملة من الإشكالات النظرية والتقنية، تتعلق بمدى كفاءة هذه النماذج مقارنةً بالأساليب التقليدية، ومدى قدرتها على التعامل مع

التحديات المرتبطة بالموثوقية والسياقية والتفسير. كما تبرز الحاجة إلى فهم العلاقة بين هذه النماذج وبيئة الاسترجاع الرقمية، وحدود التكامل بين المنهج التقليدي والمنهج التوليدي. ومن هنا تنطلق هذه الدراسة لتناول هذه الإشكالات بالتحليل، وبحث أبعاد هذا التحول في ضوء المعطيات التقنية والمعرفية المعاصرة.

### أهداف الدراسة

1. تجلية مفهوم النماذج اللغوية الكبيرة من حيث بنيتها وآلية عملها وتطبيقاتها.
2. توضيح العلاقة بين النماذج اللغوية الكبيرة واسترجاع المعلومات في البيئة الرقمية.
3. تقديم مقارنة نظرية بين الأساليب التقليدية للاسترجاع وتلك المعتمدة على النماذج اللغوية الكبيرة.
4. إبراز التحديات التقنية والمنهجية التي تواجه استرجاع المعلومات عبر النماذج اللغوية الكبيرة، واقتراح فرص للتحسين والبحث المستقبلي.

### أهمية الدراسة

تبرز أهمية هذه الدراسة في تسليط الضوء على دور النماذج اللغوية الكبيرة في إعادة تشكيل آليات استرجاع المعلومات في البيئة الرقمية، حيث لم يعد الوصول إلى المعلومة قائمًا على المطابقة النصية فحسب، بل أصبح يعتمد على فهم أعمق للسياق والدلالة. وتكمن أهمية الدراسة أيضًا في أنها تُسهم في توضيح الفروق النظرية والوظيفية بين الاسترجاع التقليدي والاسترجاع عبر النماذج التوليدية، الأمر الذي يساعد الباحثين والمطورين وصناع القرار في اختيار المنهج الأنسب وفقًا لحاجات المستخدمين. كما تتيح الدراسة فرصة لفهم التحديات التي تعترض دمج هذه النماذج في نظم الاسترجاع الحديثة، وتقديم رؤى نظرية قابلة للبناء عليها في أبحاث لاحقة.

### أسئلة الدراسة

1. ما مفهوم النماذج اللغوية الكبيرة؟ وما خصائصها وآليات عملها؟
2. ما العلاقة بين النماذج اللغوية الكبيرة واسترجاع المعلومات في البيئة الرقمية؟
3. ما هو الفرق بين الأساليب التقليدية للاسترجاع وتلك المعتمدة على النماذج اللغوية الكبيرة؟
4. ما هي إبراز التحديات التقنية والمنهجية التي تواجه استرجاع المعلومات عبر النماذج اللغوية الكبيرة؟

## مجال الدراسة وحدودها

تندرج هذه الدراسة ضمن مجال علوم المعلومات والذكاء الاصطناعي، مع تركيز خاص على تقاطع النماذج اللغوية الكبيرة (LLMs) وتقنيات استرجاع المعلومات في البيئة الرقمية. كما تنحصر هذه الدراسة في الجانب النظري التحليلي المرتبط بمفاهيم النماذج اللغوية الكبيرة وتطبيقها في مجال استرجاع المعلومات. ولا تشمل الدراسة الجوانب البرمجية أو الهندسية التفصيلية لهذه النماذج.

## منهج الدراسة

اعتمدت الدراسة على المنهج الوصفي التحليلي، حيث تم تجميع المعلومات من مصادر علمية حديثة، وتحليلها ضمن سياق مفاهيمي يهدف إلى ربط خصائص النماذج اللغوية الكبيرة بآليات استرجاع المعلومات. كما تم الاستناد إلى أسلوب المقارنة النظرية لبيان الفروق بين النماذج التقليدية وتلك المعتمدة على النماذج اللغوية الكبيرة، وذلك بغرض استخلاص استنتاجات يمكن أن تمثل أساساً لمزيد من الدراسات المستقبلية في هذا المجال.

## مصطلحات الدراسة

النماذج اللغوية الكبيرة (Large Language Models -LLMs): هي نماذج تعتمد على الذكاء الاصطناعي وتُدرَّب على كميات ضخمة من البيانات النصية، بهدف توليد وفهم اللغة البشرية. تُستخدم هذه النماذج في العديد من التطبيقات مثل المحادثة التفاعلية، والإجابة على الأسئلة، والترجمة، واسترجاع المعلومات، وتتميز بقدرتها على معالجة السياقات المعقدة واستنتاج العلاقات الدلالية بين المفاهيم.

استرجاع المعلومات (Information Retrieval -IR) هو فرع من فروع علم الحاسوب يُعنى بالبحث عن المعلومات ذات الصلة ضمن مصادر غير مهيكلة أو شبه مهيكلة، استناداً إلى استعلام يقدمه المستخدم. يشمل ذلك تحديد موقع المستندات أو المقاطع النصية التي ترتبط بمحتوى الاستعلام بدرجات متفاوتة من الصلة.

البيئة الرقمية (Digital Environment): يُشار إليها بالبنية التحتية التقنية والأنظمة المعلوماتية التي تُستخدم لتخزين المعلومات ومعالجتها واسترجاعها عبر الوسائط الإلكترونية، بما يشمل قواعد البيانات، ومحركات البحث، ومنصات الحوسبة السحابية، وغيرها من الفضاءات الرقمية التي تعتمد على تقنيات الذكاء الاصطناعي.

## أداة الدراسة والإجراءات المتبعة في الدراسة (المنهجية)

نظرًا لطبيعة هذه الدراسة النظرية التحليلية، فقد تم اعتماد التحليل الوثائقي (Documentary Analysis) بوصفه الأداة الرئيسية في جمع البيانات وتنظيمها، من خلال مراجعة الأدبيات العلمية الحديثة والدراسات السابقة ذات الصلة بمجالي النماذج اللغوية الكبيرة واسترجاع المعلومات في البيئة الرقمية.

وقد اتبعت الدراسة الخطوات الآتية:

1. جمع المصادر العلمية: تم حصر عدد من الدراسات والمقالات التقنية الصادرة عن جهات أكاديمية ومؤسسات تقنية رائدة، تغطي الفترة من 2020 حتى 2025.
2. تصنيف المعلومات: جرى تصنيف البيانات المستخلصة من المصادر إلى محاور رئيسية تعكس أهداف الدراسة، مثل: قدرات النماذج اللغوية، آليات الاسترجاع، والتحديات التقنية.
3. التحليل والمقارنة: تم تحليل محتوى الدراسات المقروءة بهدف استخلاص الاتجاهات النظرية والفروق بين الأساليب التقليدية والحديثة في استرجاع المعلومات.
4. الاستخلاص النظري: بناء على التحليل، تم توليد استنتاجات نظرية وتطبيقية، وطرح فرص للتحسين والبحث المستقبلي.

## التحليل النظري والنتائج

### أولاً: مدخل إلى النماذج اللغوية الكبيرة

شهدت السنوات الأخيرة تقدمًا سريعًا في مجال الذكاء الاصطناعي، كان من أبرز ملامحه تطور النماذج اللغوية الكبيرة (LLMs). وقد مثلت هذه النماذج نقلة نوعية في معالجة اللغة الطبيعية، لما تمتلكه من قدرة على فهم السياق وتوليد النصوص بطريقة تحاكي اللغة البشرية. وأصبحت هذه النماذج أدوات مركزية في أنظمة الحوار، واسترجاع المعلومات، وتحليل البيانات النصية. ويتطلب فهم هذه النماذج النظر في مفاهيمها الأساسية، وبنيتها، وآلية عملها، إلى جانب تتبع تطورها الزمني والنماذج البارزة التي ظهرت في سياقها.

### مفهوم النماذج اللغوية الكبيرة:

برزت النماذج اللغوية الكبيرة (Large Language Models - LLMs) كواحدة من أكثر التقنيات تأثيرًا وانتشارًا في ظل هيمنة الذكاء الاصطناعي. ولفهم هذا المفهوم بشيء من التفصيل، تجدر الإشارة إلى عرض مجموعة من التعاريف العلمية المتنوعة التي توضح طبيعة هذه النماذج وبنيتها التقنية.

النماذج اللغوية الكبيرة هي نماذج ذكاء اصطناعي تعتمد على بنية المحولات (Transformers). يتم تدريبها على كميات ضخمة من البيانات النصية من أجل فهم اللغة البشرية ودلالاتها. تعتمد هذه النماذج على تقسيم النصوص إلى وحدات صغيرة تُعرف بالرموز (Tokens)، وهي وحدات تمثل أساس المعالجة اللغوية داخل النموذج. كما يتيح للمستخدمين التفاعل باللغة الطبيعية عبر طرح الأسئلة والحصول على إجابات داعمة للمهام المختلفة. (عوض، 2024؛ أبو غنيمة والزعليك، 2024)

وتُوصف أيضاً بأنها نماذج شبكية عصبية متقدمة، تهدف إلى معالجة اللغة البشرية باستخدام التحليل الدلالي والترميز (Tokenization). تعتمد على إنشاء تمثيلات رقمية (Embedding Vectors) للنصوص، مما يمكنها من التقاط المعاني والسياقات بدقة عالية. تُستخدم هذه التمثيلات في تطبيقات مثل استرجاع المعلومات وتوليد النصوص. (Urista, 2024)

في السياق ذاته، تشير الدراسات إلى أن النماذج اللغوية الكبيرة تنتمي إلى فئة من نماذج التعلم الآلي (Machine Learning Models) التي يتم تدريبها على مجموعات نصية ضخمة، لإمداد النموذج بقدرة عالية على فهم اللغة الطبيعية وتوليدها بأسلوب منظم. وتعتمد المعرفة التي تكتسبها هذه النماذج على ما يُعرف ببارامترات أو معلمات النموذج (Model Parameters)، التي تحتفظ ضمناً بالمعلومات المستفادة خلال التدريب. (Lewis et al., 2021)

ومن التطبيقات التي تعكس قدرات النماذج اللغوية الكبيرة، نظام مولدات المحادثات الاسترجاعية (ChatGPT) الذي يمثل مثلاً واضحاً على استخدام هذه التقنية. ويُستخدم هذا النظام في برمجيات الحوار، حيث يتيح للمستخدم طرح الاستفسارات من خلال واجهة نصية، ويقوم النظام بإعطاء إجابات تعتمد على احتمالية تسلسل الرموز حتى يصل إلى نقطة إنهاء للإجابة. تعمل هذه التقنية بطريقة قريبة من تقنيات معالجة اللغة الطبيعية. (إبراهيم وزكريا، 2023)

ومن هنا، يتضح أن النماذج اللغوية الكبيرة (LLMs) تُعد من أبرز التطورات في مجال الذكاء الاصطناعي القائم على اللغة. فهي تمثل نقلة نوعية في كيفية معالجة اللغة الطبيعية من خلال قدرتها على فهم المعاني والسياقات وتوليد نصوص منطقية ومتناسكة. وتعتمد هذه النماذج على تقنيات معقدة مثل بنية المحولات والترميز والتمثيلات العددية، مما يجعلها أداة فعالة في مختلف التطبيقات الرقمية، بما في ذلك أنظمة الحوار التفاعلي مثل (ChatGPT). وتُعد هذه القدرات مؤشراً على التداخل العميق بين الذكاء الاصطناعي واللغة، مما يمنح هذه النماذج دوراً محورياً في تطوير بيئات تعليمية ذكية ومنظومات معرفية متقدمة.

### نشأة وتطور النماذج اللغوية الكبيرة:

لاقت النماذج اللغوية الكبيرة مسيرة تطويرية من تجارب بسيطة في محاكاة الحوار البشري إلى أنظمة ذكية قادرة على فهم السياقات المعقدة. بدأت الرحلة مع أنظمة قائمة على القواعد المحددة مسبقاً في ستينيات القرن الماضي، مروراً بالثورة الإحصائية مع انتشار الويب، ووصولاً إلى عصر الذكاء الاصطناعي التوليدي بفضل تقنيات التعلم العميق. هذا المحور يُسلط الضوء على المراحل الرئيسية لهذا التطور، مع عرض العوامل التقنية التي شكلت المشهد الحالي للنماذج اللغوية الكبيرة.

النشأة التاريخية: تعود جذور النماذج اللغوية إلى ستينيات القرن الماضي مع ظهور إيزا (ELIZA) عام 1966 في معهد ماساتشوستس للتكنولوجيا (MIT)، وهي أول محاولة لمحاكاة الحوار البشري باستخدام قواعد محددة مسبقاً. وفي الثمانينيات، طورت شركة (IBM) نماذج صغيرة تعتمد على الإحصاءات البسيطة للتنبؤ بالكلمة التالية في الجملة باستخدام قاموس إحصائي محدود. (Harvard Business Review, n.d.) (McDonough, 2025,

التحول نحو النماذج الإحصائية والعصبية: مع انتشار الويب عام 1991، أصبحت مجموعات البيانات اللغوية الضخمة متاحة، مما مهد الطريق لظهور نماذج إحصائية متقدمة تستخدم خوارزميات تعتمد فقط على الحدث السابق الأخير ولا تتأثر بأحداث سابقة أخرى. وبحلول العقد الأول من القرن الحادي والعشرين، أدى التقدم في الشبكات العصبية المتكررة (RNNs) إلى تحسين فهم السياقات اللغوية. (Pakhale, 2023)

ثورة المحولات: شكل عام 2017 نقطة تحول مع ظهور نماذج المحولات (Transformers)، التي سمحت بمعالجة النصوص بطريقة متوازنة، مما أدى إلى تطوير نماذج لغوية كبيرة (LLMs) مثل (BERT) من (Google)، وكذلك (GPT) الذي تم تطويره من (OpenAI). (McDonough, 2025; Foote, 2023)

التطورات الحديثة (2020-2024): شهدت الفترة الأخيرة تحول النماذج من أحادية الوسيط (Unimodal) إلى متعددة الوسائط (Multimodal)، مثل النماذج القادرة على معالجة النصوص والصور معاً. كما ظهرت أجيال جديدة مثل (GPT-4) وكذلك (Llama3) المطور من قبل (Meta) تستخدم في عملياتها تقنيات جديدة مثل سلسلة الفكر (Chain-of-Thought). (Guinness, 2025)

ومما سبق تتضح الرؤية حول نشأة وتطور النماذج اللغوية الكبيرة، حيث ارتبط بشكل وثيق بالتقدم في تقنيات التعلم العميق وتوفر البيانات الضخمة. ابتداءً من الأنظمة البسيطة القائمة على القواعد، مروراً بالثورة الإحصائية، ووصولاً إلى عصر الذكاء الاصطناعي التوليدي، شكلت كل مرحلة نقلة نوعية في قدرة النماذج

على فهم اللغة البشرية. وتُعد هذه التطورات أساسية لفهم دور النماذج اللغوية الكبيرة في تحسين استرجاع المعلومات البيئية الرقمية المعاصرة.

### قدرات النماذج اللغوية الكبيرة:

تميزت النماذج اللغوية الكبيرة بقدرتها على أداء مجموعة واسعة من المهام اللغوية المعقدة. فهي تستمد قوتها من قدرتها على معالجة كميات ضخمة من البيانات، وتحليل السياقات النصية بدقة. ومع اعتمادها على بنية المحولات وآليات التعلم العميق، أصبحت هذه النماذج إحدى الركائز التقنية لمعالجة اللغة الطبيعية. ويتمثل هذا المحور في تقديم قدرات هذه النماذج.

تتمتع النماذج اللغوية الكبيرة بقدرة متقدمة على فهم اللغة البشرية بجوانبها المعجمية والدلالية، إذ يمكنها تحليل السياق، واستنتاج المعاني الضمنية، ومعالجة العبارات المعقدة. كما تُظهر كفاءة واضحة في توليد اللغة من خلال إنشاء نصوص متماسكة ومنطقية تشبه النصوص البشرية في البنية والوضوح. وتُستخدم هذه القدرات في مهام مثل الترجمة، وتلخيص النصوص، وكتابة المحتوى الإبداعي، والإجابة على الاستعلامات، والتفاعل الفوري مع المستخدم عبر بيانات المحادثة. (Muhammad, 2025; Guinness, 2025)

ومن أبرز قدراتها، تحويل النصوص إلى متجهات دلالية (Embedding Vectors)، مما يمكنها من استرجاع المعلومات بناءً على تشابه المعنى بدلاً من المطابقة الحرفية. ومن خلال هذه التمثيلات، تتمكن النماذج اللغوية الكبيرة من تفسير نية المستخدم، وتقديم نتائج أكثر دقة في الاستجابة للاستعلامات المعقدة. ولا تعتمد هذه الاستجابات على مطابقة الكلمات المفتاحية، بل على فهم السياق الكامل للاستعلام. (Urista, 2024)

كما أن هذه النماذج قادرة على تكيف ذاتها لأداء مهام لغوية متنوعة تتجاوز حدود التوليد اللغوي، مثل بناء استعلامات بحث بديلة، وتحليل الاستعلام الأصلي لفهم المقصد، ومن ثم تقييم مدى صلة كل مصدر معلومات أو وثيقة بالمحتوى المطلوب. وتُعد هذه القدرة أساسية في دعم استرجاع المعلومات القائم على الفهم الدلالي. (Pakhale, 2023)

وتتميز النماذج اللغوية الكبيرة كذلك بما يُعرف بالقدرات الناشئة (Emergent Abilities)، وهي تلك المهارات التي تظهر عند تدريب النموذج على كميات ضخمة من البيانات دون أن تكون مبرمجة فيه بشكل صريح. وتشمل هذه القدرات التعامل مع مهام منطقية واستنتاجية مثل التعميم (Generalization) والاستدلال (Reasoning)، إلى جانب إعادة كتابة الاستعلامات، وتحسين ترتيب النتائج، والتفاعل مع نصوص طويلة بطريقة تضمن الحفاظ على الترابط المنطقي والفهم الشامل للمحتوى. (Lewis et al., Zhu et al., 2024)

2021,

بالإضافة إلى ذلك، توسع استخدام النماذج اللغوية الكبيرة في المهام اللغوية يعود إلى بنيتها الرياضية التي تعتمد على نمذجة احتمالية تسلسل الكلمات. فهي تُقدّر احتمال ظهور كلمة معينة استنادًا إلى الكلمات السابقة في النص، مما يجعلها قادرة على إنتاج نص منطقي ومرتبطة من حيث السياق، وهو ما يمثل الأساس في جميع مهام اللغة الطبيعية من الفهم إلى التفاعل. (Pakhale, 2023)

وفي ضوء ما سبق، تبين قدرات النماذج اللغوية الكبيرة التي لا تقتصر على الفهم اللغوي العميق، بل تمتد إلى تحسين جودة التفاعل بين الإنسان والآلة عبر تطبيقات مثل إعادة صياغة الاستعلامات وتقييم صلة الوثائق. فهذه النماذج لم تعد أدوات لتوليد نصوص فقط، بل أصبحت أنظمة معرفية تتعامل مع اللغة كالبشر يتغير بحسب السياق والهدف. حيث إن التركيز على التشابه الدلالي يمثل نقلة نوعية عن الأساليب التقليدية القائمة على المطابقة الكلمة بالكلمة. وبذلك، تُبرز أهمية دراسة توظيف هذه القدرات لتعزيز أنظمة استرجاع المعلومات.

#### آلية عمل النماذج اللغوية الكبيرة:

تُعد آلية عمل النماذج اللغوية الكبيرة من أكثر الجوانب التقنية تعقيدًا في مجال الذكاء الاصطناعي. إذ تعتمد هذه النماذج على بنى رياضية معقدة تُحاكي طريقة الإنسان في فهم اللغة واستيعاب المعاني. ولكي تؤدي هذه النماذج وظائفها بكفاءة، تمر بعدة مراحل تتكامل فيها مفاهيم مثل التمثيل الرقمي، والتعلم من السياق، والضبط الدقيق. هذا المحور يقدم فكرة عن الآليات التي تتعامل معها النماذج اللغوية الكبيرة في سير عملها.

تعتمد النماذج اللغوية الكبيرة على تحويل النصوص إلى تمثيلات عددية تُعرف بمتجهات التضمين الدلالي (Semantic Embedding Vectors)، وهي متجهات عالية الأبعاد تُمثل العلاقات بين الكلمات بشكل رياضي. وعند إدخال استعلام معين، يتم تمثيله رقميًا ثم مقارنته بالتمثيلات المخزنة في قاعدة البيانات الشعاعية، مما يسمح باسترجاع الأجزاء الأكثر تشابهًا من حيث المعنى والسياق، ويُعزز من دقة النتائج المسترجعة.

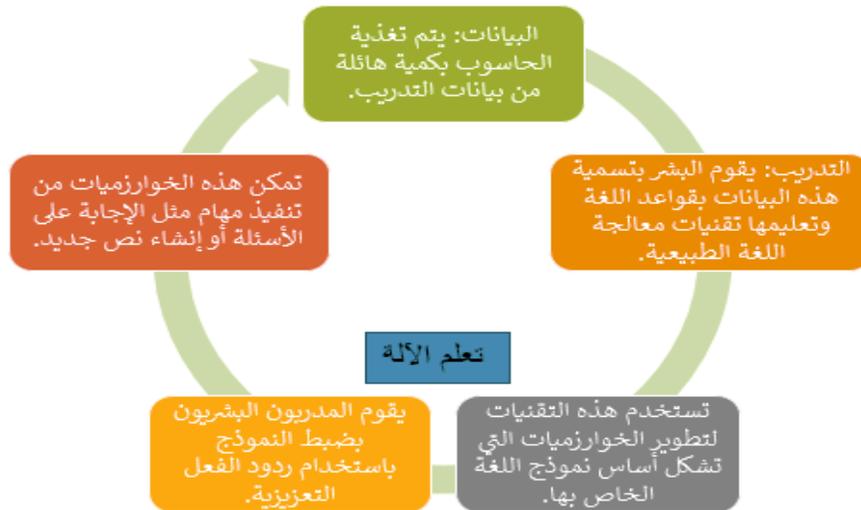
(Amazon Web Services, n.d.; Urista, 2024)

البنية الأساسية لهذه النماذج تعتمد على ما يُعرف بالمحولات (Transformers)، وهي بنية تعتمد على الشبكات العصبية المصممة خصيصًا للتعامل مع تسلسلات البيانات اللغوية. وتتمثل المكونات الرئيسية في جزأين: التمثيل الرقمي (Encoder) الذي يحول النصوص إلى تمثيلات رقمية [0:1] أي بلغة الحاسوب، والتمثيل النصي (Decoder) الذي يُعيد إنتاجها إلى لغة مفهومة أي لغة البشر. هذا يجعل النماذج قادرة على فهم العلاقات بين الكلمات بناءً على المواقع النسبية والترابطات الإحصائية. (Zhu et al., 2024; Amazon Web Services, n.d.)

وتمر النماذج اللغوية الكبيرة بمراحل تشغيلية رئيسية، أولها مرحلة التدريب التي تعتمد على كميات ضخمة من البيانات النصية مثل الكتب والمقالات ومواقع الإنترنت. ومن خلالها، تتعلم النماذج الأنماط الإحصائية اللغوية، وتبني شبكة من العلاقات بين الكلمات تُستخدم لاحقاً للتنبؤ بالكلمة التالية أو استكمال النصوص. وتعتمد على آلية "الانتباه الذاتي" (Self-Attention) لفهم موضع كل كلمة بالنسبة إلى الأخرى، مما يُمكنها من التعامل مع السياقات الطويلة. (Guinness, 2025)

وبعد التدريب الأولي، تأتي مرحلة الضبط الدقيق (Fine-Tuning) لضبط سلوك النموذج اللغوي الكبير بناءً على تطبيقات محددة. وقد تطورت هذه المرحلة إلى استراتيجيات أكثر فاعلية مثل ما يعرف بالتعلم داخل السياق (In-Context Learning) الذي يُمكن النموذج من الاستجابة بناءً على أمثلة داخل النص دون تعديل في معلماته، وأيضاً ما يُعرف بالضبط الدقيق الفعّال للمعلمات (Efficient Fine-Tuning of Parameters)، وهي طريقة لتقليل الموارد المستخدمة أثناء التشغيل مع الحفاظ على الأداء. (Pakhale, 2023؛ Zhu et al., 2024)

وفي الشكل التالي توضيح لمراحل التدريب التي تمر بها النماذج اللغوية الكبيرة ابتداءً من تغذية الحاسوب بالبيانات الضخمة مروراً بالتدريب والتطوير والضبط وانتهاءً عند قدرة هذه النماذج من تنفيذ مهام الإجابة على استفسارات المستخدمين وحتى توليد وتلخيص نصوص جديدة.



شكل رقم (1): خطوات عمل النماذج اللغوية الكبيرة. المصدر (Guinness, 2025)

وبعد التعرض لمجموعة من الآليات التي تعتمد عليها النماذج اللغوية الكبيرة في عملها، سيتم تلخيص أهم المراحل وخطوات العمل في الشكل الآتي:



شكل رقم 2: ملخص مراحل وخطوات عمل النماذج اللغوية الكبيرة. (الباحث)

وبذلك، تبرز آلية عمل النماذج اللغوية الكبيرة بوصفها حلقة الوصل بين البنية الرياضية للنموذج وقدرته اللغوية الظاهرة. فمن خلال مراحل التدريب، والتحليل، وضبط السياق، تصل هذه النماذج إلى أداء متقدم يُظهر الفهم العالي للسياقات النصية. ومع أن الآلية تقوم على التنبؤ الإحصائي أكثر من الفهم الحقيقي، إلا أنها تظل فعالة وواعدة في تطبيقات استرجاع المعلومات التي تعتمد على التشابه المعنوي والتفاعل اللغوي الطبيعي.

### أبرز النماذج اللغوية الكبيرة في المشهد التقني:

يشهد الجانب التقني في الوقت الحالي تنوعًا كبيرًا في النماذج اللغوية الكبيرة، سواء من حيث البنية أو الغرض أو بيئة الاستخدام. وقد تعددت هذه النماذج بتعدد الجهات المطورة لها، وتباينت قدراتها بين التوليد والفهم والتحليل. لفهم المشهد التقني الحالي بدقة، تجدر الإشارة في هذا المحور إلى أبرز النماذج المنتشرة.

يُعد (GPT-4) من أكثر النماذج انتشارًا، وهو من إنتاج شركة (OpenAI)، ويتميز بقدرته على دعم المهام متعددة الوسائط، كما أنه يُستخدم على نطاق واسع في تطبيقات مثل إنشاء المحتوى، والمساعدة في البرمجة،

وبناء وكلاء ذكاء اصطناعي. ومن النماذج المتقدمة أيضًا (LlamaIndex) الذي يُستخدم كمنصة تكامل للنماذج اللغوية الكبيرة داخل نظم الاسترجاع، إضافة إلى النماذج التي تُستخدم بشكل خاص في تحويل النصوص إلى تمثيلات دلالية تُستخدم في البحث الدلالي مثل نموذج (BERT). (Urista, 2024؛ Muhammad, 2025) وقد صنّفت النماذج اللغوية إلى ثلاث فئات رئيسية. الفئة الأولى هي النماذج الاحتكارية أو مغلقة المصدر (Proprietary Models)، ومنها نموذج (GPT-4o) الذي يحتوي على أكثر من 175 مليار معلمة، ويدعم المهام متعددة الوسائط، ونموذج (Claude 3.5) من إنتاج شركة (Anthropic) الذي يتميز بسعة خارقة سياقية تصل إلى 200 ألف رمز. هذه النماذج عادة ما تكون مغلقة المصدر وتخضع لسياسات وصول صارمة. إما الفئة الثانية فهي النماذج مفتوحة المصدر (Open Models)، مثل نموذج (Llama 3) من إنتاج (Meta) الذي يتوفر بعدة أحجام تصل إلى 405 مليار معلمة، ونموذج (Gemma 2) من شركة (Google) الذي يُعد نسخة مصغرة من (Gemini). هذه النماذج تسمح بالمرونة والتخصيص، ولكنها تخضع لبعض قيود الترخيص. بينما الفئة الثالثة وهي النماذج المتخصصة (Specialized Models)، ومنها نموذج (DeepSeek R1) الذي يُعد من أوائل النماذج المفتوحة المصممة لدعم التفكير المنطقي، ونموذج (Phi-3) من إنتاج شركة (Microsoft) المصمم للعمل على أجهزة منخفضة الموارد. (Guinness, 2025)

كما تتباين النماذج من حيث القدرات التقنية، إذ أظهرت نماذج مثل (GPT-4o) و(Gemini) تميزًا في دعم الوسائط المتعددة، بينما برزت نماذج مثل (DeepSeek R1) في مهام التفكير المنطقي وحل المشكلات المعقدة. على المستوى التقني، وتفوقت النماذج الكبيرة مثل (Llama 3) و(GPT-4o) في معالجة المهام الثقيلة والمعقدة، بينما أثبتت النماذج الصغيرة مثل (Phi-3) فعاليتها في البيئات ذات الموارد المحدودة. (Guinness, 2025)

ومن النماذج الأخرى الجديرة بالذكر نموذج (LaMDA) المطوّر من (Google)، والموجه للمحادثة المفتوحة، لكنه يظل في نطاق البحث وغير متاح بشكل واسع. ونموذج (T5) الذي يعتمد أسلوب تحويل جميع مهام معالجة اللغة على توليد نص من نص آخر. كما يبرز نموذج (Grok) بتوجهه نحو التفاعل العفوي وغير الرسمي، في حين يتميز نموذج (Claude) بقدرته على تلخيص النصوص الطويلة وفهم المستندات. أما نموذج (Mistral) فهو نموذج مفتوح المصدر موجّه للبيئات ذات الأداء المحدود والزمن المنخفض للاستجابة. (Muhammad, 2025)

يظهر الجدول التالي مقارنة بين أبرز النماذج اللغوية الكبيرة ضمن مجموعة من الأبعاد المختلفة، وقد تم جمع هذه المعلومات من مصادر مختلفة.

جدول (1): مقارنة بين أبرز النماذج اللغوية الكبيرة. المصدر: (Guinness, 2025, Muhammad, 2025)

النموذج اللغوي	المطور	الاستدلال الاسم الاسم الاسم	الوصول	حجم المعلمات (البارامترات)	السرعة	أفضل حالة استخدام
GPT-4	OpenAI	×	روبوت المحادثة وواجهة برمجة التطبيقات	~1.8T	متوسط إلى بطيء	الذكاء الاصطناعي للأغراض العامة، والكتابة الإبداعية، وتوليد التعليمات البرمجية، والروبوتات الدردشة المتقدمة
BERT	Google		مفتوح المصدر	1.27B	سريع	تصنيف النصوص، تحليل المشاعر، ترتيب البحث
Gemini	Google	×	روبوت المحادثة وواجهة برمجة التطبيقات	لا يوجد رقم رسمي	سريع	المهام متعددة الوسائط، والترميز، والتفكير، والبحث، واستخدام المؤسسات
Gemma	Google	×	مفتوح المصدر			
LLaMA	Meta	×	روبوت المحادثة ومفتوح المصدر	400B	سريع إلى متوسط	تطبيقات الذكاء الاصطناعي المخصصة، والبحث الأكاديمي، والنشر مفتوح المصدر
R1	DeepSeek	✓	روبوت المحادثة وواجهة برمجة التطبيقات ومفتوح المصدر			
V3	DeepSeek	×	روبوت المحادثة وواجهة برمجة التطبيقات ومفتوح المصدر			
Claude	Anthropic	✓	روبوت المحادثة وواجهة برمجة التطبيقات	لا يوجد رقم رسمي	متوسط	الاستدلال المطول، والذكاء الاصطناعي الآمن للأعمال، والأسئلة والأجوبة حول المستندات، والترميز
Command	Cohere	×	واجهة برمجة التطبيقات			
Nova	Amazon	×	واجهة برمجة التطبيقات			
Large 2	Mistral AI	×	واجهة برمجة التطبيقات			
Qwen	Alibaba Cloud	×	روبوت المحادثة وواجهة برمجة التطبيقات ومفتوح المصدر			
Phi	Microsoft	×	مفتوح المصدر			
Grok	xAI	✓	روبوت المحادثة وواجهة برمجة التطبيقات	314B	متوسط	المحادثات الحادة، الحوارات الجدلية، الفكاهة، والأسئلة والأجوبة عفوية.
LaMDA	Google		مغلق المصدر (وصول محدود)	Up to 137B	متوسط	الذكاء الاصطناعي للمحادثة وأنظمة الحوار (تركز على البحث)
T5	Google		مفتوح المصدر	~11B	متوسط	الترجمة والتلخيص والأسئلة والأجوبة الاستخراجية والتوليدية
Mistral	Mistral AI		مفتوح المصدر	140.6B	سريع	تطبيقات بزمان وصول منخفض، وعمليات نشر مضبوطة، واستخراج البيانات المنظمة

ومما سبق لوحظ التباين الكبير في النماذج اللغوية الكبيرة من حيث القدرات والأداء وسياسات الوصول، مما يعكس التوجهات المختلفة للشركات في تطوير هذه التقنيات. في حين تتفوق النماذج الاحتكارية في الأداء الشامل، وتوفر النماذج المفتوحة مرونة أكبر للتخصيص والابتكار. كما أن ظهور النماذج المتخصصة يشير إلى توجه نحو تحسين الكفاءة وتلبية احتياجات محددة.

كما يعكس تنوع النماذج اللغوية الكبيرة وتفاوت قدراتها اتساع نطاق استخدامها في مختلف التطبيقات التقنية. إذ لم تعد هذه النماذج مقتصرة على التوليد النصي، بل أصبحت مكونات بنوية في نظم التفكير والتحليل والتفاعل. هذا التنوع يبرر الحاجة إلى فهم عميق لقدرات كل نموذج قبل توظيفه، خاصة في سياق استرجاع المعلومات الذي يتطلب موازنة دقيقة بين الدقة، والكفاءة، وسرعة الأداء.

### ثانياً: استرجاع المعلومات في البيئة الرقمية: المفهوم والأساليب

يعتبر استرجاع المعلومات ركيزة أساسية في بنية البيئة الرقمية، نتيجة لتضخم حجم المحتوى وتنوع مصادر البيانات. وتتمثل الوظيفة الرئيسية لأنظمة الاسترجاع في تمكين المستخدم من الوصول إلى المعلومات ذات الصلة بكفاءة وسرعة، وسط كمية هائلة من البيانات غير المنظمة. ومع تنامي تطور الوسائط والواجهات الرقمية، تنوعت الأساليب المستخدمة بين تقليدية تستند إلى المطابقة الحرفية، وأخرى حديثة تعتمد على الذكاء الاصطناعي وتحليل اللغة. فأصبح من الضرورة فهم الأسس النظرية لهذه الأساليب لتقييم مدى فعاليتها واستجابتها لاحتياجات المستخدمين في العصر الرقمي. ويُعد هذا المحور تمهيداً رئيسياً لفهم التحول في بنية الاسترجاع وآليات التفاعل بين النظام والمستخدم.

### المفهوم العام لاسترجاع المعلومات:

يُعد استرجاع المعلومات من المفاهيم المركزية في علوم الحاسوب والمعلومات، إذ يُعنى بربط المستخدمين بالمصادر الرقمية ذات الصلة بحاجاتهم البحثية. وقد تعاضت أهمية هذا المفهوم مع تزايد حجم البيانات الرقمية، وتنامي الحاجة إلى أدوات ذكية قادرة على تصفية وانتقاء المعلومات المتاحة. وفي بيئة رقمية معقدة، باتت أنظمة الاسترجاع أداة حيوية في تسهيل الوصول المعرفي. لذا يقدم هذا المحور مجموعة من التعاريف التي تُجلى أهمية هذا المفهوم.

يُعرّف استرجاع المعلومات (Information Retrieval) بأنه العملية المنهجية للوصول إلى الوثائق أو البيانات غير المهيكلة من بين كميات ضخمة من المحتوى، بهدف تلبية استعلام المستخدم بكفاءة وفاعلية. فيقوم نظام الاسترجاع بتحليل الاستعلام المدخل، ثم يُطابقه مع محتوى مستودعات البيانات ليُعيد العناصر ذات الصلة،

و غالبًا ما يُرتَّب النتائج وفق مقياس الصلة أو الأهمية. وتُستخدم هذه الأنظمة في تطبيقات متعددة مثل محركات البحث، وفهارس المكتبات، وأنظمة التوصية وما إلى ذلك. (Tyson, 2024؛ Murel & Syed, 2024)

كما يُنظر إلى هذا المفهوم على أنه يشمل أدوات وتقنيات تتيح البحث عن الرموز أو الأوعية المعرفية من مصادر متعددة، سواء كانت مهيكلة أو شبه مهيكلة أو غير مهيكلة. ولا تقتصر عملية الاسترجاع على العثور على المستندات فحسب، بل تشمل أيضًا تصنيفها وتقييمها بناءً على ملاءمتها لحاجة المستخدم، باستخدام نماذج حسابية تُطابق بين خصائص الاستعلام ومحتوى الوثائق. (Haziqua, 2024؛ أحمد وعبدالكريم، 2023)

وقد شهد هذا المفهوم تطورًا واضحًا منذ بداياته، إذ بدأ بالاعتماد على المطابقة الحرفية للكلمات، ثم تطوّر ليُدمج تقنيات أكثر تقدمًا كالتحليل الدلالي والنماذج الإحصائية، إلى أن بلغ ذروته مؤخرًا بدمجه في نظم الذكاء الاصطناعي التوليدي. ويُعد استرجاع المعلومات أحد الأعمدة الأساسية في أنظمة الاسترجاع المعزز بالتوليد (Retrieval-Augmented Generation)، التي تُسهم في رفع كفاءة أنظمة الذكاء الاصطناعي في فهم اللغة وتقديم المعلومة ذات الصلة. (Tyson, 2024؛ Zhu et al., 2024)

وبناءً على ما تقدم، يُمثل استرجاع المعلومات حجر الأساس في أي بيئة معرفية رقمية، حيث تتقاطع فيه تقنيات البحث، ومعالجة اللغة، وتنظيم المحتوى. ويتجاوز المفهوم كونه إجراءً فنيًا إلى كونه أداة معرفية تُسهم في تمكين الأفراد والمؤسسات من الوصول السريع والدقيق إلى المعلومات ذات الصلة. ومع توسع البيئات الرقمية، ازدادت الحاجة إلى أنظمة استرجاع تتسم بالذكاء والمرونة، وهو ما أفسح المجال أمام دمج تقنيات جديدة مثل النماذج اللغوية الكبيرة. ويُمهّد هذا المحور لفهم أعمق للأساليب التقليدية والحديثة في معالجة الاستعلامات، كما أنه يُعرض الأساس المفاهيمي لفهم تحوّل نظم الاسترجاع في العصر الرقمي.

#### الأساليب التقليدية في استرجاع المعلومات:

اعتمدت أنظمة استرجاع المعلومات في مراحلها الأولى على أساليب محددة تستند إلى تطابق الكلمات المفتاحية والتحليل الإحصائي البسيط. وقد كانت هذه الأساليب فعالة في فترات سابقة، عندما كان حجم البيانات محدودًا نسبيًا، وكانت احتياجات المستخدمين أكثر بساطة. ومع تطور البيئة الرقمية، بدأت تظهر حدود هذه الأساليب في التعامل مع الاستعلامات المعقدة، خاصة فيما يتعلق بفهم السياق والمعنى. هذا المحور يقدم لمحة عن تلك الأساليب ومراحل تقدمها.

من أقدم الأساليب ما يُعرف بالنموذج البوليني أو المنطقي (Boolean Model)، الذي يعتمد على منطق "الوجود أو الغياب" للكلمات داخل الوثائق. إذ يقوم النظام باسترجاع الوثائق التي تحتوي على الكلمات المطابقة

تمامًا للاستعلام، دون الأخذ بعين الاعتبار أي دلالة سياقية أو معنوية. ويُعد هذا النموذج محدودًا من حيث المرونة لكنه بسيط وسريع في التطبيقات التي تتطلب نتائج دقيقة في مطابقة الكلمات. (Zhu et al., 2024)

إما نموذج الفضاء المتجهي (Vector Space Model) فيُعد تطورًا على النموذج البوليني، حيث يسمح بالمطابقة الجزئية بين الاستعلام والوثائق. وفي هذا النموذج يتم تمثيل كل وثيقة واستعلام على شكل متجه (سهم) داخل فضاء رياضي عالي الأبعاد، ويُحسب التشابه بين المتجهات باستخدام قياسات مثل جيب الزاوية (Cosine Similarity) الذي يقيس مدى "تقارب" اتجاهات الأسهم بين (الاستعلام والمستندات)، فكلما كانت الزاوية أصغر، كان التشابه أكبر، وبالتالي كانت الوثيقة أكثر ملاءمة للاستعلام. هذا يسمح بترتيب الوثائق وفقًا لدرجة ملاءمتها، بدلًا من اعتماد المطابقة المطلقة فقط. (Zhu et al., 2024)

ومن الأساليب الشائعة كذلك تقنية (Term Frequency–Inverse Document Frequency) واختصارها (TF-IDF)، وتقوم بمنح وزن لكل مصطلح بناءً على مدى تكراره في وثيقة معينة مقارنةً بتكراره في بقية الوثائق. هذه التقنية تُستخدم لتمييز الكلمات الأهم داخل مجموعة نصوص، وتعتمد فقط على التكرار الكمي للكلمات. (Urista, 2024)

ثم ظهر فيما بعد تقنية (Best Matching 25-BM25)، وهي تطوير على تقنية (TF-IDF) من خلال إدخال عوامل مثل طول الوثيقة وتكرار المصطلحات بطريقة محسّنة. حيث تساعد هذه التقنية في تحسين التصنيف، لكنها لا تزال غير قادرة على التعامل مع المعاني المتعددة أو المرادفات. (Urista, 2024)

ومن النماذج التقليدية الأخرى نماذج اللغة الإحصائية (Statistical Language Models)، التي تعتمد على مبادئ الاحتمالات لتقدير مدى ارتباط الوثيقة بالاستعلام. وتقوم هذه النماذج بتحليل الأنماط اللغوية استنادًا إلى تكرار الكلمات وتوزيعها، وتُعد أكثر قدرة من النماذج السابقة على التقاط إشارات دلالية، لكنها تظل أقل مرونة من النماذج اللغوية الحديثة. (Zhu et al., 2024)

كما تعتمد كثير من تقنيات البحث التقليدية على آليات "التتبع" (Crawling) و"الفهرسة" (Indexing) و"الترتيب" (Ranking). تقوم هذه العمليات بجمع صفحات الويب، وتحليلها، وتخزينها بطريقة منظمة، ثم استرجاعها بناءً على تطابق الكلمات المفتاحية، مما يجعل محركات البحث قادرة على تقديم نتائج مرتبة بحسب أهميتها الظاهرة، لا بحسب الفهم المعنوي. (Nanni, 2023)

ومما سبق، تكشف الأساليب التقليدية في استرجاع المعلومات عن مراحل تطور مبكر اعتمد على المطابقة الشكلية بين الكلمات، دون النفاذ إلى أعماق المعنى أو فهم السياق. ورغم أن هذه الأساليب كانت مناسبة في بدايات العصر الرقمي، فإن محدوديتها في التعامل مع اللغة البشرية كما هي، دفعت نحو البحث عن بدائل أكثر

ذكاء وقدرة على المعالجة السياقية، وهو ما مهد الطريق أمام النماذج اللغوية الكبيرة في إعادة تشكيل آليات الاسترجاع الحديثة.

### التحديات المرتبطة بالأساليب التقليدية:

رغم أن الأساليب التقليدية لاسترجاع المعلومات شكلت الأساس الأول لأنظمة البحث الرقمية، إلا أن اعتمادها على تقنيات محدودة جعلها تواجه صعوبات متزايدة مع تطور طبيعة المحتوى الرقمي وتنوع استعلامات المستخدمين. لذا، يركز هذا المحور على الوقوف على أبرز أوجه القصور المتعلقة باسترجاع المعلومات التقليدي لفهم الحاجة إلى حلول ذكية بديلة، وهي كالاتي:

- ضعف التعامل مع غموض اللغة الطبيعية؛ فعلى سبيل المثال يفتقر النموذج البوليفوني إلى المرونة اللازمة لفهم دلالات الكلمات وتباين معناها داخل السياق، إذ يعالج المصطلحات من منظور منطقي بحت، مما يجعله غير مناسب للاستعلامات المركبة أو غير المباشرة. (Zhu et al., 2024)
- الاعتماد على المطابقة الحرفية؛ حيث تعتمد أساليب مثل (TF-IDF) و (BM25) على المطابقة المباشرة بين كلمات الاستعلام وكلمات الوثائق دون مراعاة للمرادفات أو التعبيرات القريبة، مما يؤدي إلى ضعف في دقة النتائج عند اختلاف الألفاظ. (Urista, 2024)
- قصور في فهم السياق والمعاني المركبة؛ حيث تعجز الأنظمة التقليدية عن ربط المصطلحات بسياقها الدقيق، وتفشل في تفسير الاستعلامات ذات المستويات الدلالية المتعددة أو التي تتطلب دمج مفاهيم متشابهة. كما تواجه أيضًا صعوبات في فهم اللغة غير الرسمية أو اللغة الطبيعية التي يستخدمها الأفراد في استعلاماتهم اليومية. (Urista, 2024)
- ضعف استراتيجيات إعادة كتابة الاستعلامات؛ حيث تعتمد الأساليب التقليدية على أدوات كالمعاجم أو المكنز لإعادة صياغة الاستعلامات، لكن فعاليتها تبقى محدودة، وقد تؤدي إلى نتائج لا تعكس نية المستخدم بدقة رغم التشابه الظاهري في الكلمات. (Zhu et al., 2024)
- ثبات ترتيب النتائج؛ تعاني الأنظمة التقليدية من الجمود في ترتيب النتائج، إذ تعتمد على خوارزميات مبرمجة سلفًا دون تكيف مع طبيعة المستخدم أو السياق اللحظي، مما يضعف من ملاءمة النتائج وفاعلية التفاعل. (Urista, 2024)

• عدم تخصيص النتائج للمستخدم؛ حيث لا تراعي الأنظمة التقليدية تفضيلات المستخدم أو سلوكه السابق، مما يجعل التجربة عامة وغير شخصية. كما أن اعتمادها على بيانات ضخمة يتم جمعها عبر آليات تتبع قد يُدخل تحيزات أو أخطاء، ويؤثر سلبيًا على مصداقية النتائج. (Nanni, 2023)

ومما سبق يمكن القول إن التحديات المتعددة التي تواجهها الأساليب التقليدية في استرجاع المعلومات تُظهر قصورها في مواكبة متطلبات العصر الرقمي، خصوصًا فيما يتعلق بفهم اللغة وتقديم نتائج مخصصة ومبنية على السياق. وهذا ما يبرز أهمية التحول نحو نماذج أكثر تقدمًا كالتالي توفرها النماذج اللغوية الكبيرة، التي تعتمد على تحليل السياق والتحليل الدلالي لاستيعاب استعلامات المستخدمين وتقديم محتوى أكثر دقة وملاءمة.

### ثالثًا: استرجاع المعلومات باستخدام النماذج اللغوية الكبيرة

يمثل دمج النماذج اللغوية الكبيرة في مجال استرجاع المعلومات تقدماً أعاد تشكيل أسس هذا المجال، بعد عقود من الاعتماد على الأساليب التقليدية. فقد أتاحت هذه النماذج، بفضل قدراتها العميقة في فهم اللغة الطبيعية وتوليدها، تحسين دقة الاسترجاع وتخصيص النتائج لتكون أكثر توافقًا مع قصد المستخدم. كما أسهمت في تجاوز قيود النماذج السابقة من خلال تمكين الأنظمة من تحليل السياق واستيعاب المعاني الضمنية ضمن الاستعلامات النصية. وقد تحولت بذلك أنظمة الاسترجاع من أدوات محدودة إلى نظم معرفية نشطة قادرة على التفاعل الذكي مع المستخدم. ويُعد هذا المحور مدخلًا إلى فهم آليات هذه النماذج، وخصائصها، وتحدياتها، وما تقدمه من فرص لتطوير نظم استرجاع معرفية أكثر فعالية.

### التطور المفاهيمي لاسترجاع المعلومات في ظل النماذج اللغوية الكبيرة:

مر على أنظمة استرجاع المعلومات تغيرات متتابعة من حيث المنهجية والتقنيات المستخدمة، إذ بدأت بأساليب تقليدية تعتمد على تطابق المصطلحات، ثم تطورت نحو نماذج تستند إلى المعالجة الإحصائية واللغوية. ومع التقدم الكبير في الذكاء الاصطناعي، ظهرت نماذج جديدة بدلت المفهوم السائد حول كيفية تنظيم البيانات والوصول إليها. وتمثل النماذج اللغوية الكبيرة ذروة هذا التغيير، حيث أعادت تعريف العلاقة بين اللغة والبحث والمعنى. يقدم هذا المحور جملة من التطورات المفاهيمية للاسترجاع القائم على هذه النماذج.

فيمكن تتبع نشأة استرجاع المعلومات عبر مراحل رئيسية، بدءًا من النماذج القائمة على الكلمات المفتاحية البسيطة، وصولاً إلى اعتماد الشبكات العصبية لفهم العلاقات المعقدة بين المفاهيم داخل النصوص. وقد مثل إدخال النماذج العصبية نقطة تحول مفاهيمية، لأنها لم تعد تكتفي بالمطابقة الشكلية، بل تعلمت من الأنماط

الدلالية والسياقات المتعددة داخل اللغة الطبيعية. وأدى هذا التطور إلى تكون فلسفة بحث جديدة، لا تقتصر على الاستخلاص المباشر للمعلومات، بل تشمل أيضًا التأويل والتفسير والتوليد. (Zhu et al., 2024)

ويُعد ظهور النماذج اللغوية الكبيرة نقطة انعطاف حاسمة في تاريخ نظم الاسترجاع، لأنها دمجت بين الفهم الدلالي والتوليد النصي ضمن آلية واحدة. وأصبحت الأنظمة الحديثة بفضل هذه النماذج قادرة على فهم استعلامات المستخدم بطريقة أكثر إنسانية، والتمييز بين المعاني الدقيقة، بل وإعادة توليد استعلامات بديلة إذا لزم الأمر. وبهذا، تحوّل نظام الاسترجاع من مجرد وسيط لتحديد الوثائق إلى بنية معرفية قادرة على تقديم إجابات مباشرة وتحليل لغوي عميق. (Pakhale, 2023)

وقد أدى هذا التقدم إلى ثورة في مفاهيم استرجاع المعلومات، إذ أصبح الاهتمام لا ينصب فقط على "مدى تطابق" المحتوى مع الاستعلام، بل على "مدى ملاءمة" المحتوى لسياق المستخدم ونيّته. فأنظمة البحث الحديثة المبنية على النماذج اللغوية الكبيرة تُعيد تقييم ملاءمة النتائج بناءً على الفهم الدلالي، وتُعطي الأولوية للنتائج التي تعالج الاستعلام ضمن سياق واضح ومتسق. وهذا ما لم يكن ممكنًا ضمن الأطر التقليدية التي تركز فقط على التكرار اللفظي أو النسب الإحصائية. (Zhu et al., 2024؛ Pakhale, 2023)

يشمل هذا التحول أيضًا إعادة النظر في أدوات القياس والتقييم الخاصة بجودة الاسترجاع، حيث لم تعد مؤشرات مثل الدقة (Precision) أو الاستدعاء (Recall) كافية وحدها. بل أصبح من الضروري إدخال مؤشرات نوعية تعتمد على جودة الفهم وسلامة التفسير وملاءمة اللغة، وهو ما يعكس نقلات في المنهجية النظرية التي تحكم استرجاع المعلومات. ولهذا السبب، يُنظر إلى النماذج اللغوية الكبيرة كأدوات لا تقدم فقط أداء أعلى، بل تُعيد تشكيل تركيب المعرفة الرقمية نفسها. (Zhu et al., 2024)

وفي ضوء ما سبق، يتضح أن التحول في استرجاع المعلومات لم يكن من الجانب التقني فحسب، بل كان يشمل أيضًا التحولات المفاهيمية التي غيرت من طبيعة الأسئلة التي تُطرح على الأنظمة، ومن نوعية الإجابات المتوقعة. فقد أصبح من الممكن الانتقال من استعلام حرفي إلى حوار معرفي يعتمد على الفهم والاستدلال. وتُعد النماذج اللغوية الكبيرة القوة المحركة لهذا التحول، لما تتمتع به من قدرة على تفسير اللغة البشرية لا بمجرد رموز، بل كتركيبة دلالية متكاملة. كما أن هذا التطور يفرض مراجعة الأدوات النظرية التي بُنيت عليها أنظمة البحث التقليدية، ويدعو إلى إعادة صياغة معايير الكفاءة والفعالية في نظم المعلومات. وهذه النقطة تفتح المجال لتطوير أنظمة معرفية قادرة على التعامل مع اللغة والمعنى بمستوى غير مسبوق من العمق والدقة.

آلية الاسترجاع عبر النماذج اللغوية الكبيرة:

تطورت آليات استرجاع المعلومات في ظل النماذج اللغوية الكبيرة، حيث تجاوزت هذه النماذج حدود البحث التقليدي، لتُدخل مفاهيم جديدة تعتمد على الفهم العميق للغة والسياق. ومع تنامي قدرات هذه النماذج على تحليل اللغة الطبيعية، ظهرت آليات جديدة تُعيد تعريف طرق البحث، لا سيما في التطبيقات الرقمية المتقدمة. هذا المحور يسلط الضوء على استرجاع المعلومات عبر النماذج اللغوية الكبيرة واعتمادها على آلية متعددة الخطوات، تتكامل فيها المهام التحليلية والدلالية من أجل الوصول إلى نتائج دقيقة وملائمة للسياق. ويمكن تفصيل هذه الآلية في المستويات الآتية:

#### أولاً: تجهيز البيانات وبناء قاعدة المعرفة:

- تبدأ الآلية بتقسيم الوثائق إلى أجزاء صغيرة (chunks) تسهّل معالجتها وتحليلها.
- تُحوّل هذه الأجزاء إلى تمثيلات عددية تُعرف بتضمين المتجهات (embedding vectors)، وهي الصيغة التي تعتمد النماذج لتمثيل المعنى بطريقة رياضية.
- تُخزن هذه التمثيلات في قاعدة بيانات شعاعية (vector database) تُمكن من إجراء المقارنة بين الاستعلامات والمحتوى بناءً على التشابه الدلالي، وليس التطابق النصي المباشر. (Urista, 2024)

#### ثانياً: معالجة استعلام المستخدم وفهم مقصده:

- عند إدخال المستخدم لاستعلامه، يتم تحويله إلى تمثيل دلالي مماثل.
- تُقارن هذه الصيغة مع محتويات قاعدة البيانات على أساس تقارب المعنى والسياق.
- تتيح هذه الخطوة للنموذج فهم نية المستخدم والتعامل مع الاستعلامات المعقدة وغير المباشرة بكفاءة. (Urista, 2024)

#### ثالثاً: دعم وتطوير الاستعلامات:

- تقوم النماذج بإعادة صياغة الاستعلامات بصيغ أكثر وضوحاً وملاءمة لأسلوب اللغة المستخدمة في الوثائق، مما يسهم في تقليل الغموض وزيادة دقة النتائج.

#### رابعاً: تحسين جودة النتائج وترتيبها:

- تُسهم النماذج في اختيار المصادر الأكثر ملاءمة للاستعلام من خلال تحليل المعنى وتحديد الوثائق ذات العلاقة الحقيقية بهدف البحث.
- تتم إعادة ترتيب النتائج بناءً على تحليل السياق وليس فقط على التكرار اللفظي، مما يجعل ترتيب الوثائق أكثر دقة وموضوعية.

• يمكن للنموذج كذلك تلخيص الوثائق أو استخراج المعلومات الأساسية منها، مما يختصر الوقت والجهد على المستخدم.

#### خامساً: الدمج مع الأنظمة التقليدية:

• لا يشترط تبني هذه النماذج استبدال الأنظمة التقليدية كلياً، بل يمكن دمجها داخل بنية النظام القائم في نقاط محددة.

• يتيح هذا الدمج تحسين الأداء تدريجياً، دون الحاجة إلى إعادة بناء النظام من الأساس، مما يجعله خياراً عملياً في بيئات العمل المختلفة. (Nanni, 2023؛ Zhu et al., 2024)

ومن هنا تُبرز آلية الاسترجاع عبر النماذج اللغوية الكبيرة تحولاً جذرياً في الطريقة التي يتعامل بها النظام مع اللغة. فهي لم تعد تعتمد على شكل الكلمة، بل على معناها، مما يجعل تجربة البحث ميسرة وذكية. وتُعد تقنية التقسيم النصي والتحويل الدلالي من أهم الأدوات التي مكّنت هذه النماذج من تجاوز القيود التقنية للأنظمة التقليدية. كما أن قدرتها على تحليل السياق وإعادة ترتيب النتائج وتلخيص المحتوى يمنح المستخدمين تجربة أكثر كفاءة. ينعكس هذا التقدم في تحسين دقة النتائج وتقليل الجهد اللازم للوصول إلى المعلومة. وتُمثل هذه الآلية نقلة نوعية في فهم دور النماذج اللغوية في دعم الوصول إلى المعرفة، مما يؤكد أهميتها في مستقبل نظم الاسترجاع. وهي تمهّد لدمج الذكاء الاصطناعي في بنية نظم المعلومات المعرفية بشكل أعمق وأكثر فعالية.

#### الخصائص والمميزات:

تتسم النماذج اللغوية الكبيرة بعدد من الخصائص فيما يتعلق باسترجاع المعلومات. وتُظهر هذه الخصائص إمكانيات هذه النماذج في تحويل الاستعلامات إلى مدخلات لغوية تحمل السياق والمعنى. ولأن فهم هذه المميزات يعد ضرورياً لاستيعاب التحول المفاهيمي في أنظمة الاسترجاع، فإن الوقوف في هذا المحور عند أبرزها يُساعد في تفسير الأداء العالي الذي تتمتع به هذه النماذج، وهي كالاتي:

1. تتميز النماذج اللغوية الكبيرة بقدرتها على الفهم العميق للسياق، حيث تستطيع تحليل المعنى الضمني لاستعلامات المستخدم، حتى عندما لا تتطابق لفظياً مع محتوى الوثائق، مما يسمح باسترجاع نتائج أكثر صلة في حالات الغموض أو استخدام اللغة غير الرسمي. (Urista, 2024)
2. تُظهر هذه النماذج مرونة عالية في معالجة اللغة الطبيعية، إذ تستطيع فهم صيغ معقدة من الاستعلامات مثل الأسئلة المفتوحة، والمصطلحات متعددة الدلالة، والعبارات غير القياسية، كما تولد استعلامات بديلة بناء على فهم نية المستخدم لتوسيع نطاق البحث. (Pakhale, 2023)

3. تمتلك النماذج اللغوية قدرات استدلالية متقدمة، تتيح لها التعامل مع استعلامات تتطلب جمع وتحليل معلومات من مصادر متعددة، واستخلاص إجابات دقيقة، بالإضافة إلى تلخيص المحتوى أو استخراج أبرز معلوماته. (Zhu et al., 2024)
  4. تتميز النماذج باستجابة تفاعلية لحظية، إذ يمكنها تعديل مسار البحث، وتوضيح الاستعلامات، وتخصيص النتائج وفقاً لتفضيلات المستخدم أو سلوكه السابق، كما تدعم بعض النماذج التفاعل عبر وسائط متعددة تشمل النصوص والصور والمستندات. (Nanni, 2023)
  5. تُعد سهولة الوصول وسلاسة الاستخدام من الخصائص العملية لهذه النماذج، إذ يمكن تشغيلها على أجهزة ذكية متنوعة، وغالباً ما تكون منخفضة التكلفة أو مجانية، مما يُعزز من انتشارها وإتاحتها لفئات واسعة من المستخدمين. (زقروق، 2024)
  6. تُحقق النماذج دقة عالية في الاسترجاع، من خلال تقييم السياق والمعنى بدلاً من الاعتماد على التطابق اللفظي المباشر، حيث تُقيّم مدى معالجة الوثائق للموضوع المطلوب، سواء بشكل مباشر أو ضمني، ما يوفر على المستخدم الوقت والجهد. (Pakhale, 2023)
- تُظهر الخصائص التي تتميز بها النماذج اللغوية الكبيرة كيف انتقلت نظم الاسترجاع من طور البحث الآلي إلى طور الفهم الحركي النشط. فهذه النماذج لا تُجيب فقط بناءً على كلمات المستخدم، بل تُحلل قصده، وتنتج ما يُريده ضمناً، ثم تُعيد تنظيم النتائج لتناسب ذلك القصد. هذه النقطة تعكس التحول العميق في العلاقة بين الإنسان والمعلومة، إذ لم يعد المستخدم مضطراً لصياغة استعلامه بدقة حرفية، بل يكفي التعبير بلغته الطبيعية. كما تُتيح هذه المميزات إمكانيات هائلة في تقديم تجربة بحث ذكية، وشخصية، وتفاعلية. وبذلك، يمكن القول إن النماذج اللغوية الكبيرة لم تعد أداة للبحث فقط، بل أصبحت مكوناً معرفياً قادراً على تمثيل وتوصيل الفهم البشري ضمن النظام الرقمي. هذا التقدم يمهد لتطوير بيانات معرفية أكثر مرونة وشمولية.

### أوجه القصور والعيوب:

- رغم الإمكانيات الكبيرة التي توفرها النماذج اللغوية الكبيرة في مجال استرجاع المعلومات، إلا أن استخدامها لا يخلو من أوجه قصور تعيق الاعتماد الكامل عليها كمصدر وحيد وموثوق للمعلومة. ويوضح هذا المحور هذه العيوب على عدة مستويات، بدءاً من جودة البيانات المستخدمة في التدريب، إلى محدودية الفهم العميق للسياقات، مروراً بمخاوف تتعلق بالدقة، والموثوقية، والانحياز.
1. تعاني النماذج اللغوية الكبيرة من ظاهرة الهلوسة المعلوماتية (Hallucination)، حيث تولد استجابات تبدو صحيحة ومتناسكة لكنها غير دقيقة أو لا تستند إلى مصادر موثوقة، مما يضعف مصداقية النتائج

- ويشكل تحديًا في التطبيقات التي تتطلب دقة عالية. تشير الدراسات إلى أن ما يقارب 20% من هذه المخرجات قد تكون مغلوبة. (إبراهيم وزكريا، 2023 ؛ Pakhale, 2023 ؛ Urista, 2024)
2. تُعد محدودية التفسير أو الشفافية من أبرز أوجه القصور، إذ توصف النماذج بأنها "صناديق سوداء" يصعب فهم كيفية اتخاذها للقرارات، مما يقلل من ثقة المستخدم في النتائج ويجعل من الصعب التحقق من منطق الترتيب أو الاسترجاع. (Zhu et al., 2024 ؛ Pakhale, 2023)
3. تعاني هذه النماذج من التحيزات المضمنة الناتجة عن تدريبها على بيانات ضخمة غير منقّحة، ما يؤدي إلى إعادة إنتاج أنماط تمييزية أو مشوهة في النتائج، وهو ما يؤثر سلبيًا على العدالة المعلوماتية والحياد في الاستجابة. (Bender et al., 2021)
4. تواجه بعض النماذج صعوبة في التعامل مع استعلامات غامضة أو غير دقيقة الصياغة، مما يؤدي إلى نتائج ضعيفة الصلة أو غير مفهومة، كما تتأثر دقة المخرجات بطول الفقرات وتعقيد النصوص، حيث قد يظهر فقدان للترابط أو تناقض في المعلومات. (إبراهيم وزكريا، 2023 ؛ Lewis et al., 2021)
5. تُعاني النماذج من ذاكرة محدودة عند معالجة استعلامات طويلة أو متعددة الأبعاد، بسبب قيود في سعة تخزين السياق، مما يحد من قدرتها على تتبع المعلومات عبر النصوص الممتدة. (Bender et al., 2021)
6. تثير هذه النماذج مخاوف متعلقة بخصوصية البيانات، لا سيما عند تضمين معلومات شخصية أو حساسة في بيانات التدريب، مما قد يؤدي إلى تسرب غير مقصود لمحتوى خاص أو محمي ضمن مخرجات النموذج. (Nanni, 2023)
- وبناءً على ما تقدم، برزت أوجه القصور في النماذج اللغوية الكبيرة التي تتطلب معالجة دقيقة لضمان تحقيق أهداف كفاءة استرجاع المعلومات وفعاليتها. فبينما توفر هذه النماذج إمكانات تحليلية متقدمة، إلا أن محدوديتها في الفهم الحقيقي للغة، وقابليتها لإنتاج معلومات زائفة أو متحيزة، تقلل من موثوقيتها خاصة في التطبيقات الحساسة. كما أن الغموض في آلية اتخاذ القرار داخل هذه النماذج يُشكل عائقًا أمام الشفافية والثقة. وتُحتم هذه التحديات على الباحثين والمطورين تصميم حلول هجينة تجمع بين ذكاء النموذج ودقة المراجعة البشرية أو الأنظمة المرجعية. فمعالجة هذه العيوب لا تقتصر على تحسين تقني فقط، بل تمتد إلى أبعاد أخلاقية وقانونية تتعلق بالخصوصية والعدالة والوصول المتكافئ للمعلومة. ويعتبر فهم هذه الإشكالات بعمق هو خطوة ذات أهمية في سبيل تطوير أنظمة استرجاع معرفية آمنة وعادلة.

### التحديات التقنية والمنهجية:

كيفما أن للنماذج اللغوية الكبيرة القدرات المتقدمة، إلا أن إدماجها في أنظمة استرجاع المعلومات يفرض عددًا من التحديات التقنية والمنهجية التي لا يمكن تجاهلها. وتشمل هذه التحديات جوانب متعلقة بالبنية الحاسوبية، وجودة البيانات، وإمكانية التفسير، إلى جانب القضايا الأخلاقية والتنظيمية. إن الوقوف على هذه الإشكالات في هذا المحور، يصوغ ضرورة فهم محدودات هذه النماذج، واستشراف سبل تطويرها.

1. ارتفاع التكلفة الحسابية: يتطلب تدريب وتشغيل النماذج اللغوية الكبيرة موارد حاسوبية هائلة، تشمل وحدات معالجة متقدمة ومراكز بيانات واسعة، ما يؤدي إلى آثار بيئية واقتصادية كبيرة، ويحد من استخدامها في المؤسسات الصغيرة أو البيئات الأكاديمية. (Bender et al., 2021؛ Zhu et al., 2024)
2. الاعتماد على بيانات غير منظمة: تعتمد هذه النماذج على ما يُعرف بالبيانات غير المستوعبة (Uncurated Data)، مما يؤدي إلى ظهور ما يُعرف بمديونية التوثيق (Documentation Debt)، ويزيد من احتمالية إدخال تحيزات أو معلومات خاطئة في النظام. (Bender et al., 2021)
3. صعوبة تحديث المعرفة المضمنة: تعجز النماذج اللغوية عن التفاعل الفوري مع المعلومات الحديثة، مما يجعلها تُنتج أحيانًا استجابات مبنية على بيانات قديمة، خاصة في المواضيع المتغيرة أو الأحداث الجارية. (Urista, 2024)
4. التحديات اللغوية والثقافية: تواجه النماذج صعوبة في التكيف مع تحولات اللغة والمعايير الاجتماعية، وخصوصًا في اللغات المتخصصة أو اللهجات المحلية ذات التمثيل المحدود في بيانات التدريب. (Bender et al., 2021؛ Pakhale, 2023)
5. قصور أدوات التقييم: لا تُعد المقاييس التقليدية مثل الدقة والاستدعاء كافية لتقييم أداء النماذج التي تعتمد على الفهم العميق وفهم السياق، مما يستدعي تطوير أدوات جديدة لتقييم السياق والدقة الدلالية. (Zhu et al., 2024)
6. صعوبة التكامل مع الأنظمة التقليدية: يتطلب دمج النماذج اللغوية مع أنظمة البحث التقليدية بنى تحتية مرنة، وخطوة هجينة تجمع بين البحث بالكلمات المفتاحية، وقدرات النماذج في التفسير وإعادة ترتيب النتائج. (Pakhale, 2023)
7. تحديات تجارية وتنظيمية: تواجه النماذج المفتوحة تحديات في المنافسة مع النماذج الاحتكارية مغلقة المصدر، إضافة إلى قيود تفرضها بعض الشركات التقنية الكبرى، ما يؤثر على عدالة الوصول إلى المعرفة ويُسهّم في توسيع الفجوات التقنية. (Guinness, 2025)

استناداً على ما سبق، تُعد التحديات التقنية والمنهجية عاملاً مهماً في فهم حدود استخدام النماذج اللغوية الكبيرة في استرجاع المعلومات. إذ أن هذه التحديات لا تتعلق فقط بالبنية التحتية أو التكلفة، بل تمتد إلى قضايا أعمق ترتبط بجودة البيانات، وحيادية النتائج، ومصداقية المخرجات. كما أن صعوبة التفسير، ومحدودية التحديث، وعدم وجود أدوات تقييم مناسبة، كلها عوامل تُقلل من فعالية هذه النماذج في البيئات الحساسة أو المعتمدة على الدقة الفائقة. ومن هنا، تظهر الحاجة إلى بناء أنظمة هجينة تجمع بين تقنيات الذكاء الاصطناعي وأسس الاسترجاع التقليدية، بما يوازن بين الدقة والسياق، ويقلل من المخاطر التقنية أو الأخلاقية المحتملة. ويظل تطوير هذه النماذج مشروطاً بقدرتها على التكيف، والانفتاح على الحلول المستدامة، وتعزيز الشفافية في العمليات التي تقوم بها.

#### رابعاً: مقارنة نظرية بين الاسترجاع التقليدي والاسترجاع عبر النماذج اللغوية الكبيرة

يخطو مجال استرجاع المعلومات خطوات نوعية مع تطور تقنيات الذكاء الاصطناعي، حيث بات من الضروري إعادة النظر في الأسس المفاهيمية والتقنية التي تقوم عليها أنظمة البحث. تجمع هذه المقارنة النظرية بين مدرستين مختلفتين: الأولى قائمة على المطابقة النصية المباشرة، والثانية تعتمد على الفهم العميق لسياق اللغة الطبيعية. ويهدف هذا المحور إلى تحليل أوجه التباين بين النهجين من حيث البنية، الأداء، وتجربة المستخدم. كما يُسلط الضوء على التحول النوعي الذي تقوده النماذج اللغوية الكبيرة في تجاوز محدودية الأنظمة التقليدية نحو نظم استرجاع معرفية أكثر دقة وتفاعلاً.

#### الجوانب المفاهيمية والتقنية:

تُظهر المقارنة بين الأساليب التقليدية في استرجاع المعلومات وتلك المعتمدة على النماذج اللغوية الكبيرة اختلافاً من حيث المنطلقات المفاهيمية والبنى التقنية. فكل منهما تمثل نموذجاً مستقلاً في التعامل مع اللغة والمعلومة والسياق، ما يجعل هذا المحور مدخلاً لفهم طبيعة التحول الذي أحدثته تقنيات الذكاء الاصطناعي في بنية نظم الاسترجاع.

في السياق التقليدي، تعتمد خوارزميات مثل (TF-IDF) و(BM25) على التكرار الإحصائي للكلمات المفتاحية، وتُقيّم أهمية الوثيقة بناءً على تواتر المصطلحات وندرته. غير أن هذه النماذج تتجاهل السياق والمعاني الدلالية، وتعجز عن إدراك النية الحقيقية للمستخدم، ما يجعل نتائج البحث تعتمد على تطابق لفظي ضيق النطاق. وتقوم بنية هذه الخوارزميات على هياكل بيانات بسيطة ومعادلات حسابية مباشرة لا تتيح المرونة في فهم اللغة. (Zhu et al., 2024؛ Urista, 2024)

في المقابل، تعتمد النماذج اللغوية الكبيرة على تمثيل النصوص والاستعلامات على هيئة متجهات دلالية (Semantic Embedding Vectors)، تُمكنها من إدراك العلاقات بين الكلمات والمعاني المتعددة داخل السياق الواحد. وتنفذ هذه العمليات عن طريق بنى معمارية قائمة على الشبكات العصبية العميقة (Deep Neural Networks)، لا سيما المحولات (Transformers)، والتي تتطلب تدريباً مسبقاً على كميات هائلة من البيانات النصية. ويمنح هذا الأسلوب للنظام قدرة على تحليل اللغة الطبيعية واستخلاص نية المستخدم حتى عندما تكون الاستعلامات غير مباشرة أو غير نمطية. (Zhu et al., 2024)

من الناحية التقنية، يُعد استرجاع المعلومات القائم على النماذج التقليدية أقل تكلفة من حيث الموارد الحاسوبية، ولا يتطلب سوى قدرة محدودة على التخزين والمعالجة. أما النماذج اللغوية الكبيرة، فتلتزمها بنية تحتية متقدمة تشمل وحدات معالجة متوازية (GPUs أو TPUs)، وخوارزميات متطورة لتوليد التمثيلات العددية للنصوص. ورغم ارتفاع التكلفة، إلا أن هذه النماذج تُوفر دقة أعلى واستجابة أكثر مرونة مقارنة بالأساليب التقليدية، خاصة في المهام المعتمدة على الفهم العميق للسياق. (Nanni, 2023)

ويُلخص الجدول التالي أوجه المقارنة بين استرجاع المعلومات القائم على النماذج اللغوية الكبيرة والاسترجاع التقليدي:

جدول (2): مقارنة بين الاسترجاع التقليدي والاسترجاع عبر النماذج اللغوية الكبيرة من حيث الجوانب المفاهيمية والتقنية. (الباحث)

الفقرة	الاسترجاع التقليدي	الاسترجاع عبر النماذج اللغوية الكبيرة
الأساس المفاهيمي	يعتمد على تطابق الكلمات المفتاحية	يعتمد على الفهم الدلالي وتحليل السياق والمعنى
طريقة التمثيل	تمثيل نصي مباشر (كلمات/عبارات)	تمثيل دلالي باستخدام متجهات عديدة (Semantic Embeddings)
الاستجابة للاستعلام	يتفاعل مع الاستعلام كما هو دون تعديل	يمكنه إعادة صياغة الاستعلام وتحسينه حسب نية المستخدم
معالجة اللغة	لا يدعم فهم اللغة الطبيعية ولا التعقيدات اللغوية	يفهم اللغة الطبيعية ويتعامل مع الغموض والتعابير الاصطلاحية
البنية التقنية	خوارزميات بسيطة وهيكل بيانات تقليدية (BM25، TF-IDF)	شبكات عصبية عميقة تعتمد على المحولات (Transformers)
متطلبات الموارد	منخفضة نسبياً، لا تتطلب بنية حوسبة متقدمة	مرتفعة، تتطلب موارد حسابية كبيرة (GPU/TPU) وتدريب مكثف
المرونة في النتائج	نتائج محدودة ودقيقة إذا تطابق الاستعلام مع الوثائق	نتائج مرنة تتجاوز المطابقة الحرفية إلى الفهم المعنوي
إمكانية التخصيص	محدودة	مرتفعة، تستجيب لسياق المستخدم وتفضيلاته
الملاءمة للغة غير الرسمية	غير فعال	قادر على فهم الاستعلامات غير الرسمية والمحكية

ومما سبق، تُبين المقارنة المفاهيمية والتقنية بين أساليب الاسترجاع التقليدية والنماذج اللغوية الكبيرة التحول الجذري في فلسفة البحث المعلوماتي. فبينما تتعامل النماذج التقليدية مع النصوص ككلمات منعزلة عن سياقها، تتعامل النماذج الحديثة مع اللغة بمثابة كيان دلالي متكامل. ويعني ذلك أن البحث لم يعد مجرد تطابق ألفاظ، بل أصبح عملية تفاعلية لفهم المعنى واستنتاج المقصود. وقد نتج عن هذا التحول تحسينات واضحة في جودة نتائج البحث، واستجابة أكثر تكيفاً مع المستخدم. كما يعكس هذا التحول تطوراً في النظرة إلى "المعلومة" باعتبارها النتاج اللغوي الذي يمكن تحليله والتفاعل معه، لا مجرد وحدة بيانات ثابتة. ومع استمرار تطور الذكاء الاصطناعي، يُتوقع أن تتسع الفجوة بين المدرستين، مع تقدم النماذج الدلالية على حساب النماذج الإحصائية.

### كفاءة الاسترجاع ودقته:

يناقش هذا المحور مقارنة كفاءة ودقته الاسترجاع بشكليه، حيث إن الدقة والكفاءة معيارين رئيسيين في تقييم أداء أنظمة استرجاع المعلومات، ويتعلقان مباشرة بقدرة النظام على استحضار المعلومات ذات الصلة. ومع ظهور النماذج اللغوية الكبيرة لم تعد الكفاءة بقياس سرعة الاسترجاع أو حجم النتائج فقط، بل أصبح يركز على جودة الفهم والاستدلال.

فمن الناحية التقليدية، تتميز النماذج القائمة على خوارزميات مثل (TF-IDF) و (BM25) بكفاءة عالية من حيث السرعة وقلة استهلاك الموارد الحاسوبية، لا سيما عند التعامل مع قواعد بيانات ضخمة. ومع ذلك، فإن هذه النماذج تُظهر محدودية واضحة في التعامل مع الاستعلامات غير المباشرة أو متعددة المعنى، مما يؤدي في بعض الأحيان إلى استرجاع وثائق لا تعكس الحاجة الحقيقية للمستخدم، خاصة في الحالات المتقدمة التي تتطلب فهم السياق. (Zhu et al., 2024)

في المقابل، توفر النماذج اللغوية الكبيرة قدرة أعلى على تحليل السياق والتعامل مع الغموض والتعبيرات الاصطلاحية. فهي تتجاوز المطابقة السطحية للمصطلحات، لتدخل في عمق المعنى والمقصد، ما يجعل نتائجها أكثر دقة وملاءمة، خصوصاً في الاستعلامات المعقدة أو المصاغة بلغة غير رسمية. (Pakhale, 2023)

كما تتميز هذه النماذج بإمكانية توليد استعلامات بحث محسنة، حيث يمكنها إعادة صياغة الاستعلام الأصلي أو توسيعه بمفاهيم مترادفة أو مرتبطة، مما يزيد من احتمالية العثور على مصادر ذات صلة لم تكن لتظهر في النظام التقليدي. وإذا أدخل المستخدم استعلاماً عاماً مثل "الاحتباس الحراري"، فإن النموذج قد يقترح استعلامات إضافية مثل "تغير المناخ"، ما يوسع مجال البحث ويوفر نتائج ثرية ومتنوعة. (Pakhale, 2023)

إضافة إلى ذلك، هذه النماذج لا تقدم فقط نتائج أكثر دقة، بل أيضاً أكثر تخصيصاً ومواءمة لسياق الاستخدام، ما يجعلها خياراً متقدماً للأنظمة التي تتطلب فهماً عميقاً للاستعلام. لكنها في المقابل تتطلب موارد حسابية

مرتفعة، وقد تكون أبطأ من الأنظمة التقليدية في بعض الحالات، خاصة في عمليات الاستدلال الموسعة أو عند تحليل كميات كبيرة من النصوص في الزمن الفعلي. (Zhu et al., 2024؛ Urista, 2024)

وتُظهر النماذج اللغوية الكبيرة كفاءة عالية أيضاً في ترتيب النتائج حسب الصلة، إذ يمكنها تحديد ما إذا كانت الوثيقة تعالج الموضوع المطلوب بصورة مباشرة أو ثانوية، وبالتالي تنظم النتائج على أساس ملائمة واقعية لا مجرد إحصائية. وبهذا، توفر على المستخدم الوقت والجهد المطلوبين في فرز النتائج غير المفيدة. (Pakhale, 2023؛ Nanni, 2023)

الجدول التالي يلخص أوجه المقارنة بين دقة استرجاع المعلومات وكفاءته في كل من الاسترجاع التقليدي أو عبر النماذج اللغوية الكبيرة:

جدول (3): مقارنة بين الاسترجاع التقليدي والاسترجاع عبر النماذج اللغوية الكبيرة من حيث كفاءة الاسترجاع ودقته. (الباحث)

الجانب	الاسترجاع التقليدي	الاسترجاع عبر النماذج اللغوية الكبيرة
فهم الاستعلام	محدود، يعتمد على الكلمات المفتاحية فقط	عميق، يعتمد على فهم نية المستخدم والسياق والمعاني الضمنية
دقة النتائج	منخفضة في الاستعلامات المعقدة أو غير المباشرة	مرتفعة خاصة في الاستعلامات السياقية أو غير الرسمية
توليد استعلامات بديلة	لا يدعم	يدعم اقتراح وتحسين الاستعلامات لتوسيع نطاق البحث
ترتيب النتائج	يعتمد على تكرار المصطلحات أو الأوزان الإحصائية	يُرتب النتائج حسب صلتها الحقيقية بالاستعلام والمعالجة السياقية
الاستجابة للاستعلامات الغامضة	ضعيف في معالجة الغموض والتعبيرات المركبة	قادر على فهم الغموض اللغوي والتعابير الاصطلاحية
السرعة والأداء الحسابي	سريع وخفيف من حيث استهلاك الموارد	أبطأ نسبياً ويتطلب موارد حاسوبية مرتفعة
التخصيص والتفاعل	غير مخصص، يعامل جميع المستخدمين بنفس الطريقة	مخصص، يُراعي تفضيلات وسلوك المستخدم

في ضوء ما تم عرضه، توضح المقارنة الكفاءة والدقة بين الاسترجاع التقليدي والاسترجاع عبر النماذج اللغوية الكبيرة. فبينما تقوم النماذج التقليدية على السرعة والكم، تُعيد النماذج اللغوية صياغة المفهوم من خلال التركيز على الفهم الدلالي والاستجابة السياقية. وبات استرجاع المعلومات أقرب إلى المحاور مع نظام ذكي، لا مجرد تصفح قائمة من النتائج. ومع أن كلفتها التقنية قد تُقيد استخدامها في بعض البيئات، إلا أن فعاليتها في فهم اللغة وتقديم نتائج دقيقة يجعلها ركيزة أساسية في مستقبل نظم الاسترجاع.

### تجربة المستخدم والتفاعل:

يشكل التفاعل بين المستخدم ونظام الاسترجاع عاملاً أساسياً في الحكم على فاعلية الأنظمة المعلوماتية. ومع تطور تقنيات الذكاء الاصطناعي، بدأت العلاقة بين المستخدم والنظام تأخذ طابعاً أكثر خصوصية وحيوية. فلم يعد المستخدم يكتفي بقائمة جامدة من النتائج، بل أصبح يتوقع نظاماً يتفاعل معه ويفهم مقاصده وسياق استعماله. ويركز هذا المحور على تقديم مقارنة لتجربة المستخدم وتفاعله في كلا المدرستين.

في النموذج التقليدي للاسترجاع، تعتمد تجربة المستخدم على إدخال كلمات مفتاحية محددة، ليتم تقديم قائمة من الوثائق المرتبة بحسب تطابقها مع المصطلحات الواردة في الاستعلام. هذا النوع من التجربة يُوصف بالخطّي والجامد، حيث يتفاعل النظام مع الطلب كما هو، دون محاولة لتفسير المقصود أو تقديم تكيف للنتائج بحسب خصائص المستخدم أو تفضيلاته. (Zhu et al., 2024؛ Nanni, 2023)

أما في الاسترجاع المعتمد على النماذج اللغوية الكبيرة، فتأخذ التجربة منحى أكثر ديناميكية. إذ تُقدّم هذه النماذج إجابات مباشرة أو توليفات معرفية قائمة على مصادر متعددة، كما تتيح إمكانية إعادة صياغة السؤال أو طرح استفسارات متتابعة ضمن تفاعل شبيه بالحوار. هذا ما يجعل التفاعل مع المستخدم أقرب إلى التواصل مع مساعد ذكي، لا مجرد محرك بحث تقليدي. (Amazon Web Services, n.d.؛ Urista, 2024)

كما توفر النماذج اللغوية الكبيرة أيضاً إمكانيات غير مسبوقة في التخصيص، من خلال فهم نمط استخدام الفرد، وسلوكه، وسياقه الشخصي. فهي قادرة على تقديم توصيات مُصاغة بحسب تفضيلات المستخدم، وتوفير نتائج تتكيف مع احتياجاته الخاصة، بما في ذلك ذوي الإعاقة الذين يمكنهم الاستفادة من توليد أوصاف صوتية أو تلخيصات مرئية للمحتوى وما إلى ذلك. (قناوي، 2024)

كما أن هذه النماذج أصبحت مدمجة في تطبيقات يومية مثل المساعدات الافتراضيين، وخدمات الدردشة، وأنظمة الدعم الفني، حيث تعزز من التفاعل وتحسن من مستوى الرضا. ومع أن استخدامها يتطلب واجهات أكثر تطوراً وتوقعات مختلفة من المستخدمين، إلا أنها تمنح تجربة استخدام أكثر طبيعية وواقعية، بما يتماشى مع تطور توقعات الأفراد في البيئة الرقمية المعاصرة. (Zhu et al., 2024)

الجدول التالي يوضح الفروقات بين تجربة المستخدم وتفاعله في كل من الاسترجاع التقليدي للمعلومات والاسترجاع المعتمد على النماذج اللغوية الكبيرة.

جدول (4): مقارنة بين تجربة المستخدم في الاسترجاع التقليدي والاسترجاع عبر النماذج اللغوية الكبيرة. (الباحث)

الاسترجاع عبر النماذج اللغوية الكبيرة	الاسترجاع التقليدي	الجانب
تفاعلي، يشبه الحوار مع مساعد ذكي	خطي، يعتمد على إدخال كلمات مفتاحية وتلقى قائمة نتائج	شكل التفاعل
إجابات مباشرة أو ملخصات مستخلصة من مصادر متعددة	قائمة مرتبة بناءً على التتابع اللفظي	نوع النتائج
عميق، يفهم النية والسياق والمفاهيم الضمنية	محدود، لا يتجاوز الكلمات المدخلة	فهم الاستعلام
متقدم، يراعي تفضيلات وسياق المستخدم	غائب أو محدود	التخصيص
يدعم الحوارات متعددة الخطوات والاستفسارات المتفرعة	غير مدعوم	مرونة الحوار
يشرح، يفسر، ويعيد الصياغة عند الحاجة	يستعرض وثائق دون تفسير	تقديم الخدمة
يدعم ذوي الإعاقة (أوصاف صوتية، تليخيص مرئية)	محدود	دعم الوصول
مدمج في المساعدات الافتراضيين، وتطبيقات التوصية، والدرشة	غالبًا محصور في محركات البحث	الدمج في التطبيقات اليومية

ومما سبق، تُبرز مقارنة تجربة المستخدم بين النظم التقليدية وتلك المعتمدة على النماذج اللغوية الكبيرة التحول في طبيعة التفاعل البشري مع نظم المعلومات. إذ أصبح المستخدم أكثر فاعلية، لا مجرد متلقي للنتائج، بل مشارك في صياغة الحوار المعلوماتي عبر واجهات ذكية. تتيح هذه النماذج الحوارات المرنة، مما يعزز من تخصيص الإجابات، ويوفر إمكانية توجيه دقيق للمعلومة المسترجعة. كما أنها تسهم في دمج الاسترجاع ضمن أنظمة يومية مثل التطبيقات والمساعدات الافتراضية، مما يجعل الوصول إلى المعرفة أكثر سلاسة وشمولاً. ومع كل هذه المزايا، لا تزال هذه النماذج تتطلب بنى تفاعلية متقدمة وجهوداً في توجيه المستخدمين لفهم إمكاناتها واستثمارها بالشكل الأمثل.

### خامساً: الإمكانيات التكاملية لنماذج اللغوية الكبيرة لتعزيز الاسترجاع

مع بروز النماذج اللغوية الكبيرة بوصفها أدوات قادرة على التفاعل مع محتوى معقد ومتعدد المصادر. فقد أدى دمج هذه النماذج في أنظمة استرجاع المعلومات إلى إعادة صياغة آليات البحث من خلال الاستفادة من التمثيل المعرفي والتوليد الدلالي المتقدم للمعنى والسياق. يستعرض هذا المحور أبرز الإمكانيات التي تدمج بين تقنيات البحث الكلاسيكي وإمكانيات الفهم اللغوي، بما في ذلك الاسترجاع المعزز بالتوليد (RAG) التي تدمج بين استرجاع المستندات والتوليد الفوري للإجابات، والرسوم البيانية المعرفية (KGs) التي توفر خرائط للعلاقات المفاهيمية، بالإضافة إلى القدرات الواسعة المتعددة، بوصفها أدوات مركزية في تعزيز أداء الاسترجاع في البيئات الرقمية المعاصرة.

### الاسترجاع المعزز بالتوليد (Retrieval-Augmented Generation - RAG):

في ظل التوسع الكبير في استخدام النماذج اللغوية الكبيرة، دعت الحاجة إلى تقنيات داعمة تُعزز موثوقية نتائج هذه النماذج وتقلل من انحرافات أو ما يُعرف بالهلوسة المعلوماتية. ويُعد نموذج "الاسترجاع المعزز بالتوليد" (Retrieval-Augmented Generation) من أبرز التطورات الحديثة التي جمعت بين قدرات التوليد اللغوي والفهرسة الذكية للمحتوى. ويدعم هذا النموذج اللغوي في استرجاع المعلومات، من حيث إمكانيةه بين الاستدعاء اللحظي للمعلومة والتوليد الفوري للنصوص ذات الصلة. ويركز هذا المحور على توضيح إمكانيات تكامل الاسترجاع المعزز بالتوليد مع النماذج اللغوية الكبيرة.

تعتمد بنية نموذج الاسترجاع المعزز بالتوليد على تكامل نموذج لغوي مدرب مسبقاً مع قاعدة بيانات خارجية (مثل الموسوعات)، حيث تُخزن النصوص كتمثيلات دلالية لتسهيل الاسترجاع. وعند إدخال استعلام المستخدم، يُحوّل إلى صيغة عددية تُقارن بمحتوى القاعدة، ليُستخرج النص الأكثر صلة ويُدمج مع إمكانيات النموذج التوليدية لتقديم إجابة مدعومة بالمعرفة (Lewis et al., 2021). تُستخدم في هذا السياق مصادر مثل ويكيبيديا، أو مستودعات متخصصة، مما يُضفي على نتائج النموذج طابعاً موثقاً ويمكن تتبع مصدره.

ويتميز هذا الأسلوب بقدرته على توليد إجابات أكثر دقة واستناداً إلى معلومات قابلة للتحقق، وذلك عبر تضمين سياق الاستعلام في نتائج البحث المُسترجعة. وتتم العملية على مرحلتين: الأولى استرجاعية تعتمد على مطابقة تمثيلات الاستعلام مع الوثائق المتاحة؛ والثانية توليدية تستخدم ما تم استرجاعه لصياغة رد لغوي منطقي، يتوافق مع بنية السؤال ومتطلباته المعرفية. (Zhu et al., 2024؛ Urista, 2024)

وفي السياق التطبيقي، يُستخدم نموذج (Command) من شركة (Cohere) بوصفه إحدى الآليات المتقدمة التي توظف هذا النهج، حيث يُستفاد منه في تحسين استجابات النماذج عبر الرجوع إلى مصادر خارجية عند توليد الإجابات. هذه التقنية تُسهم في تقليل الأخطاء الناجمة عن نقص المعلومات أو الاعتماد على بيانات داخلية قديمة، كما تمنح المستخدم مستوى أعلى من الشفافية والمصداقية. (Guinness, 2025)

الجدول التالي يوضح التفاوت بين عمليات الاسترجاع من الجانب التقليدي، وعبر النماذج اللغوية الكبيرة فقط، ثم في حالة تكامل النماذج اللغوية مع الاسترجاع المعزز بالتوليد.

جدول (5): مقارنة بين الاسترجاع المعزز بالتوليد (RAG) والاسترجاع التقليدي والنماذج اللغوية الكبيرة فقط (LLMs-only): (الباحث)

البند	الاسترجاع التقليدي	النماذج اللغوية الكبيرة فقط	مع الاسترجاع المعزز بالتوليد (RAG)
طريقة العمل	مطابقة كلمات مفتاحية	توليد إجابات من المعرفة الداخلية	استرجاع وثائق ثم توليد إجابة بناءً على المعرفة الخارجية
مصدر المعلومات	قاعدة بيانات مؤرشفة	المعرفة المتعلمة من بيانات التدريب فقط	قاعدة معرفية خارجية + قدرة توليد من النموذج
دقة المعلومة	تعتمد على تطابق المصطلحات	عرضة للهلوسة المعلوماتية	عالية، لأن الإجابة مدعومة بمصدر مسترجع وواقعي
المرونة في اللغة	منخفضة، تعتمد على المطابقة الحرفية	عالية	عالية
الشفافية وقابلية التتبع	متوسطة	منخفضة	عالية، يمكن تتبع مصدر الإجابة
القدرة على الاستدلال	محدودة	مرتفعة	مرتفعة، مع دعم واقعي من الوثائق
الاعتماد على التحديثات الخارجية	لا يدعم	لا يدعم	يدعم، بفضل الاتصال بذاكرة خارجية قابلة للتحديث
الاستخدامات المثلى	البحث البسيط/الأرشيف	المحادثة العامة/إنشاء النصوص	التطبيقات المتخصصة، مثل التعليم، القانون، والطب

وبذلك، يمكن القول إن الاسترجاع المعزز بالتوليد يمثل نقطة التقاء حيوية بين تقنيتي البحث والاستدلال اللغوي، حيث تُدمج المعرفة الخارجية مع القدرات اللغوية الاصطناعية لتوليد إجابات أكثر دقة وموثوقية. وقد أثبت هذا النموذج فاعليته في التخفيف من مشكلات "الهلوسة المعلوماتية" في النماذج اللغوية الكبيرة، مع تحسين تجربة المستخدم من حيث الشرح والتوثيق. وبفضل قدرته على الوصول اللحظي إلى المعلومات، أصبح نموذج الاسترجاع المعزز بالتوليد أداة واعدة في التطبيقات التي تتطلب استجابات دقيقة في مجالات مثل التعليم، والطب، والقانون. كما يفتح المجال أمام تطوير نظم هجينة تجمع بين فعالية نظم الاسترجاع وديناميكية التوليد اللغوي. ومع التقدم التقني المستمر، يُتوقع أن يشكّل هذا النهج إحدى الركائز المستقبلية في بناء نظم معلومات معرفية ذكية.

### الرسوم البيانية المعرفية (Knowledge Graphs -KGs):

تتزايد الحاجة في نظم استرجاع المعلومات الحديثة إلى تمثيل معرفي منظم يتيح للنماذج اللغوية فهمًا أعمق للسياق والمعاني الضمنية. في هذا الإطار، تُمثل الرسوم البيانية المعرفية (Knowledge Graphs) إحدى الأدوات التي تُعزز من فعالية النماذج اللغوية الكبيرة، إذ تقوم على بناء شبكات مترابطة من الكيانات والعلاقات تمكّن النظام من استخلاص المعرفة بطريقة دقيقة وقابلة للتحليل. ومن خلال ربط هذه الرسوم بالنماذج اللغوية،

يصبح بالإمكان تجاوز كثير من محدودات الفهم القائم على النصوص فقط، والانتقال نحو استرجاع أكثر دقة ومرونة. ويتناول هذا المحور العلاقة التكاملية بين النماذج اللغوية والرسوم البيانية المعرفية.

تتيح الرسوم البيانية المعرفية تخزين معلومات منظمة حول الكيانات والعلاقات التي تربطها، مما يساعد أنظمة الاسترجاع على فهم السياق الكامل للاستعلام وليس فقط المصطلحات الفردية. ونتيجة لذلك، تصبح هذه الأنظمة قادرة على تقديم نتائج أكثر صلة حتى في حالات الغموض أو تعدد المعاني. من جانب آخر، تُظهر النماذج اللغوية الكبيرة قدرة مرنة على تحليل الاستعلامات المعقدة وتوليد إجابات تستند إلى فهم اللغة الطبيعية، بما يشمل الصياغات غير الرسمية أو الأسئلة غير المباشرة. (Pan et al., 2023؛ Nanni, 2023)

ويُسهّم التكامل بين الرسوم البيانية المعرفية والنماذج اللغوية الكبيرة في تحقيق تحولات رئيسية في أنظمة الاسترجاع، إذ يمكن استخدام الرسوم لتزويد النموذج بمعلومات دقيقة ومنظمة تدعم عملية التوليد، مما يقلل من ظاهرة "الهلوسة المعلوماتية" التي قد تنتج عن اعتماد النموذج على بيانات غير منسقة. كما يمكن للنموذج بدوره تحليل النصوص واستخلاص مفاهيم جديدة تُغذي الرسوم البيانية وتوسّع نطاقها، مما يُنتج بنية معرفية متكاملة ومُحدثة باستمرار. (Pan et al., 2023؛ Hogan et al., 2025)

ومن بين التطبيقات البارزة لهذا التكامل؛ البحث الدلالي في الصور والفيديوهات، حيث تُستخدم النماذج متعددة الوسائط لتحليل الصور واستخلاص رموزها الدلالية، وربطها بمفاهيم في الرسوم البيانية، مما يفتح آفاقاً لاسترجاع دقيق عبر وسائط مختلفة (Guinness, 2025). وسوف نعرض في المحور التالي بشيء من التفصيل للقدرات الواسطة في النماذج اللغوية الكبيرة.

بالإضافة لذلك، أن فهم الوثائق التقنية والتقارير المتخصصة يمكن تحسينه باستخدام نماذج لغوية مدعومة برسوم بيانية تمثل المفاهيم والعلاقات التخصصية داخل المجال ذاته (Pan et al., 2023). فعلى سبيل المثال، في المجال الطبي، يمكن استخدام نموذج لغوي كبير مدعوم برسم بياني معرفي مخصص لعلوم الأعصاب لتحليل تقرير طبي معقد عن حالة مريض مصاب باضطراب عصبي. يحتوي الرسم البياني على كيانات مثل "الدواء"، "الأعراض"، "المناطق الدماغية"، مع علاقات دقيقة توضح التفاعلات بينها. عند إدخال التقرير، يساعد النموذج في تفسير العلاقة بين الدواء الموصوف والتأثير الجانبي المذكور، وربما يقترح تساؤلات استقصائية إضافية للطبيب حول منطقة دماغية ذات صلة لم تُذكر صراحة. وهذا النوع من التحليل لا يمكن تحقيقه بسهولة باستخدام نموذج لغوي غير معزز برسم بياني معرفي متخصص.

ومن أبرز مميزات الرسوم البيانية المعرفية كذلك هو قدرتها على تقديم بنية موثوقة للمعرفة، يمكن للنموذج اللغوي الاستناد إليها لتوليد استجابات أكثر دقة، مما يُسهّم في تجاوز بعض نقاط الضعف البنوية للنماذج التي

تعتمد فقط على البيانات النصية الضخمة. كما تسهم الرسوم البيانية في تنظيم عمليات البحث بطريقة تسمح بفهم العلاقات بين المفاهيم، وبالتالي استرجاع معلومات شاملة وسياقية دون الاعتماد على التطابق اللفظي. (Hogan et al., 2025)

الجدول التالي يُلخص العلاقة التكاملية بين كل من النماذج اللغوية الكبيرة والرسوم البيانية المعرفية من أبعاد عدة.

جدول (6): العلاقة بين الرسوم البيانية المعرفية والنماذج اللغوية الكبيرة في سياق استرجاع المعلومات. (الباحث)

العلاقة التكاملية	النماذج اللغوية الكبيرة	الرسوم البيانية المعرفية (KGs)	البُعد
الرسوم البيانية توفر بنية تُكمل النصوص الحرة التي تُعالجها النماذج اللغوية	غير منظمة (Unstructured)	منظمة (Structured)	نوع البيانات
النماذج اللغوية تفهم النصوص، والرسوم البيانية توفر تمثيلًا دقيقًا للمعرفة	فهم اللغة الطبيعية وتوليد النصوص	تمثيل العلاقات بين الكيانات بدقة	الوظيفة الأساسية
الرسوم البيانية تقلل من الأخطاء الناتجة عن استجابات غير دقيقة	قد تعاني من "الهلوسة المعلوماتية"	مرتفعة (لأنها مبنية على مصادر موثوقة)	دقة المعرفة
يمكن للنماذج اللغوية تحديث الرسوم البيانية عبر استنتاج علاقات جديدة	يتطلب إعادة تدريب النموذج	يتم يدويًا أو تلقائيًا	التحديث
تكامل في أنظمة البحث المتقدمة والتحليل المفاهيمي	روبوتات المحادثة، توليد النصوص، البحث الدلالي	قواعد البيانات، الأنظمة الدلالية، تحليل المفاهيم	المجال التطبيقي
النماذج اللغوية تولد استجابة، والرسوم البيانية تؤكد أو تصحح المعلومة	استنتاج أن "باريس" مرتبطة بـ "فرنسا" بناءً على السياق	تمثيل علاقة "باريس هي عاصمة فرنسا" ضمن شبكة	مثال تطبيقي

وبهذا يمكن القول، إن تكامل النماذج اللغوية الكبيرة مع الرسوم البيانية المعرفية يمثل خطوة واعدة نحو بناء نظم استرجاع معلومات أكثر ذكاءً وتكيفًا مع حاجات المستخدمين المعقدة. إذ يجمع هذا النهج بين قدرة النماذج على فهم اللغة الطبيعية واستيعاب السياق، وبين دقة الرسوم البيانية في تمثيل العلاقات والمفاهيم. وبفضل هذا التكامل، يمكن تقليل الاعتماد على التطابق الحرفي، وتحقيق مستويات أعلى من التخصيص والدقة في نتائج البحث. كما يُعد هذا التكامل أساسيًا في مجالات معرفية متخصصة تتطلب استرجاع السياق والتحليل العميق، مثل القانون، والطب، والهندسة. لذلك، من المتوقع أن يظل دور الرسوم البيانية المعرفية في تنامي مستمر مع تطور النماذج اللغوية، ليدعما معًا مستقبل نظم البحث الذكية.

القدرات الواسعة المتعددة للنماذج اللغوية الكبيرة:

تسارعت وتيرة تطور النماذج اللغوية الكبيرة في قدرتها على معالجة مدخلات متعددة الوسائط، مما يعكس فهم هذه النماذج بطريقة شبيهة بالبشر. فبينما كانت النماذج السابقة تركز على النصوص فقط، باتت الآن قادرة على

دمج أنواع متعددة من البيانات مثل الصور والصوت والفيديو ضمن عمليات التحليل والفهم. هذا التوسع في قدرات النماذج يعزز من كفاءتها في استرجاع المعلومات من مصادر غير نصية. ويُعنى هذا المحور بتقديم لمحة حول القدرات الواسائطية للنماذج اللغوية.

تُعد القدرات الواسائطية المتعددة سمة مركزية في النماذج الحديثة، حيث تتيح لهذه النماذج استقبال أنواع مختلفة من المدخلات وربطها ببعضها لاستخلاص معنى أعمق. وبهذا تصبح هذه النماذج أكثر قدرة على محاكاة الإدراك البشري الذي يقوم على الدمج بين الحواس لفهم الظواهر. لم تعد أنظمة الاسترجاع المعتمدة على النماذج اللغوية تعتمد فقط على البحث في النصوص، بل تتجه نحو معالجة الصور والمقاطع المرئية والمسموعة، مما يعد بتجربة استرجاع أكثر ثراءً وتكاملاً، حتى وإن كانت هذه الإمكانيات لا تزال في طور التطوير والتجريب. (Urista, 2024)

من أبرز النماذج متعددة الوسائط في المشهد الراهن نموذج (GPT-4)، والذي يتميز بقدرته على استقبال النصوص والصور كمدخلات متزامنة، ومعالجتها بطريقة تتيح له إنتاج مخرجات نصية عالية الجودة. تسمح له هذه الإمكانية بتطبيق استراتيجيات معقدة في الفهم مثل الاستدلال المنطقي (Logical Reasoning) وسلاسل التفكير (Chain-of-Thought) على المحتوى النصي والمرئي معاً، دون فقدان الدقة التي يُظهرها في معالجة النصوص فقط. (OpenAI, 2023)

أما نموذج (Gemini 1.5)، فيُعد مثلاً متقدماً آخر على القدرات الواسائطية في النماذج اللغوية، إذ يتمتع بقدرة فريدة على التعامل مع سياقات طويلة للغاية من النصوص والوسائط. فليده القدرة على تحليل كميات ضخمة من البيانات، تتضمن ساعات طويلة من التسجيلات الصوتية أو مقاطع الفيديو، إلى جانب تحليل الصور والنصوص، مما يجعله مناسباً للمهام التي تتطلب معالجة معقدة لمحتوى وسائطي متعدد. كما أنه قادر على الاسترجاع الدقيق للمعلومات جراء البحث عن مشهد معين ضمن فيديو طويل، أو عن معلومة محددة ضمن تسجيل صوتي لمحاضرة مطوّلة. إضافة إلى ذلك، يستطيع دمج وتحليل مدخلات من أنواع متعددة في وقت واحد، كأن يُجيب على سؤال حول صورة استناداً إلى نص يشرح خلفيتها وسياقها، أو أن يربط بين محتوى مرئي وصوتي بشكل مترابط. (Gemini Team, 2024)

بالتالي، التحول نحو الواسائطية لا يُعد مجرد تطور تقني، بل يعيد تشكيل طبيعة استرجاع المعلومات نفسها. إذ أصبح من الممكن توظيف هذه القدرات في مجموعة واسعة من التطبيقات الواقعية، مثل المجال الطبي الذي يمكن فيه استخدام الصور الإشعاعية لاسترجاع حالات سريرية مشابهة، أو تحليل مقاطع الفيديو الجراحية لاستخلاص معلومات دقيقة. أما في السياقات التعليمية، فإن البحث في محتوى المحاضرات المصورة أو

الصوتية بات أكثر سهولة، مما يدعم التحصيل المعرفي للطلاب. وفي مجالات الإعلام والقانون، يمكن استخدام هذه القدرات لاسترجاع الأدلة من مصادر مرئية أو صوتية، بما يساهم في تسريع وتيرة التحليل واتخاذ القرار. (Urista, 2024; Gemini Team, 2024)

وبذلك، يتضح من العرض السابق أن القدرات الوسائطية المتعددة في النماذج اللغوية الكبيرة لا تمثل مجرد تحسين تقني، بل تعكس تغير المشهد في فهم آليات استرجاع المعلومات ضمن البيئة الرقمية. فدمج النصوص بالصور والأصوات والفيديو، تُمكن هذه النماذج من تجاوز محدودية الاسترجاع النصي نحو استيعاب أعمق وأكثر تكاملاً للمعرفة المتاحة في أشكالها المتنوعة. ومع استمرار تطوّر هذه النماذج، يتوقع أن تتوسع تطبيقاتها في ميادين حيوية، مما يستدعي من الباحثين إعادة التفكير في نظريات الاسترجاع التقليدية لصياغة أطر مفاهيمية جديدة تُراعي هذا الطابع الوسائطي المتقدم.

#### الاستخدامات المعاصرة في السياقات الرقمية:

تتعدد الاستخدامات المعاصرة للنماذج اللغوية الكبيرة في السياقات الرقمية، مع تزايد الحاجة إلى أدوات ذكية قادرة على التعامل مع المعلومات واسترجاعها بشكل فعال. وتوظّف هذه النماذج في بيئات تطبيقية متنوعة، تتراوح بين منصات المحتوى التفاعلي، وأدوات دعم القرار، وأنظمة خدمة العملاء. ويُشكّل هذا التوظيف امتداداً مباشراً لقدرات النماذج على توليد اللغة وتحليلها وربطها بسياق الاستخدام، مما يجعلها أدوات مركزية في المشهد الرقمي الراهن. ويهدف هذا المحور إلى تقديم الاستخدامات الشائعة للنماذج اللغوية الكبيرة في البيئات الرقمية.

من أبرز التطبيقات الحديثة للنماذج اللغوية الكبيرة استخدامها في أنظمة الإجابة على الأسئلة المفتوحة والتلخيص التوليدي، حيث تعتمد على آليات استرجاع معرفي توليدي لتقديم إجابات دقيقة وغنية بالسياق. كما تُستخدم هذه النماذج في صياغة الأسئلة الآلياً، لا سيما في سياقات تعليمية وتقييمية، إلى جانب دورها في التحقق من صحة الحقائق عبر مقارنة المعطيات مع مصادر متعددة، مما يُبرز فعاليتها في استرجاع المعلومات الدقيقة والموثوقة. (Lewis et al., 2021)

وقد تم تطبيق هذه القدرات فعلياً في منصات مراجعة الوثائق، التي تعتمد على تجزئة النصوص وربطها بالنماذج اللغوية لاستخلاص المقاطع الأكثر صلة بالاستعلام، وهي تقنية توظف الاسترجاع الدلالي (Semantic Retrieval) لدعم قرارات المستخدمين في مجالات مثل القانون أو إدارة الأعمال. كما تشهد أنظمة المحادثة الذكية تطوراً ملحوظاً من خلال دمج النماذج اللغوية الكبيرة ضمن تطبيقات الإرشاد المالي أو الدعم المؤسسي، رغم ما يواجهه هذه الأنظمة أحياناً من تحديات تتعلق بحدثة البيانات أو التحيزات السياقية. (Urista, 2024)

وفي المجال المؤسسي، ظهرت تطبيقات متقدمة توظف النماذج اللغوية ضمن إطار الاسترجاع المعزز بالتوليد، حيث تُربط النماذج بمصادر خارجية لتوليد إجابات حديثة وموثوقة. وتُعد هذه التقنية أساسًا لتطبيقات مثل محركات البحث التفاعلية، أو وكلاء البحث الذكي، الذين يقومون بأتمتة عملية الاستفسار وتقديم إجابات مبنية على استدعاء السياق الخارجي. (Zhu et al., 2024)

وتُساهم النماذج اللغوية الكبيرة في تحسين الوصول إلى المعلومات وتيسير استخراجها، خصوصًا من خلال أتمتة عمليات الدعم والاستجابة الفورية لاستفسارات المستخدمين. فعند استخدامها في أنظمة دعم العملاء، تعتمد على استرجاع البيانات الفورية لتوفير ردود دقيقة وشخصية، مما يقلل من زمن التفاعل ويرفع مستوى رضا المستخدمين. كما تُستخدم هذه النماذج في تحليل البيانات واستخلاص المؤشرات العامة، بما في ذلك تحليل المشاعر وإنشاء الملخصات، وهو ما يمثل نمطًا متقدمًا من استرجاع المعلومات المعتمد على الفهم التفسيري للسياقات. وفي السياقات المتخصصة، يبرز دور النماذج في التعامل مع مجالات دقيقة مثل تحليل المستندات القانونية، وتلخيص التقارير الطبية، أو مراجعة الامتثال التنظيمي، وذلك من خلال نماذج مُضبطة بدقة على بيانات متخصصة، مما يُحسن دقة الاسترجاع ويُقلل من نسب الخطأ في هذه البيئات الحرجة. (Muhammad, 2025)

وتتكامل هذه الاستخدامات مع تقنيات إدارة واسترجاع المعرفة، مثل بناء قواعد بيانات المتجهات، التي تُستخدم لتخزين البيانات عالية الأبعاد واسترجاعها بكفاءة عبر تشابه السياقات والمعاني، وهي بُنى أساسية تُوظف في تعزيز دقة نظم البحث الدلالي والتطبيقي. (IBM Think, 2023; Holdsworth & Kosinski, 2024)

وبناءً على ما تقدم، يُظهر تتبع الاستخدامات المعاصرة للنماذج اللغوية الكبيرة في السياقات الرقمية كيف أصبحت هذه النماذج من المكونات الأساسية في بنية استرجاع المعلومات، لا بوصفها أدوات لغوية فحسب، بل باعتبارها نظامًا معرفيًا قادرًا على توليد المحتوى وتحليل السياق وتكييف المخرجات بحسب طبيعة المهام. وقد ساهم هذا التكامل في إثراء التطبيقات الرقمية عبر تحسين تجربة المستخدم، ورفع كفاءة البحث، وتمكين الأفراد والمؤسسات من الوصول إلى المعرفة بصورة أذكى وأكثر فاعلية. ويشير هذا إلى تحول جذري في وظيفة الاسترجاع، باستحضار المعنى وتوليد المعرفة المخصصة، بما يعزز الحاجة إلى فهم نظري ومنهجي أعمق لهذا التداخل المتصاعد بين الذكاء الاصطناعي واسترجاع المعلومات.

## الاستنتاجات

بعد تناول محاور هذه الدراسة المتعلقة بالنماذج اللغوية الكبيرة ودورها في استرجاع المعلومات، تبلورت مجموعة من الاستنتاجات التي تعكس الفهم التحليلي للموضوع. وانقسمت هذه الاستنتاجات إلى أبعاد نظرية وأخرى تطبيقية. كما تقترح فرص تطوير مستقبلية ومجالات بحثية يمكن استثمارها لتعميق المعرفة وتحسين الكفاءة في هذا المجال المتسارع.

### الاستنتاجات النظرية:

- أثبتت النماذج اللغوية الكبيرة قدرتها على إحداث تحول جوهري في آليات معالجة اللغة الطبيعية من خلال محاكاة الفهم البشري للنصوص، مما مكنها من تجاوز حدود النماذج التقليدية في الاستدلال وتوليد اللغة.
- آلية عمل النماذج اللغوية تقوم على التعلم العميق وتمثيل السياق عبر آليات الانتباه (Attention)، وهو ما مكنها من فهم المعاني الدقيقة وتحليل البنى التركيبية للنصوص بصورة متقدمة.
- إن استرجاع المعلومات بالاعتماد على النماذج التقليدية يواجه قيودًا تتعلق بدقة النتائج وسياقية الإجابة، بينما تتميز النماذج اللغوية الكبيرة بقدرتها على تعزيز جودة الاسترجاع من خلال التفاعل النشط مع الاستعلامات، وفهم النية خلف السؤال.
- يبرز الاسترجاع المعزز بالتوليد (RAG) بوصفه تطورًا مفاهيميًا ومنهجيًا يعكس تكامل قدرات الاسترجاع والتوليد، ويمنح أنظمة المعلومات القدرة على تقديم إجابات دقيقة مدعومة بمصادر موثوقة.
- تُظهر النماذج اللغوية تفوقًا واضحًا في دعم التطبيقات الرقمية المتقدمة، مثل وكلاء البحث والمساعدات الذكية وأنظمة دعم القرار، وهو ما يعزز مكانتها بوصفها بنى معرفية قابلة للتخصيص والتكيف مع المهام التخصصية.
- تعتمد فعالية هذه النماذج على وجود بيانات رقمية معرفية غنية، مثل الرسوم البيانية المعرفية (KGs)، التي تزود النماذج بصلات دلالية ومعرفية تعزز من دقة الاسترجاع وسياقه.
- إن الاستخدامات المعاصرة للنماذج اللغوية تعكس توجهًا نحو إعادة تشكيل البنية المعرفية الرقمية، بحيث تصبح النماذج وسائط لاستكشاف المعرفة، لا مجرد أدوات لاسترجاعها، مما يفتح آفاقًا جديدة أمام البحث العلمي وتطوير نظم المعلومات.
- لا تُغني تقنيات الاسترجاع المعتمدة على النماذج اللغوية الكبيرة الحاجة إلى الأساليب التقليدية للاسترجاع في البيئة الرقمية، بل تُعد مكملة لها. ويتوقف اختيار الأسلوب الأمثل على طبيعة متطلبات البحث ونوع

المعلومات المطلوبة وسلوك المستخدم، مما يجعل من الضروري النظر إلى التكامل بين المنهجين بدلاً من المفاضلة المطلقة بينهما.

#### الاستنتاجات التطبيقية:

- أظهرت النماذج اللغوية الكبيرة كفاءة عالية في استرجاع المعلومات من خلال فهمها العميق للغة الطبيعية، مما يجعلها أكثر قدرة على التعامل مع الاستعلامات الغامضة أو غير الصريحة مقارنة بالأساليب التقليدية.
- يسهم دمج تقنية الاسترجاع المعزز بالتوليد (RAG) في تقديم نتائج دقيقة ومدعومة بمصادر موثوقة، حيث يسمح للنموذج بالوصول إلى محتوى محدث ومتعدد السياقات، ما يرفع من موثوقية المعلومات المسترجعة.
- يُعد التكامل بين النماذج اللغوية الكبيرة والرسوم البيانية المعرفية عاملاً مهماً في تحسين دقة الاسترجاع، إذ يتيح الجمع بين المعالجة اللغوية العميقة والتمثيل البياني للمعرفة، خاصة في البيئات التخصصية.
- تتيح القدرات الوسائطية للنماذج اللغوية استرجاع معلومات متعددة الأنماط (صور، فيديو، صوت)، ما يفتح المجال أمام أنظمة بحث أكثر شمولاً وتكيفاً مع السياقات غير النصية، كالمجال الطبي والإعلامي والتعليم التفاعلي.
- أثبتت النماذج اللغوية فعاليتها في استرجاع المعلومات السياقية في التطبيقات اليومية مثل المساعدات الذكية وخدمات العملاء، من خلال القدرة على تحليل السياق الشخصي للمستخدم وتقديم نتائج مخصصة.
- توفر النماذج اللغوية إمكانات واسعة لتطوير أدوات بحث معرفي تعتمد على فهم عميق للمفاهيم لا على تطابق الكلمات المفتاحية، مما يجعلها مناسبة لمحركات البحث المستقبلية والموسوعات التفاعلية.
- تُظهر النماذج اللغوية الكبيرة قدرة على الاسترجاع الفوري للمعلومات الدقيقة عبر واجهات المحادثة، مما يؤهلها لأداء دور فعال في دعم اتخاذ القرار الفوري في قطاعات الأعمال والخدمات العامة.

#### فرص التحسين والبحث النظري المستقبلي

- أولاً: تبرز الحاجة إلى تطوير نماذج أكثر دقة في تقليل ظاهرة الهلوسة المعلوماتية، وذلك عبر تعزيز التكامل بين النماذج اللغوية الكبيرة ومصادر المعرفة المنظمة مثل الرسوم البيانية المعرفية وقواعد البيانات المتخصصة، بما يضمن موثوقية المحتوى المسترجع.

- ثانيًا: من الضروري ابتكار بنى هجينة تستفيد من مزايا كل من الأساليب التقليدية والأنظمة التوليدية، إلى جانب دعم آليات التفسير الشفاف لقرارات النماذج، بما يعزز ثقة المستخدم وفهمه للألية التي تستند إليها النتائج المسترجعة.
- ثالثًا: تمثل الوسائط المتعددة مجالًا واعدًا للبحث، حيث يُتوقع من النماذج اللغوية المستقبلية أن تستوعب نصوصًا وصورًا وفيديوهات ضمن بيئة استرجاع موحدة، مما يتطلب العمل على تقنيات تمثيل متعددة الوسائط أكثر تطورًا ودقة.
- رابعًا: هناك حاجة لتوسيع دراسات التقييم والتجريب في السياقات الواقعية، خاصة في المجالات المتخصصة كالقانون والطب والتعليم لقياس فعالية النماذج اللغوية في الاسترجاع المتخصص، إلى جانب العمل على دعم اللغات المنخفضة الموارد لتناسب احتياجات مجتمعات غير ناطقة بالإنجليزية وتعاني من ضعف المحتوى الرقمي، لضمان عدالة الوصول إلى تقنيات الاسترجاع الذكي وتقليص الفجوة الرقمية.

### الخاتمة

سلّطت هذه الدراسة الضوء على التحول الجذري الذي أحدثته النماذج اللغوية الكبيرة (LLMs) في ميدان استرجاع المعلومات في البيئة الرقمية. وقد بيّنت النتائج النظرية أن هذه النماذج لا تُعد فقط امتدادًا للأساليب التقليدية، بل تقدم نموذجًا بديلًا قائمًا على الفهم للسياق والمعالجة الدلالية العميقة للغة، وهو ما يُحدث فرقًا واضحًا في دقة الاسترجاع وتجربة المستخدم.

كما أوضحت الدراسة كذلك أن دمج النماذج اللغوية في نظم الاسترجاع، سواء عبر آلية الاسترجاع المعزز بالتوليد (RAG) أو عبر التفاعل مع الرسوم البيانية المعرفية، يمثل نقلة منهجية نحو بناء أنظمة أكثر كفاءة وقدرة على مواكبة تنوع المدخلات واختلاف الاستعلامات. كما تبين أن هذه النماذج تتجاوز اللغة النصية لتوظيف إمكانات وسائطية متعددة، مما يوسع من آفاق استرجاع المعلومات عبر أنماط غير تقليدية.

ورغم هذه التطورات، فقد أشارت الدراسة إلى وجود تحديات تقنية ومنهجية تتعلق بالدقة، والتفسير، والموثوقية، إلى جانب الحاجة لمعايير تقييم جديدة. كما أكدت أهمية الموازنة بين القدرات التوليدية للنماذج ومتطلبات التخصص، خاصة في مجالات حساسة كالقانون والطب.

كما تبرز أهمية مواصلة البحث في هذا المجال من خلال التركيز على تحسين تكامل النماذج اللغوية مع مصادر المعرفة المنظمة، وتطوير آليات تقييم دقيقة وعادلة، إلى جانب ضمان الاستخدام الأخلاقي والمتخصص لها بما يحقق أقصى فاعلية لأنظمة استرجاع المعلومات في عصر المعرفة المتسارعة.

## المراجع

### المراجع العربية:

- إبراهيم، س. ر. س.، & زكريا، م. ش. (2023). الأثار المترتبة على: ChatGPT نحو تبني مولدات (المحادثات الاستراتيجية) (النماذج المستحدثة لمعالجة اللغة في البيئة الأكاديمية ومجال المكتبات). Arab Journal for Archives, Documentation & Information (AJADI), 54, 107–132 لهذه الدراسة مفيدة جداً في موضوعنا يمكن استنتاج منها المميزات والعيوب لاسترجاع المعلومات من خلال هذه التقنية.
- أبو غنيمة، عيد محمد عبدالعزيز، والزعليك، محمد السيد عبدالبر. (2024). استخدام نموذج مقترح لتدريس فيزياء المتحكمات الدقيقة قائم على النمذجة العلمية والنماذج اللغوية الكبيرة لتنمية التفكير الحاسوبي والمبادئ والتعميمات العلمية لطلاب الجامعة التكنولوجية. مجلة كلية التربية، مج21، ع122، 100-178. مسترجع من <http://search.mandumah.com.sdl.idm.oclc.org/Record/1512917>
- أحمد، ع. ر. ع. ا.، & علا رمضان عبد الكريم. (2023). التطلعات المستقبلية لاستخدام نظم استرجاع المعلومات وأدواتها القائمة على الذكاء الاصطناعي في المكتبات: وفقاً للتحليل الرباعي SWOT. مجلة كلية الآداب بالوادي الجديد، 9(17)، 904-941.
- زقروق، م. (2024). مقدمة في استخدام نماذج اللغة الكبيرة للمستخدمين غير التقنيين. مزن. [mozn.ws/91484](https://mozn.ws/91484)
- عوض، إيمان عبده حسن. (2024). تطبيقات هندسة أوامر النماذج اللغوية الكبيرة "LLMs" في التدريب على مهام هندسة البرمجيات: مراجعة منهجية. المجلة السعودية للعلوم التربوية، ع16، 89-106. مسترجع من <http://search.mandumah.com.sdl.idm.oclc.org/Record/1532095>
- قناوي، يارة ماهر محمد. (2024). استخدام تقنية ChatGpt كأداة ذكية لتحليل البيانات في المكتبات دراسة استكشافية. Egyptian Journal of Information Sciences, 11(1), 505–540.
- AWS. (n.d.). What is a Large Language Model (LLM)? Retrieved April 29, 2025, from <https://aws.amazon.com/what-is/large-language-model/>
- Harvard Business Review. (n.d.). النماذج اللغوية الكبيرة. Retrieved April 29, 2025, <https://hbrarabic.com/>

- 
- Holdsworth, J., & Kosinski, M. (2024). ما المقصود بقاعدة البيانات الموجهة؟ IBM Think. <https://www.ibm.com/sa-ar/think/topics/vector-database>
  - IBM Think. (2023). ما عمليات النماذج اللغوية الكبيرة (LLMOps)? <https://www.ibm.com/sa-ar/think/topics/llmops>

#### المراجع الأجنبية:

- Bender, E. M., Gebru, T., McMillan-Major, A., & Shmitchell, S. (2021). On the Dangers of Stochastic Parrots: Can Language Models Be Too Big? In Conference on Fairness, Accountability, and Transparency (FAccT '21), March 3-10, 2021, Virtual Event, Canada. ACM, New York, NY, USA, 14 pages. <https://doi.org/10.1145/3442188.3445922>.
- Foote, K. D. (2023). A brief history of large language models. DATAVERSITY. <https://www.dataversity.net/a-brief-history-of-large-language-models/>.
- Gemini Team. (2024). Gemini 1.5: Unlocking multimodal understanding across millions of tokens of context. arXiv preprint arXiv:2403.05530v5.
- Guinness, H. (2025). The best large language models (LLMs) in 2025. Zapier. <https://zapier.com/blog/best-llm/>.
- Haziqa S. (2024, August 10). What is information retrieval? Zilliz Learn. <https://zilliz.com/learn/what-is-information-retrieval> (Accessed February 16, 2025).
- <https://medium.com/@daniele.nanni/revolutionizing-information-retrieval-the-role-of-large-language-models-in-a-post-search-engine-7dd370bdb62>.
- Lewis, P., Perez, E., Piktus, A., Petroni, F., Karpukhin, V., Goyal, N., Küttler, H., Lewis, M., Yih, W-t., Rocktäschel, T., Riedel, S., & Kiela, D. (2021). Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks. arXiv preprint arXiv:2005.11401v4.
- McDonough, M. (2025, April 29). Large language model. [Retrieved from <https://www.britannica.com/topic/large-language-model>.
- Muhammad, A. (2025, January 7). Best Large Language Models for 2025 and How to Choose the Right One for Your Site. Retrieved from <https://www.hostinger.com/tutorials/large-language-models>.
- Murel, J., & Syed, M. (2024). What is information retrieval? IBM. Retrieved from <https://www.ibm.com/think/topics/information-retrieval>.

- 
- Nanni, D. (2023, May 17). Revolutionizing Information Retrieval: The Role of Large Language Models in a Post-Search Engine Era. Medium.
  - OpenAI. (2024). GPT-4 Technical Report. <https://doi.org/10.48550/arXiv.2303.08774>.
  - Pakhale, Kalyani. "Large Language Models and Information Retrieval." International Journal for Multidisciplinary Research (IJFMR), vol. 5, no. 6, 2023, pp. 1-12.
  - Pan, J. Z., Razniewski, S., Kalo, J.-C., Singhania, S., Chen, J., Dietze, S., Jabeen, H., Omeliyanenko, J., Zhang, W., Lissandrini, M., Biswas, R., de Melo, G., Bonifati, A., Vakaj, E., Saleem, J., & Lehmann, J. (2023). Large Language Models and Knowledge Graphs: Opportunities and Challenges. arXiv preprint arXiv:2307.04022.
  - Tyson, M. (2024, May 15). What is information retrieval? Coveo. Retrieved from <https://www.coveo.com/blog/information-retrieval/>.
  - Urista, T. (2024, November 9). Enhancing Information Retrieval with Large Language Models: Techniques and Best Practices. Medium. <https://www.google.com/search?q=https://timothy-urista.medium.com/enhancing-information-retrieval-with-large-language-models-techniques-and-best-practices-3f414a37e27f>.
  - Zhu, Y., Yuan, H., Wang, S., Liu, J., Liu, W., Deng, C., Chen, H., Liu, Z., Dou, Z., & Wen, J.-R. (2024). Large Language Models for Information Retrieval: A Survey.