

المحاضرة الثانية لمادة: تصميم شبكات اللوجيستيك بالذكاء الاصطناعي

موجهة لطلبة الماستر مالية وتجارة دولية

عنوان المحاضرة: لمحة عامة حول الذكاء الاصطناعي

مقدمة:

أصبح الذكاء الاصطناعي (AI) من أبرز مجالات التقنية الحديثة نظراً لتطبيقاته الواسعة وتأثيره المتزايد في مختلف جوانب الحياة. تهدف هذه المحاضرة إلى تقديم لمحة شاملة عن الذكاء الاصطناعي، بما في ذلك تعريفه ومجالاته الفرعية وعلاقته بتعلم الآلة والتعلم العميق والذكاء الاصطناعي التوليدي. كما سنستعرض مفهوم طبقة النماذج مقابل طبقة التطبيقات في أنظمة الذكاء الاصطناعي الحديثة، مع أمثلة لتطبيقات الذكاء الاصطناعي التوليدي في توليد النصوص والصور والصوت والفيديو والكود. وأخيراً، سنتناول مفهوم الأوامر (Prompts) في النماذج اللغوية الضخمة واستراتيجيات كتابتها للحصول على أفضل النتائج من هذه النماذج.

تعريف الذكاء الاصطناعي:

يمكن تعريف الذكاء الاصطناعي بأنه فرع من علوم الحاسوب يركز على تطوير أنظمة وبرامج قادرة على محاكاة القدرات الذهنية للبشر وأداء المهام التي تتطلب عادةً ذكاءً بشرياً تشمل هذه القدرات مثلاً: التعلم واكتساب المعرفة من التجارب، الاستنتاج واتخاذ القرارات، التفكير المنطقي وحل المشكلات، والإدراك وفهم البيئة المحيطة. يستخدم الذكاء الاصطناعي اليوم في مجالات متعددة كالتشخيص الطبي والصناعة والتعليم والأمن السيبراني وغيرها؛ فنجد تطبيقات تشمل السيارات ذاتية القيادة، وأنظمة التشخيص الطبي الذكي، والترجمة الآلية، والمساعدات الشخصية الافتراضية التي تعتمد جميعها على تقنيات الذكاء الاصطناعي. وبفضل التقدم الكبير في خوارزميات تعلم الآلة والشبكات العصبية العميقة في العقد الأخير، أصبحت أنظمة الذكاء الاصطناعي قادرة على أداء مهام معقدة كانت حكراً على البشر في السابق. هذا التطور يرافقه اهتمام متزايد بتحديات أخلاقية وتنظيمية لضمان استخدام هذه التقنيات بشكل مسؤول.

المراحل التاريخية و المدارس الفكرية

بدأت قصة الذكاء الاصطناعي رسمياً في عام 1956، عندما استخدم المصطلح لأول مرة. تبعت ذلك "السنوات الذهبية" بين 1956 و 1974، التي تميزت بتمويل حكومي قوي ومحاولات رائدة لبناء أنظمة ذكية. ومع ذلك، فإن عدم قدرة التقنيات المبكرة على تلبية التوقعات المتفائلة، جنباً إلى جنب مع الانتقادات الفلسفية

والأخلاقية والتحديات التقنية غير المحلولة، أدت إلى أول "شتاء للذكاء الاصطناعي" في الفترة ما بين 1974 و 1980، حيث انخفض التمويل بشكل كبير .

شهدت الثمانينيات (1980-1987) ازدهاراً ثانياً، مدفوعاً بالانتشار الواسع للأنظمة الخبيرة Expert Systems وزيادة التمويل الحكومي، وهي فترة تُعرف أيضاً بـ "ثورة المعرفة". أما العصر الحديث (2005-2017) فقد تميز بالتوفر الهائل "للبيانات الضخمة (Big Data)" وتطور الآلات الحاسوبية العملاقة، مما سمح بظهور التعلم العميق (Deep Learning) وبدء الأبحاث الجادة في مجال الذكاء الاصطناعي العام (AGI).

الفرق بين الذكاء الاصطناعي وتعلم الآلة والتعلم العميق والذكاء التوليدي:

توجد عدة مفاهيم فرعية تندرج تحت مظلة الذكاء الاصطناعي، منها تعلم الآلة والتعلم العميق والذكاء الاصطناعي التوليدي. كثيراً ما يحدث خلط في استعمال هذه المصطلحات، لذا فيما يلي توضيح موجز لكل منها:

- **الذكاء الاصطناعي (Artificial Intelligence - AI):** يشير إلى الأنظمة أو البرامج الحاسوبية القادرة على محاكاة الذكاء البشري في أداء المهام، خاصة ما يتعلق بعملية اتخاذ القرارات وحل المشكلات بناءً على الخبرات والبيانات المتوفرة.
- **تعلم الآلة (Machine Learning - ML):** مجموعة فرعية من الذكاء الاصطناعي تُركّز على تطوير خوارزميات تسمح للآلات بالتعلم من البيانات وتحسين أدائها تلقائياً مع مرور الوقت، دون أن تكون مبرمجة بشكل صريح لكل حالة. أي أن النظام يستخلص الأنماط والاستنتاجات من البيانات التي يتدرب عليها، ثم يطبقها على بيانات جديدة.
- **التعلم العميق (Deep Learning):** منهجية متقدمة ضمن تعلم الآلة تستخدم شبكات عصبية اصطناعية متعددة الطبقات لمحاكاة طريقة عمل الدماغ البشري في معالجة البيانات. يتيح التعلم العميق للآلات حل مشكلات شديدة التعقيد (مثل تمييز الصور أو فهم اللغة الطبيعية) عن طريق نماذج ذات طبقات عديدة تتعلم تمثيل الميزات المعقدة بشكل تدريجي.
- **الذكاء الاصطناعي التوليدي (Generative AI):** يقصد به أنظمة الذكاء الاصطناعي القادرة على توليد محتوى جديد وأصلي (نصوص أو صور أو أصوات أو غيرها) استناداً إلى الأنماط التي تعلمتها من بيانات التدريب. على عكس الأنظمة التقليدية التي تكتفي بتحليل البيانات أو تصنيفها، يقوم الذكاء الاصطناعي التوليدي بابتكار بيانات ومخرجات تشابه ما تم تدريبه عليه. يعتمد هذا النوع من النماذج على تقنيات التعلم العميق المتطورة) مثل نماذج المحولات (Transformer) التي تتعرف على الأنماط الخفية في كميات هائلة من البيانات، ثم تستعين بها لإنتاج محتوى جديد ذي طابع مشابه للمحتوى الأصلي .

باختصار، تعلّم الآلة هو جزء من الذكاء الاصطناعي يهتم بجعل الآلات تتعلم من البيانات، والتعلّم العميق هو جزء من تعلّم الآلة يستخدم شبكات عصبية متعمقة. أما الذكاء الاصطناعي التوليدي فيمثل نوعًا خاصًا من تطبيقات الذكاء الاصطناعي (غالبًا بالاعتماد على التعلم العميق) يركز على إنشاء محتوى جديد.

طبقة النماذج مقابل طبقة التطبيقات في الذكاء الاصطناعي

عند بناء حلول قائمة على الذكاء الاصطناعي عمومًا – والتوليدي خصوصًا – يمكن تصور بنية من مستويين : طبقة النماذج (Model Layer) وطبقة التطبيقات (Application Layer) لكل طبقة دور مميز في منظومة الذكاء الاصطناعي الحديثة:

طبقة النماذج : تشمل النماذج الرياضية والتقنية نفسها التي تمثل ذكاء الآلة. في سياق الذكاء الاصطناعي التوليدي، هذه الطبقة تضم النماذج الأساسية (Foundation Models) المدربة على كميات ضخمة من البيانات والقادرة على توليد المحتوى. هذه النماذج هي المحرك الرئيسي لقدرات الذكاء الاصطناعي، وتوفّر الوظائف الجوهرية مثل فهم اللغة الطبيعية، ومعالجة النصوص، وتوليد الأكواد البرمجية، وإنشاء الصور، وغير ذلك. على سبيل المثال، من النماذج اللغوية التوليدية المعروفة GPT-3 من شركة OpenAI ، ونموذج Gopher من DeepMind ، ونموذج OPT من شركة Meta (فيسبوك). تشكّل هذه النماذج البنية التقنية الأساسية التي تُبنى عليها التطبيقات المختلفة، حيث أنها توفر القدرات العامة التي يمكن تخصيصها لمهام متنوعة.

طبقة التطبيقات : تمثل التطبيقات العملية المبنية فوق نماذج الذكاء الاصطناعي الأساسية لخدمة غرض محدد أو مجال تخصصي. في هذه الطبقة يتم توظيف النماذج الذكية لحل مشاكل واقعية وتقديم خدمات للمستخدم النهائي. على سبيل المثال، يمكن استخدام النماذج التوليدية في:

- تطبيقات التسويق الرقمي كتوليد محتوى إعلاني أو منشورات تلقائيًا لجذب العملاء.
- تطبيقات الدعم الفني وخدمة العملاء مثل بناء روبوتات محادثة ذكية تقدم إجابات فورية لاستفسارات المستخدمين.
- أدوات مساعدة المبرمجين مثل اقتراح تصحيحات للكود أو إكمال شفرة برمجية تلقائيًا لتسريع عملية التطوير.
- منصات الإبداع الفني كتوليد صور أو موسيقى أو فيديوهات بناءً على طلبات المستخدمين.

بعبارة أخرى، النموذج (Model) هو العقل التقني القادر على الإنتاج والتوليد، بينما التطبيق (Application) هو تجسيد استخدام هذا العقل في مجال أو صناعة معينة لتحقيق منفعة محددة أو لأتمتة مهمة ما. في الفقرة التالية سنستعرض بعض أبرز المجالات التطبيقية للذكاء الاصطناعي التوليدي وكيفية توظيف النماذج فيها.

ظهرت في الفترة الأخيرة مجموعة متنوعة من التطبيقات العملية التي تستفيد من قدرات نماذج الذكاء الاصطناعي التوليدي لإنتاج المحتوى. فيما يلي أمثلة بارزة على ذلك، تصنف حسب نوع المخرجات التي يولدها النموذج:

- **توليد النصوص (Text Generation):** استخدام نماذج اللغة الطبيعية لإنشاء نصوص مكتوبة بشكل تلقائي لأغراض مختلفة. يشمل ذلك توليد مقالات وأجوبة للأسئلة وملخصات نصية ومحتوى تسويقي وإبداعي. على سبيل المثال، يمكن لنموذج مثل GPT-3 (أو GPT-4 من OpenAI) توليد فقرة تسويقية للترويج لمنتج ما أو كتابة قصة قصيرة بناءً على توجيهات المستخدم. كذلك تُستخدم هذه التقنية في روبوتات الدردشة مثل ChatGPT لإنتاج ردود لغوية عالية الجودة تحاكي أسلوب البشر في المحادثة.
- **توليد الأكواد البرمجية (Code Generation):** مساعدة المبرمجين على كتابة الشيفرات البرمجية أو إكمالها تلقائيًا باستخدام نماذج ذكاء اصطناعي متخصصة. على سبيل المثال، نموذج OpenAI Codex المبني على تقنيات GPT قادر على اقتراح أجزاء من كود برمجي بلغة معينة أو إكمال دوال برمجية بناءً على وصف وظيفتها. وقد تم دمج مثل هذه النماذج في أدوات تطوير شهيرة مثل GitHub Copilot لمساعدة المبرمجين على كتابة الكود بشكل أسرع وأكثر دقة.
- **توليد الصور (Image Generation):** إنشاء صور رقمية جديدة بناءً على وصف نصي أو معطيات يحددها المستخدم. على سبيل المثال، نموذج DALL·E من OpenAI يستطيع توليد صورة مبتكرة من جملة وصفية مثل "قطعة ترتدي قبعة وتقود سيارة"، حيث يقوم بترجمة الوصف اللغوي إلى صورة تخيلية. هناك أيضًا نماذج أخرى كـ Midjourney وStable Diffusion تحقق نتائج مبهرة في هذا المجال.
- **توليد الصوت (Voice Synthesis):** تحويل النصوص المكتوبة إلى كلام منطوق أو توليد مقاطع صوتية تحاكي أصواتًا بشرية معينة. على سبيل المثال، يمكن لنموذج ذكاء اصطناعي توليدي مدرب على الصوت (مثل بعض نماذج TTS الحديثة أو خدمة ElevenLabs) أن يقرأ مقالًا بصوت يشبه الصوت البشري الطبيعي. كما تسمح هذه التقنية بتوليد أصوات مخصصة (مثل تحويل نص إلى صوت أحد المشاهير بطريقة اصطناعية). وقد طورت OpenAI نموذجًا ضمن منصتها قادر على توليد كلام منطوق من النص بدقة عالية.
- **توليد الفيديو (Video Generation/Editing):** إنشاء مشاهد فيديو جديدة أو تعديل مشاهد قائمة باستخدام نماذج توليدية. على سبيل المثال، كشفت شركة Meta عن نموذج Make-A-Video القادر على توليد مقطع فيديو قصير اعتمادًا على وصف نصي للمشاهد المطلوب. وبالمثل، تظهر نماذج وأدوات مثل Runway Gen-2 إمكاناتها تحويل سلسلة من الصور أو وصف نصي إلى فيديو متحرك. هذه التقنية لا تزال في بداياتها ولكنها تتطور بسرعة، وتفتح آفاقًا لتحويل النص أو الصور الثابتة إلى محتوى فيديو ديناميكي.

تجدر الإشارة إلى أن جميع الأمثلة أعلاه تعتمد على نماذج توليدية أساسية تم تدريبها على أصناف المحتوى المختلفة (نصوص، صور، أصوات، إلخ). ومع تقدم الأبحاث، تتحسن جودة هذه النماذج وقدرتها على إنتاج مخرجات أكثر دقة وواقعية في كل مجال.

النماذج اللغوية الضخمة (Large Language Models - LLMs)

النماذج اللغوية الضخمة هي فئة من نماذج الذكاء الاصطناعي تتميز بحجمها الكبير جدًا (يصل عدد المعاملات فيها إلى مليارات أو أكثر) وتدريبها على كم هائل من البيانات النصية. يمتاز هذا النوع من النماذج بالقدرة على فهم اللغة الطبيعية وإنتاجها بطريقة شبيهة بأسلوب البشر. فهي تتعلم خلال مرحلة التدريب قواعد اللغة وأنماط استخدام الكلمات والمعاني الضمنية من النصوص التي تتعرض لها، مما يمكنها لاحقًا من توليد نصوص مترابطة والإجابة على الأسئلة واستكمال المحادثات بشكل سياقي. تعتمد العديد من النماذج اللغوية الضخمة الحديثة على بنية المحوّل (Transformer) في تصميمها. على سبيل المثال، GPT هو اختصار لـ *Generative Pre-trained Transformer* ويشير إلى سلسلة نماذج لغوية ضخمة تستخدم المحولات والتعلم العميق لإنتاج نصوص شبيهة بالنصوص البشرية.

شهدت السنوات القليلة الماضية ظهور عدة نماذج لغوية ضخمة بارزة تتنافس في قدراتها. من الأمثلة المهمة حاليًا:

- GPT-5 من شركة OpenAI وهو النموذج الذي يقوم عليه أحدث إصدار من نظام ChatGPT الشهير. يتمتع GPT-5 بقدرة محسّنة على فهم السياق وإنتاج ردود أكثر دقة وتعقيدًا مقارنةً بالإصدارات السابقة.
- Bard من شركة Google يعتمد على نموذج PaLM 2 اللغوي، وتم تصميمه للإجابة على الأسئلة وإجراء المحادثات. يتميز Bard بإمكانية الوصول إلى معلومات محدثة من الويب وتوليد إجابات بجودة عالية.
- Claude من شركة Anthropic نموذج لغوي ضخم تم تطويره مع التركيز على السلامة وضبط السلوك، ويُستخدم لأغراض متعددة مثل تلخيص المستندات والإجابة التفاعلية.
- LLaMA 2 من شركة Meta سلسلة نماذج لغوية مفتوحة المصدر بأحجام مختلفة (7 مليار إلى 70 مليار معاملة)، تتميز بأنها متاحة للباحثين ويمكن تشغيل النماذج الأصغر منها على أجهزة محدودة الموارد. تتيح LLaMA 2 للمطورين بناء تطبيقات مخصصة بالاعتماد على نموذج لغوي قوي.

هذه أمثلة قليلة من نماذج عديدة في المشهد الحالي مثل Bloom و GPT-NeoX وغيرها. (وقد اكتسبت واجهات المحادثة القائمة على النماذج اللغوية شهرة واسعة بعد إطلاق ChatGPT في أواخر عام 2022، إذ أظهرت للعامة مدى تقدم هذه النماذج وقدرتها على إنتاج حوار شبيه بالحوار البشري. وبالإضافة إلى تطبيقات

المحادثة، تُستخدم LLMs أيضًا في الترجمة الآلية المتقدمة، وتحليل المشاعر للنصوص، وتلخيص المستندات الطويلة، وغيرها من المهام اللغوية المعقدة. الجدير بالذكر أن تدريب النماذج اللغوية الضخمة يتطلب موارد حسابية ضخمة وبيانات وفيرة، ولكن النتائج المبهرة التي تحقّقها جعلتها محورًا أساسيًا في تطور مجال الذكاء الاصطناعي.

مفهوم الأوامر (Prompts) وأنواعها

في تفاعل الإنسان مع النماذج اللغوية الضخمة، يلعب الأمر (Prompt) دورًا جوهريًا في تحديد مخرجات النموذج. ال Prompt هو ببساطة النص أو السؤال أو التعليمات التي يقدمها المستخدم لنموذج الذكاء الاصطناعي بغرض توجيهه لأداء مهمة أو الإجابة عن سؤال. قد يكون الأمر عبارة عن سؤال مباشر ("ما تعريف الذكاء الاصطناعي؟")، أو طلب لتنفيذ مهمة معينة ("لخص النص التالي..."), أو حتى مجموعة أمثلة يُراد من النموذج مواصلة النمط بناءً عليها.

إن هندسة الأوامر (Prompt Engineering) هي المجال الذي يهتم بابتكار وصياغة هذه المطالبات بطريقة ذكية لتحقيق أفضل استجابة من النموذج. نظرًا لأن النماذج اللغوية - مهما بلغت تطورها - لا تستطيع تخمين قصد المستخدم بدقة تامة، فإن صياغة السؤال أو الأمر بوضوح ودقة تعتبر عاملاً حاسماً للحصول على نتيجة مرضية. كلما كان الأمر محددًا ومفصلاً، قلّت حاجة النموذج للتخمين، وزادت احتمالية أن تكون الاستجابة مناسبة لما يريده المستخدم. على سبيل المثال، إذا حصلت من النموذج على إجابة مطوّلة جدًا، يمكنك أن تطلب منه صراحةً أن يقدمها بإيجاز أكبر؛ وإذا كانت الإجابة سطحية، فبإمكانك أن تسترشد النموذج ليُجيب بمستوى أكثر تخصصًا أو بأسلوب خبير؛ وإذا لم يعجبك تنسيق الإجابة، فيمكنك أن تحدد التنسيق المطلوب أو تعرض مثالاً له ضمن أمرك. توجيه النموذج بهذه الصورة يساعد على تضيق نطاق الاحتمالات التي سيفكر فيها النموذج ويزيد من جودة الإجابة النهائية.

يمكن للأوامر أن تأخذ أشكالًا مختلفة حسب حاجة المستخدم. فقد تكون سؤالًا مباشرًا يطلب معلومة محددة، أو تعليمات خطوة بخطوة لحل مسألة، أو طلبًا لتوليد قائمة أو صياغة جواب بصيغة معينة، أو حتى إعطاء أمثلة ضمن الأمر ليقوم النموذج بالافتداء بها. جميع هذه الأساليب هي طرق لصياغة المدخل للنموذج بحيث "يفهم" بالضبط المهمة المطلوبة منه.

استراتيجيات كتابة الأوامر للحصول على نتائج دقيقة

لتحقيق أفضل استفادة من نماذج الذكاء الاصطناعي، نشر القائمين على مختلف النماذج اللغوية الضخمة توصيات حول استراتيجيات صياغة الأوامر. على سبيل المثال، تقترح إرشادات صادرة عن شركة OpenAI اتباع ستة تكتيكات أساسية عند كتابة أي أمر لضمان الحصول على إجابات دقيقة وذات صلة:

1. إضافة التفاصيل إلى الأمر: احرص على أن يكون سؤالك محددًا ويتضمن أكبر قدر مناسب من التفاصيل حول ما تريده. كلما كان الأمر أكثر تحديدًا، كانت الإجابة أكثر دقة وتركيزًا على المطلوب. مثال: بدل أن تقول للنموذج: "أعطني نصيحة حول السفر"، يمكنك صياغة طلبك بشكل أوضح: "أعطني خمس نصائح للسفر بميزانية محدودة تشمل نصائح بشأن الطعام والمواصلات والإقامة والتخطيط".
2. طلب تبني النموذج لشخصية أو دور محدد: أحيانًا يكون من المفيد أن تطلب من النموذج الإجابة بأسلوب شخصية معينة أو دور محدد لتعزيز التخصص في الإجابة. على سبيل المثال، يمكنك أن تقول: "تخيل أنك طبيب وتريد إسداء نصائح لمريض حول الحفاظ على صحته العامة؛ ما النصائح التي ستقدمها؟". في هذا الأمر سيتبنى النموذج دور الطبيب ويجب من هذا المنظور المتخصص.
3. استخدام فواصل أو تنسيق واضح لأجزاء الإدخال: إذا كان الطلب الذي تقدمه للنموذج مركبًا أو يحتوي على عدة أجزاء (مثلاً: نص طويل يتبعه سؤال حول ذلك النص)، فمن المهم فصل الأجزاء المختلفة بشكل واضح. يمكنك استخدام علامات تنصيص أو فواصل أو قوائم مرقمة أو أية تنسيقات أخرى لتقسيم المدخل إلى مقاطع مفهومة. هذا يساعد النموذج على تمييز ما تريده بالضبط في كل جزء من الأمر وعدم الخلط بين الأمور المختلفة.
4. توضيح الخطوات المطلوبة لإتمام المهمة: عندما تطلب من النموذج مهمة معقدة ذات مراحل متعددة، حاول أن تقسم المهمة إلى خطوات في أمرك. حدد بشكل صريح ما هي الخطوات أو العناصر التي تتوقع أن تتضمنها الإجابة. مثالاً، بدل أن تسأل "حل هذه المشكلة الرياضية المعقدة"، يمكنك القول: "1) اشرح المعطيات، 2) اذكر القوانين ذات الصلة، 3) اعرض خطوات الحل مع الشرح، 4) أعط النتيجة النهائية." بهذا التوجيه، سيلتزم النموذج ببنية منظمة في الإجابة.
5. تزويد النموذج بأمثلة ضمن الأمر: إعطاء أمثلة إرشادية للنموذج ضمن نص الطلب يمكن أن يوضح له الشكل المطلوب للإجابة. على سبيل المثال، يمكنك تقديم نمط Q&A قصير قبل سؤالك الحقيقي: "س: كيف يؤثر التمرين اليومي على الصحة؟ ج: التمرين اليومي يعزز صحة القلب ويقوي العضلات... (إلخ). الآن س: كيف يؤثر الغذاء الصحي على الطاقة؟ ج: ...". بتضمين مثال أو اثنين كهذا داخل الأمر، سيتبين للنموذج الأسلوب أو مستوى التفصيل المطلوب فيما سيولده من إجابة. تُعرف هذه التقنية باسم *Few-Shot Prompting* حيث تعرض على النموذج بضعة "أمثلة" ليسترشد بها في إنتاج الرد.
6. تحديد الطول أو التنسيق المطلوب للإجابة: من المفيد أحيانًا أن تحدد في أمرك حجم الإجابة أو شكلها المرغوب. يمكنك مثلاً أن تطلب "الإجابة في حدود فقرة واحدة لا تتجاوز 100 كلمة" أو تقول "برجاء أن تكون الإجابة على شكل نقاط مرقمة". تحديد هذه المتطلبات مسبقاً ضمن الأمر يساعد النموذج على ضبط طول الرد وهيكله كما تريد. وهكذا تتفادى الحصول على إجابة مطولة جداً أو مختصرة جداً على غير ما ترغب.

باتباع الاستراتيجيات الستة أعلاه، يمكن للمستخدم أن يوجه النموذج بطريقة تجعل إجاباته أكثر دقة وملاءمة للسؤال المطروح. هذه الممارسات أثبتت عمومًا أنها تقلل من الاستجابات غير المتعلقة أو الغامضة، وتضمن قدرًا أكبر من السيطرة على مخرجات النموذج.

أساليب متقدمة في هندسة الأوامر

إلى جانب التقنيات الأساسية المذكورة، ظهرت مؤخرًا أساليب متقدمة في هندسة وصياغة الأوامر ضمن الأوساط البحثية تهدف إلى تحقيق استفادة أكبر من النماذج، خاصة في المهام المعقدة. فيما يلي لمحة موجزة عن بعض هذه الأساليب المتقدمة:

- **التوجيه التحفيزي الموجه (Directional Stimulus Prompting):** تضمين تلميحات أو توجيهات ضمن الأمر ذاته لتركيز النموذج على زاوية أو أسلوب معين في الإجابة قبل الشروع بالتفاصيل. هذا يعني أن تبدأ سؤالك بجملة تمهيدية تحفز النموذج على اتباع نهج محدد في الرد، مما يضمن أن تأتي الإجابة ضمن الإطار المرغوب.
- **التوجيه باستخدام أمثلة قليلة (Few-Shot Prompting):** سبق شرحه ضمن الاستراتيجيات الأساسية؛ وهو إعطاء النموذج أمثلة ضمن الطلب. يُستخدم هذا الأسلوب لتدريب النموذج ضمنيًا على نمط الإجابة المرغوب خلال نفس جلسة الاستعلام، حيث يتوقع من النموذج أن يستنتج السياق والأسلوب من الأمثلة ويطبقهما على المهمة الجديدة.
- **سلسلة المطالبات (Prompt Chaining):** تنفيذ مهمة معقدة عبر تقسيمها إلى سلسلة من الأوامر المتتابعة. في هذا الأسلوب، يتم طرح أمر أول للنموذج للحصول على جزء معين من الحل أو المعلومات، ثم يُستخدم ناتج هذا الأمر في أمر تالي وهكذا، بشكل تدريجي حتى يتم الحصول على النتيجة النهائية. هذه الطريقة مفيدة لحل المسائل التي تتطلب خطوات متعددة أو استدلالًا طويل المدى، إذ تبقى تركيز النموذج في كل خطوة على نطاق أضيق.
- **شجرة الأفكار (Tree of Thoughts - ToT):** مطالبة النموذج بتوليد سلسلة من الأفكار أو الحلول المحتملة في هيكل هرمي متفرع، بدلًا من إجابة خطية واحدة. يفيد هذا الأسلوب في استكشاف مساحة أكبر من الاحتمالات، حيث يمكن للنموذج تقديم عدة خيارات أو مسارات تفكير متفرعة (كشجرة قرارات) حول مسألة معينة، مما يساعد المستخدم لاحقًا في اختيار الفكرة الأنسب أو الجمع بين الأفكار المطروحة.
- **التوجيه الميتا (Meta Prompting):** تقديم توجيهات ضمن الأمر حول كيفية حل المشكلة أو منهجية التفكير المطلوبة، وليس فقط طلب الإجابة مباشرة. مثلًا، قد يسبق المستخدم سؤاله الرئيسي بطلب من النموذج أن يفكر كنوع معين من الخبراء أو أن يتبع أسلوب تفكير معين ("فكر بطريقة محلل

بيانات..." أو "ضع خطة من ثلاث مراحل للإجابة..."). هذه الميكنة-توجيهات تؤثر في النهج الذي سيسلكه النموذج في إنتاج الإجابة.

- **سلسلة التفكير (Chain-of-Thought - CoT):** مطالبة النموذج بشكل صريح بتوليد خطوات التفكير المنطقي أثناء صياغة الإجابة. أي بدلاً من تقديم الإجابة النهائية فقط، يُطلب من النموذج أن يعرض تسلسلاً من الخطوات المبررة أو الاستنتاجات المرحلية التي قادتته إلى الإجابة. هذا الأسلوب مفيد في المسائل الحسابية أو المنطقية، إذ يساعد على تتبع طريقة الاستدلال والتحقق من صحة كل خطوة على حدة.

- **الاتساق الذاتي (Self-Consistency):** هنا يقوم المستخدم بتشغيل النموذج على نفس السؤال عدة مرات أو يطلب منه اتباع عدة أساليب تفكير مستقلة لإنتاج إجابات متعددة لنفس المشكلة، ثم يقوم بمقارنة هذه الإجابات لترشيح الأكثر اتساقاً ومنطقية بينها. الفكرة هي أن الإجابة الصحيحة أو عالية الجودة ستكون قاسماً مشتركاً بين عدة محاولات للنموذج، مما يزيد الثقة فيها. هذا الأسلوب يقلل من تأثير "الهلوسة" أو الإجابات الشاذة التي قد تنتج من محاولة واحدة.

- **النموذج المُوجَّه بالأدوات (Program-Aided Language Model - PAL):** دمج استخدام أدوات برمجية أو عمليات حسابية خارجية في عملية توليد الإجابة. على سبيل المثال، قد يُطلب من النموذج صياغة معادلة رياضية أو كود برمجي لحل جزء من المشكلة، ثم يتم تنفيذ هذا الكود فعلياً وجلب النتيجة لإكمال الإجابة. بهذا الأسلوب، يستفيد النموذج من قدرات خارجية (كحسابات أو قواعد بيانات) لتعزيز دقة النتائج في المهام التي تتطلب عمليات دقيقة.

- **التوجيه بتوليد المعرفة (Generated Knowledge Prompting):** يتضمن طلباً من النموذج لتوليد معلومات أو حقائق إضافية حول موضوع معين قبل الإجابة على السؤال الرئيسي. فعلى سبيل المثال، قبل طرح سؤال تفصيلي، يمكن أن تطلب من النموذج سرد ما يعرفه عن الموضوع كقائمة نقاط. بعد ذلك تستخدم تلك النقاط (التي ولدها النموذج نفسه) كمرجع ضمني ليبنى عليها إجابته النهائية الأكثر تفصيلاً. هذا الأسلوب أشبه بجعل النموذج يسترجع معرفته الكامنة ذاتياً قبل أن يحاول صياغة الإجابة.

هذه التقنيات المتقدمة تعكس مدى ابتكار الباحثين والمطورين في تحسين تفاعلنا مع نماذج الذكاء الاصطناعي. بعضها لا يزال في طور التجريب الأكاديمي، لكن فهمها يمنحنا نظرة أعمق حول كيفية توجيه النماذج بطرق غير تقليدية لتحقيق نتائج أفضل. مع تطور الأبحاث، قد تصبح بعض من هذه الأساليب جزءاً من الممارسات الشائعة لمستخدمي أدوات الذكاء الاصطناعي في المستقبل.

الذكاء الاصطناعي في القطاعات الاستراتيجية

الذكاء الاصطناعي والرعاية الصحية

أحدث الذكاء الاصطناعي نقلة نوعية في مجال الرعاية الصحية، حيث يساعد في التغلب على المشكلات المتعلقة بإدارة صحة السكان ورعاية المرضى. في مجال الأبحاث الطبية واكتشاف الأدوية وأبحاث الجينات، يُعد الذكاء الاصطناعي أمراً بالغ الأهمية، إذ يمكّن الباحثين من دمج وتحليل مجموعات بيانات ضخمة وتحديد الأنماط بسرعة تفوق بكثير الأساليب التقليدية .

كما تساهم تقنيات الذكاء الاصطناعي في تقليل وقت تشخيص المرض وتصميم خطط علاجية مخصصة من خلال تحليل التاريخ الطبي للمريض والمخاطر المحتملة. يتطلب دمج الذكاء الاصطناعي في الرعاية الصحية التزاماً صارماً بالمعايير الأخلاقية، وحماية بيانات المرضى الحساسة، وضمان عدالة التوصيات العلاجية. ويجب تصميم هذه الأنظمة بحيث تكون قادرة على التعلم والتحسين المستمر مع كل تفاعل، مما يضمن أن تصبح دقة الرعاية وتخصيصها أعلى بمرور الوقت .

الذكاء الاصطناعي في القطاع المالي والمصرفي (BFSI)

يُعد الذكاء الاصطناعي محركاً أساسياً للتحويل في القطاع المالي والمصرفي (BFSI). يُستخدم الذكاء الاصطناعي لتقييم الجدارة الائتمانية عبر التحليلات التنبؤية ونماذج تقييم المخاطر، كما تستخدم خوارزميات التعلم الآلي لضمان دقة اتخاذ القرارات .

في مجال الامتثال التنظيمي ومكافحة غسل الأموال (AML)، يبسط الذكاء الاصطناعي العمليات من خلال مراقبة المعاملات واكتشاف الحالات الشاذة. تستخدم نماذج التعرف على الأنماط للمساعدة في عمليات مكافحة غسل الأموال، مما يضمن الشفافية والامتثال. الأنظمة الذكية قادرة على تتبع ومقارنة أطر الامتثال المتعددة بالتوازي، مما يقلل من الساعات التي تقضيها فرق الامتثال في التدقيق الروتيني والوثائق اليدوية. هذا لا يقلل من التكاليف فحسب، بل يضمن أيضاً تقارير خالية من الأخطاء وفي الوقت المناسب، مما يحسن العلاقات مع المنظمين .

الذكاء الاصطناعي والصناعة 4.0 (الصيانة التنبؤية)

في سياق الثورة الصناعية الرابعة (Industry 4.0)، تُعد الصيانة التنبؤية (Predictive Maintenance - PdM) تطبيقاً محورياً للذكاء الاصطناعي. تهدف PdM إلى منع فشل المعدات ووقت التوقف من خلال التقييم المستمر لحالة المعدات في الوقت الفعلي .

تعتمد آلية عمل الصيانة التنبؤية على ربط الأصول الصناعية المدعومة بإنترنت الأشياء (IoT)، وتطبيق التحليلات المتقدمة والتعلم الآلي على البيانات الناتجة في الوقت الفعلي. تُستخدم خوارزميات التعلم الآلي، مثل العنقدة (Clustering)، في الصيانة المعتمدة على الحالة (CBM) يتيح هذا النهج تعزيز موثوقية الأصول، وزيادة وقت التشغيل، وتقليل التكاليف التشغيلية بشكل فعال. إن قواعد البيانات الحديثة وأنظمة تخطيط موارد

المؤسسة (ERP) المدمجة مع الذكاء الاصطناعي ضرورية لمعالجة البيانات الضخمة وغير الخطية اللازمة لتمكين هذه التحليلات .

الآفاق المستقبلية والتقنيات العابرة

تحدي الذكاء الاصطناعي العام (Artificial General Intelligence - AGI)

يمثل الذكاء الاصطناعي العام (AGI) الهدف النهائي للبحث، وهو ذكاء اصطناعي مبتكر، قابل للتكيف، ولديه القدرة على أداء أي مهمة فكرية يمكن للإنسان القيام بها. ومع ذلك، فإن تحقيق AGI لا يزال يواجه تحديات معرفية جوهرية تتجاوز القدرات الحالية للتعلم العميق. تشمل هذه التحديات :

1. الإبداع (Creativity) على الرغم من أن الذكاء الاصطناعي يمكنه توليد نصوص وإبداعات فنية، إلا أن الإبداع الحقيقي يتضمن الأصالة والجدة، وهو سمة مميزة للإبداع البشري لم يتم تحقيقها بعد في الآلات .

2. الوعي الاصطناعي (Artificial Consciousness) يتناول هذا المجال النظري منح الآلات الوعي الذاتي والتجربة الذاتية، وهو مكون رئيسي يُحتمل أن يكون ضرورياً للذكاء الحقيقي والكامل .

الذكاء الاصطناعي الكمي (Quantum AI - QAI)

يُعتبر الذكاء الاصطناعي الكمي (QAI) تقنية عابرة ناشئة، ظهرت من تضافر الذكاء الاصطناعي مع الحوسبة الكمية (QC). تتجاوز الحوسبة الكمية حدود الحوسبة التقليدية من خلال الاستفادة من مبادئ ميكانيكا الكم، مثل حالة التراكب (Superposition) والتشابك (Entanglement).

الوحدة الأساسية للمعلومات في QC هي البت الكمي (Qubit)، الذي يمكن أن يمثل حالي '0' و '1' في نفس الوقت بفضل خاصية التراكب. هذا يمنح الحواسيب الكمية قدرة فائقة على معالجة كميات هائلة من البيانات بشكل متوازٍ، وهو ما يمثل السرعة اللازمة لتغذية نماذج الذكاء الاصطناعي الضخمة .

يهدف التعلم الآلي الكمي (QML) إلى تحسين التعقيد المكاني والزمني لخوارزميات التعلم الآلي التقليدية. يستخدم QML أساليب هجينة تجمع بين المعالجة التقليدية والكمومية، حيث يتم الاستعانة بالأجهزة الكمية لحل الروتينات الفرعية الصعبة حسابياً، مثل مشكلات التحسين في التعلم العميق. هذا الاندماج ضروري؛ فالحوسبة الكمية هي المسار الواعد لتجاوز القيد الحسابي الذي تفرضه نماذج LLMs الحالية. إضافة إلى ذلك، يمكن لخوارزميات الذكاء الاصطناعي نفسها أن تساعد في التغلب على التحديات التجريبية المرتبطة بتنفيذ وتشغيل الحوسبة الكمية .

من الاتجاهات الناشئة التي تثبت مرونة نماذج المحولات (Transformer architectures) تطبيقها على التنبؤ بالسلاسل الزمنية (Time Series Forecasting - TSF) على الرغم من أن TSF كان تقليدياً مجالاً للتحليل المتخصص، فقد أظهرت الأبحاث إمكانية التعامل مع بيانات السلاسل الزمنية كـ "لغة" يمكن نمذجتها بواسطة المحولات .

تتطلب هذه الآلية تحويل القيم الرقمية المستمرة للسلاسل الزمنية إلى مفردات منفصلة (Discrete Vocabulary) عبر خطوتين: القياس الكمي والتكميم. وقد تحقق هذه النماذج تنبؤات أفضل على مجموعات البيانات التي تظهر موسمية أو اتجاهات قوية، مما يثبت قدرتها على تحديد دورية الأنماط الزمنية بدقة. هذا يوضح أن بنية المحول لديها القدرة على أن تكون نموذجاً أساسياً عالمياً قوياً (Foundation Model) يمكن تطبيقه بنجاح عبر مجالات متباينة، مما يعزز فكرة الذكاء الاصطناعي الضيق القابل للنقل

خاتمة

بعد هذا العرض الشامل حول الذكاء الاصطناعي، يمكننا القول إن هذا المجال يمثل أحد أهم محاور التحول الرقمي العالمي وأبرز ركائز الاقتصاد المعرفي الحديث. فقد انتقل الذكاء الاصطناعي من مجرد فكرة بحثية إلى منظومة تقنية متكاملة تسهم في تطوير مختلف القطاعات، من الرعاية الصحية والصناعة إلى التمويل والتعليم والخدمات الذكية.

لقد تناولت هذه المحاضرة المفاهيم الأساسية للذكاء الاصطناعي، وتطوره التاريخي، وأبرز فروع مثل تعلم الآلة والتعلم العميق والذكاء التوليدي، كما استعرضنا النماذج اللغوية الضخمة ودورها في بناء تطبيقات متقدمة قادرة على محاكاة التفكير البشري. وقد بينا أيضاً أهمية هندسة الأوامر في التفاعل مع هذه النماذج والحصول على أفضل النتائج الممكنة، إضافةً إلى استعراض الاتجاهات المستقبلية مثل الذكاء الاصطناعي العام والذكاء الكمومي.

إن إدراك هذه المفاهيم لا يهدف فقط إلى الفهم النظري، بل إلى تمكين الطلبة من توظيف الذكاء الاصطناعي في مجالات تخصصهم، خصوصاً في المالية والتجارة الدولية، حيث يمكن لهذه التقنيات أن تُحدث تحولاً جذرياً في تحليل البيانات، والتنبؤ بالأسواق، وتحسين سلاسل الإمداد، واتخاذ القرارات الاستراتيجية المبنية على المعرفة.

ختاماً، يبقى الذكاء الاصطناعي علماً متجدداً يتطلب المتابعة المستمرة والتعلم الذاتي والانفتاح على المستجدات. فكل تطور في هذا المجال هو فرصة جديدة للابتكار والإبداع، ومسؤولية في الوقت ذاته لاستخدامه بما يخدم الإنسان والمجتمع على حد سواء.

د عبد الحق ليفيل .

جامعة ميله