

لمحة شاملة الذكاء الاصطناعي

Overview on Artificial Intelligence

الاستاذ ربيع ع. قبلأوي

تعريف الذكاء الاصطناعي

الذكاء الاصطناعي، هو محاكاة للذكاء البشري في الآلات، حيث يتم برمجتها للتفكير والتعلم وحل المشكلات بشكل مستقل. تخيل أن جهاز الكمبيوتر الخاص بك لا ينفذ الأوامر فقط، بل يفهمها ويتعلم منها ويتخذ قرارات بناءً على البيانات.

الهدف الأساسي هو تمكين الآلات من أداء مهام كانت تتطلب في السابق تدخلاً بشرياً، مثل فهم اللغة الطبيعية، التعرف على الصور، واتخاذ القرارات.

عائلة الذكاء الاصطناعي

من الناحية التقنية، الذكاء الاصطناعي عبارة عن مظلة كبيرة تشمل العديد من الخوارزميات والتقنيات المختلفة منها:

- **تعلّم الآلة (Machine Learning):** وهو المجال الأكثر شيوعاً، حيث تتعلم الخوارزميات من البيانات لاتخاذ قرارات أو توقعات. من أمثلتها خوارزميات الانحدار (Regression) والتصنيف (Classification).
- **الذكاء الاصطناعي القائم على الأشجار (Tree based)**
- **التعلم العميق (Deep Learning):** وهو فرع متقدم من تعلم الآلة يستخدم الشبكات العصبية الاصطناعية متعددة الطبقات لمحاكاة طريقة عمل الدماغ البشري في معالجة البيانات المعقدة مثل الصور والصوت.

عائلة الذكاء الاصطناعي (تكميل)

- **الرؤية الحاسوبية (Computer Vision):** تهدف إلى تدريب الآلات على "رؤية" وتفسير وفهم المعلومات المرئية من العالم الرقمي، مثل الصور ومقاطع الفيديو.
- **معالجة اللغات الطبيعية (Natural Language Processing - NLP):** تركز على تمكين أجهزة الكمبيوتر من فهم وتفسير وتوليد اللغة البشرية.


تعلم الآلة (Machine Learning)

التعلم الآلي هو فرع من فروع الذكاء الاصطناعي حيث تتعلم الحواسيب الأنماط من البيانات لتقديم تنبؤات أو اتخاذ قرارات دون أن تتم برمجتها بشكل صريح. يتحسن أدائه بمرور الوقت كلما عالج المزيد من البيانات وطور نماذجه الداخلية.

في التعلم الآلي، يتم تدريب النموذج باستخدام مجموعة من البيانات التي تحتوي على مدخلات (Features) ومخرجات (Labels) معروفة، بحيث يتعلم النموذج العلاقة بينهما. هذا النوع من التعلم يسمى "التعلم الخاضع للإشراف" (Supervised Learning)، حيث يُقدّم للنموذج أمثلة صحيحة تساعد على التعلم. يمكن أيضا فقط تدريب النموذج على بيانات غير مفرزة عندها يصبح التعليم غير خاضع للإشراف, (Unsupervised Learning).


تعلم الآلة (Machine Learning) - التصنيف (classification)

التصنيف (Classification) هو نوع من مشكلات التعلم الآلي حيث يكون الهدف هو تحديد الفئة أو التصنيف الصحيح لعنصر معين. على سبيل المثال: تصنيف الرسائل إلى "بريد عادي" أو "بريد مزعج"، أو تصنيف الصور إلى "قطة" أو "كلب". النتيجة هنا تكون فئة محددة.



تعلم الآلة (Machine Learning) - الانحدار (Regression)

لانحدار (Regression) هو نوع آخر من التعلم الآلي، يهدف إلى التنبؤ بقيمة عددية مستمرة. على سبيل المثال: التنبؤ بسعر منزل بناءً على مساحته وموقعه، أو التنبؤ بدرجة الحرارة غدًا. هنا تكون النتيجة رقمًا وليست فئة.



Classification

Regression

باختصار، التصنيف يحدد "ما هو نوع الشيء؟"، بينما الانحدار يحدد "ما هي قيمة الشيء؟"

أي من الخيارات التالية يُعبر بشكل صحيح عن الفرق الرئيسي بين الانحدار (Regression) والتصنيف (Classification) في تعلم الآلة؟

- أ) الانحدار يتعامل مع البيانات النصية، بينما التصنيف يتعامل مع البيانات العددية.
- ب) الانحدار يُستخدم لتوقع القيم المستمرة، بينما التصنيف يُستخدم لتحديد الفئات أو التصنيفات.
- ج) الانحدار يتطلب بيانات أكثر من التصنيف للعمل بشكل صحيح.
- د) التصنيف يُستخدم فقط مع الصور، والانحدار يُستخدم فقط مع الأرقام.

أي من الخيارات التالية يُعبر بشكل صحيح عن الفرق الرئيسي بين الانحدار (Regression) والتصنيف (Classification) في تعلم الآلة؟

أ) الانحدار يتعامل مع البيانات النصية، بينما التصنيف يتعامل مع البيانات العددية.

ب) الانحدار يُستخدم لتوقع القيم المستمرة، بينما التصنيف يُستخدم لتحديد الفئات أو التصنيفات. ☒


ج) الانحدار يتطلب بيانات أكثر من التصنيف للعمل بشكل صحيح.

د) التصنيف يُستخدم فقط مع الصور، والانحدار يُستخدم فقط مع الأرقام.

الإجابة: ب

الخوارزميات الشجرية (Tree Based Algorithms)

الخوارزميات الشجرية هي نوع من تعلم الآلة تعتمد على بنية "الشجرة", حيث يتم تقسيم البيانات تدريجياً, مناسبة للتصنيف (classification) والانحدار (Regression) تتكون من:



- جذر (Root) : يمثل بداية القرار.
- عقدة داخلية (Nodes): تمثل الأسئلة والشروط.
- أوراق (Leaves): تمثل النتائج أو التصنيف.

خوارزميات شجرية متقدمة

● Random Forest:

- مجموعة من أشجار القرار.
- تعتمد على التصويت (التجميع) للحصول على نتيجة أكثر دقة.


● Gradient Boosted Trees (مثل XGBoost):

- تبني الأشجار بالتتابع، حيث تحاول كل شجرة تصحيح أخطاء السابقة. دقيقة جداً ولكنها أبطأ.

متى نستخدم الخوارزميات الشجرية


- عند التعامل مع بيانات تحتوي على سمات نوعية وكمية
- الخوارزميات الشجرية تتعامل مع أنواع مختلفة من البيانات بدون الحاجة لتحويلات معقدة.
- عند وجود علاقات غير خطية بين المتغيرات
- حيث يمكن للشجرة التقاط التفاعلات والتفرعات المعقدة بين المتغيرات.
- عندما نحتاج إلى نموذج سريع للتدريب والتنبؤ
- الشجرات عادة أسرع مقارنة ببعض النماذج المعقدة مثل الشبكات العصبية

التعلم العميق (Deep Learning)




- التعلم العميق هو فرع من فروع تعلم الآلة يعتمد على الشبكات العصبية.
- يستخدم لتعلم الأنماط المعقدة من كميات ضخمة من البيانات.
- يُستخدم في تطبيقات مثل: التعرف على الصور، الترجمة الآلية، والمساعدات الصوتية.


التعلم العميق (Deep Learning)



الشبكات العصبية, مثال



النيورون العصبي (الوحدة الأساسية)



- الوحدة الأساسية في الشبكات العصبية هي النيورون، يعمل النيورون بالقيام بعملية رياضية بسيطة وهي ضرب المدخل بوزن w .
- الأوزان تسمح لنا بضبط الشبكة العصبية، وخلق مسارات بين المدخل و الجواب.

- من أجل تدريب الشبكة العصبية، كل ما تحتاجه هو معرفة الأوزان الداخلة لكل نيورون بالشبكة، وهذه الأوزان يتم ضبطها بعدة طرق/ خوارزميات. ولكن لا يمكن تدريب الشبكة من دون بيانات.
- البيانات ممكن أن تكون عبارة عن صور، ملفات صوتية، فيديو، كتابة نصية، الخ، ولكن في النهاية تدخل الى الشبكة على شكل ارقام 0 و 1.

- يحتوي موقع kaggle على كم هائل من قواعد البيانات الجاهزة للتدريب على الشبكات العصبية مفتوحة المصدر. ويمكن حتى تنزيل هذه البيانات مباشرة من داخل لغة البايثون. عن طريق مكتبة خاصة.

الرؤية الحاسوبية (computer vision)

الرؤية الحاسوبية هي فرع من الذكاء الاصطناعي يهدف الى تمكين الحاسوب من "رؤية" وفهم الصور والفيديوهات كما يفعل البشر تشمل المهام:

- التعرف على الكائنات
- تحليل المشهد
- تتبع الحركة
- فهم محتوى الصورة

أهمية الرؤية الحاسوبية

● تُستخدم في:

- السيارات ذاتية القيادة.
- الكاميرات الذكية والمراقبة.
- الطب (تحليل الأشعة).
- الواقع المعزز (AR).
- الصناعة (الكشف عن العيوب).

كيف تعمل الرؤية الحاسوبية

- جمع الصور/الفيديو.
- معالجة البيانات (Preprocessing).
- استخراج الميزات (Features).
- التعرف أو التصنيف باستخدام خوارزميات تعلم الآلة أو الشبكات العصبية.

أشهر النماذج و المكاتب

- **Convolutional Neural Networks CNNs** : العمود الفقري للرؤية الحاسوبية الحديثة.

- نماذج مشهورة:

- **YOLO** : لكشف الكائنات بسرعة.


- **ResNet / VGG / MobileNet** : لتصنيف الصور.

- **Mask R-CNN** : لتقسيم وتحديد الكائنات.

- أطر برمجية:

- **PyTorch ، TensorFlow ، OpenCV**

convolutional neural networks ^{أل}



أل convolutional neural networks

الشبكات العصبية الالتفافية هي نوع متقدم من الشبكات العصبية تستخدم بشكل واسع في معالجة الصور و الرؤية الحاسوبية, فبدلا من تحليل كل بيكسيل بشكل منفصل, تستخرج ال CNN الأنماط كالخطوط والحواف من الصور باستخدام مرشحات (filters).

مكونات رئيسية:

طبقة الالتفاف (Convolution Layer), تقوم بتمرير الفلاتر الخاصة لاستخلاص الميزات من الصورة.

طبقة التفعيل (ReLU) تمكن الشبكة من تعلم علاقات أكثر تعقيدًا بين البيانات

طبقة التجميع (Pooling) تقلل من أبعاد البيانات مع الحفاظ على المعلومات المهمة

طبقات كاملة الاتصال (Fully Connected) تستخدم لاتخاذ القرار النهائي

ما هو الدور الأساسي لطبقة الالتفاف (*Convolutional Layer*) في الشبكات العصبية الالتفافية (*CNN*)؟

أ) تقليل الأبعاد المكانية للصورة باستخدام التقسيم

ب) استخراج الميزات المحلية من البيانات المدخلة باستخدام المرشحات

ج) ربط كل مدخلة بكل مخرج لتعلم الأنماط

د) تحويل الإخراج إلى احتمالات باستخدام دالة Softmax

ما هو الدور الأساسي لطبقة الالتفاف (*Convolutional Layer*) في الشبكات العصبية الالتفافية (*CNN*)؟

أ) تقليل الأبعاد المكانية للصورة باستخدام التقسيم

ب) استخراج الميزات المحلية من البيانات المدخلة باستخدام المرشحات

ج) ربط كل مدخلة بكل مخرج لتعلم الأنماط

د) تحويل الإخراج إلى احتمالات باستخدام دالة Softmax

الإجابة: استخراج الميزات المحلية من البيانات المدخلة باستخدام المرشحات

الخوارزميات اللغوية الطبيعية NLP (١)

- هي فرع من الذكاء الاصطناعي يهدف إلى تمكين الآلة من فهم وتحليل وتوليد اللغة البشرية بطريقة ذكية.
- تُستخدم تقنيات **NLP** في العديد من التطبيقات مثل تحليل المشاعر لفهم رأي المستخدم، والترجمة الآلية مثل ترجمة Google، والتلخيص التلقائي للمقالات، والتعرف على الكيانات لاستخراج الأسماء والأماكن والتواريخ، والرد التلقائي على الأسئلة لفهم استفسارات المستخدم وتقديم إجابات مباشرة.

الخوارزميات اللغوية الطبيعية NLP (٢) امثلة


- **Bag of Words**
- **TF-IDF (Term Frequency–Inverse Document Frequency)**
- **Word Embeddings** (مثل Word2Vec, GloVe)
- **Transformers** (مثل BERT ،GPT)

	the	red	dog	cat	eats	food
1. the red dog →	1	1	1	0	0	0
2. cat eats dog →	0	0	1	1	1	0
3. dog eats food →	0	0	1	0	1	1
4. red cat eats →	0	1	0	1	1	0

النماذج التحويلية (Transformers)

- النماذج التحويلية هي معمارية جديدة ظهرت عام 2017 في ورقة بحثية بعنوان " **Attention is All You Need**", أحدثت ثورة في مجال **معالجة اللغة الطبيعية (NLP)**، وتستخدم اليوم في الترجمة، الملخصات، توليد النصوص، وأكثر.

المكونات الرئيسية للنموذج التحويلي




- الترميز (Encoder) وفك الترميز (Decoder):
 - الترميز يفهم ويمثل الإدخال.
 - فك الترميز: يولد الإخراج بناءً على الترميز السابق.
- الإنتباه الذاتي (Self-Attention):
 - يسمح للنموذج بالتركيز على أجزاء مختلفة من الإدخال.

نموذج مبنية على ال Transformers

- : لفهم اللغة والسياق. **BERT**
- : لإنشاء اللغة وتوليد النصوص. **GPT**
- : لنقل المهام إلى مسألة توليد نص. **5BART** و **T**
- : لنقل المعمارية إلى معالجة الصور. **Vision Transformers (ViT)**

- **ال Embedding** هو تمثيل رقمي (Vector) للكلمات بحيث يتم تحويل كل كلمة إلى مجموعة أرقام يمكن للحاسوب فهمها والعمل بها. كل كلمة تُصبح نقطة في فضاء عددي (Vector Space).



لماذا نستخدم ال Embedding

- يجعل النموذج يفهم العلاقات بين الكلمات، يقلل حجم البيانات، تستخدم في الترجمة، تحليل المشاعر، الإجابة على الأسئلة. تستعمل في النماذج اللغوية الكبيرة مثل Bert و GPT.

- **فضاء المتجهات (Vector Space)** هو مساحة رياضية يمكن تمثيل الكلمات فيها كنقاط، بحيث تعكس المسافات بينها العلاقات والمعاني. الكلمات المتشابهة في المعنى تكون قريبة من بعضها في الفضاء. الكلمات المختلفة تكون بعيدة عن بعضها

قياس التشابه، similarity search

- هناك عدة خوارزميات لقياس التشابه بين الكلمات لإيجاد السياق، من أشهرها ال **Cosine Similarity**، و ال **Euclidean Distance**. تُستخدم هذه الخوارزميات لمقارنة تمثيلات الكلمات في فضاء المتجهات (Vector Space)، حيث يُعبّر عن كل كلمة كمتجه عددي. تستعمل هذه الخوارزميات داخل العديد من المكتبات في لغات البرمجة و قواعد البيانات المبنية الخاصة في ال vector databases. من هذه المكتبات مكتبة FAISS من شركة فيسبوك (Meta).

إذا كانت الكلمتان "ملك" و "ملكة" قريبتين في فضاء التضمين (Embedding Space)، وكذلك الكلمتان "رجل" و "امرأة"، فما الاستنتاج الأكثر منطقية عند تنفيذ العملية التالية في فضاء المتجهات؟

$$\text{"ملك"} - \text{"رجل"} + \text{"امرأة"} = ?$$

(أ) "ملكة"

(ب) "زوجة"

(ج) "أميرة"

(د) "قائدة"

إذا كانت الكلمتان "ملك" و "ملكة" قريبتين في فضاء التضمين (Embedding Space)، وكذلك الكلمتان "رجل" و "امرأة"، فما الاستنتاج الأكثر منطقية عند تنفيذ العملية التالية في فضاء المتجهات؟

$$\text{"ملك"} - \text{"رجل"} + \text{"امرأة"} = ?$$

(أ) "ملكة"

(ب) "زوجة"

(ج) "أميرة"

(د) "قائدة"

الإجابة: أ

النماذج اللغوية الضخمة (LLMs)

- **تعريف:**

نماذج ذكاء اصطناعي متقدمة مبنية على النماذج التحويلية (Transformers) لفهم وتوليد النصوص بطريقة مشابهة للبشر.

- **كيف تعمل:**

تعتمد على شبكات عصبية ضخمة مدربة على مجموعات بيانات هائلة من النصوص لتعلم الأنماط اللغوية والقواعد والسياق.

نافذة السياق (Context Window)

التعريف: هي الحد الأقصى لكمية النص (المدخلات والمخرجات) التي يمكن للنموذج معالجتها في تفاعل واحد.
الأهمية: تحدد مدى "ذاكرة" النموذج. كلما كانت أكبر، زادت قدرة النموذج على فهم السياق المعقد والمحدثات الطويلة.

القياس: عادة ما تقاس بالرموز (tokens)

التحكم بالمخرجات: درجة الحرارة (Temperature)

التعريف: معلمة تتحكم في مدى عشوائية أو إبداعية مخرجات النموذج.

النطاق: عادةً ما تتراوح قيمتها بين 0.0 و 1.0 (أو 2.0 في بعض الحالات).

التأثير:

- **درجة حرارة منخفضة (مثال: 0.2):** مخرجات أكثر تحديدًا وتكرارًا، أقل إبداعًا، أفضل للمهام التي تتطلب دقة (مثل تلخيص الحقائق).
- **درجة حرارة عالية (مثال: 0.8):** مخرجات أكثر تنوعًا وإبداعًا، قد تكون غير متوقعة، أفضل للمهام الإبداعية (مثل كتابة القصص أو العصف الذهني).

الحد الأقصى للرموز (Max Output Tokens)

التعريف: يحدد الحد الأقصى لعدد الرموز (tokens) التي سيقوم النموذج بإنشائها كاستجابة.

الأهمية:

- **التحكم بالتكلفة:** خاصة عند استخدام واجهات برمجة التطبيقات (API) حيث يتم الدفع عادةً بناءً على عدد الرموز.
- **تجنب الاستجابات الطويلة جدًا:** للحفاظ على الاستجابات موجزة ومركزة


مخاوف وأخلاقيات النماذج اللغوية الكبيرة

مع تزايد حجم هذه النماذج وتعقيدها، ظهرت تحديات جديدة تتعلق بالاستهلاك الكبير للموارد الحاسوبية، وحاجة النماذج إلى كميات ضخمة من البيانات للتدريب. كما أثارت تساؤلات أخلاقية تتعلق بالتحيزات في البيانات، وخصوصية المستخدمين، واستخدام هذه النماذج في توليد معلومات مضللة. ولذلك، يعمل الباحثون حاليًا على تطوير تقنيات لضبط مخرجات النماذج، وتحسين كفاءتها، وجعلها أكثر أمانًا وموثوقية في الاستخدامات الواقعية.

قواعد البيانات الخاصة بال Vectors

النماذج اللغوية الضخمة لا تخزن المعلومات بطريقة تقليدية, واطافة معلومات جديدة يتطلب اعادة تمرين النموذج على المعلومات الجديدة عن طريق عملية ال "fine-tuning" ولكن يمكن استعمال قواعد بيانات خاصة غير تقليدية لتخزين معلومات جديدة, وعند قيام المستخدم للنموذج بسؤال معين, يتم عملية حساب المسافة بين السؤال وبين النصوص المخزنة في قاعدة البيانات, ليتم تمرير المعلومات ذات الصلة خلال ال context-window الى النموذج

قواعد البيانات الخاصة بال Vectors



شكرا لكم