

مقدمة في التعلم العميق:

الذكاء الاصطناعي هو في الأساس محاكاة للبشر وسلوكياتهم العقلية بواسطة برنامج كمبيوتر يمكنه القيام بأشياء تتطلب عادة ذكاء بشري. بعبارة أبسط، نظام يمكنه محاكاة السلوك البشري. تشمل هذه السلوكيات حل المشكلات والتعلم والتخطيط التي يتم تحقيقها من خلال تحليل البيانات وتحديد الأنماط بداخلها من أجل تكرار تلك السلوكيات

الكود أو التقنية أو الخوارزمية أو أي نظام يمكنه محاكاة فئة الفهم المعرفي التي تظهر حد ذاتها أو إنجازاته هو الذكاء الاصطناعي. يتضمن ذلك التعلم الآلي، حيث يمكن للآلات التعلم من خلال الخبرة واكتساب المهارات دون تدخل بشري. ومن ثم، فإن الذكاء الاصطناعي هو لبنة بناء التعلم الآلي. الواقع، يعد التعلم الآلي مجموعة فرعية رئيسية من الذكاء الاصطناعي ويمكنه تمكين الآلات من استخدام الأساليب الإحصائية لجعل تجاربهم أكثر جودة ودقة. يسمح هذا لأجهزة الكمبيوتر والآلات بتنفيذ الأوامر بناءً على بياناتهم وتعلمهم. تم تصميم هذه البرامج أو الخوارزميات لمعرفة المزيد بمرور الوقت والتكيف مع البيانات الجديدة

الفكرة الرئيسية لاختراع التعلم الآلي القائم على العينة هو أن عملية التفكير المشكلة أصبحت ممكنة من خلال الإشارة إلى أمثلة مماثلة سابقة. تسمى الأمثلة السابقة المستخدمة لبناء القدرات أمثلة تعليمية، وتسمى عملية القيام بذلك التعلم. أنظمة الكمبيوتر، هناك خبرة شكل البيانات، والمهمة الرئيسية للتعلم الآلي هي تطوير خوارزميات التعلم التي تقوم بنمذجة البيانات. من خلال تغذية البيانات التجريبية إلى خوارزمية التعلم الآلي، نحصل على نموذج يمكنه عمل تنبؤات الملاحظات الجديدة.

التعلم العميق هو أيضًا مجموعة فرعية من الذكاء الاصطناعي والتعلم الآلي حيث تكتسب الشبكات العصبية الاصطناعية، والخوارزميات المستوحاة من الدماغ البشري، القدرة على التعلم من كميات كبيرة من البيانات. تقوم خوارزمية التعلم العميق، على غرار الطريقة التي نتعلم بها من التجارب والأمثلة، بعمل شيء واحد مرارًا

وتكرارًا، وتغييره قليلاً كل مرة لتحسين النتيجة. من خلال القيام بذلك، فإنه يساعد أجهزة الكمبيوتر العثور على خصائص من البيانات والتكيف مع التغييرات. يساعد التعرض المتكرر لمجموعات البيانات الآلات على فهم الاختلافات ومناطق البيانات والوصول إلى نتيجة موثوقة. أبسط أشكاله، يمكن اعتبار التعلم العميق وسيلة

لأتمتة التحليلات التنبؤية predictive analytics

تعريف التعلم العميق:

التعلم العميق عبارة عن مجموعة من الخوارزميات التي "تتعلم من خلال الطبقات." بمعنى آخر، يتضمن التعلم من خلال الطبقات التي تمكن الخوارزمية من إنشاء تسلسل هرمي للمفاهيم المعقدة من مفاهيم أبسط

لفهم التعلم العميق بشكل أفضل، تخيل طفلاً صغيراً يتعلم ماهية القطعة. يتعلم الطفل الصغير ما هي القطعة وما هي القطعة من خلال الإشارة إلى الأشياء وقول كلمة "قطعة". يقول الآباء، "نعم، إنها قطعة" أو "لا، إنها ليست قطعة". مع استمرار الطفل الدارج الإشارة إلى الأشياء، فإنه يصبح أكثر وعياً بالخصائص التي تتمتع بها جميع القطط؛ ما الذي يفعله الطفل دون أن يعرف ذلك. هذه هي الطريقة التي يخلق بها تجريباً معقدًا (مفهوم القطعة) من خلال إنشاء تسلسل هرمي يكون فيه كل مستوى من التجريد مع المعرفة المكتسبة من الطبقة السابقة للتسلسل الهرمي، لجعل هذا التجريد المعقد بسيطاً وواضحاً

سبب شعبية التعلم العميق

تتجه صناعة البرمجيات اليوم نحو الذكاء الآلي، والتعلم الآلي هو الذي مهد الطريق للآلات الذكية. ببساطة، التعلم الآلي عبارة عن مجموعة من الخوارزميات التي تحلل البيانات، وتتعلم منها، ثم تطبق ما تعلموه لاتخاذ قرارات ذكية. الشيء الذي يميز خوارزميات التعلم الآلي التقليدية هو أنها، بغض النظر عن مدى تعقيدها، لا تزال شبيهة بالآلة. بمعنى آخر، يحتاجون إلى خبراء هذا المجال للتعلم. بالنسبة لخبراء الذكاء الاصطناعي،

هذه هي النقطة التي يعد بها التعلم العميق. وذلك لأن الشبكات العصبية العميقة تتعلم ميزات عالية المستوى من البيانات بشكل تدريجي (هرميًا) دون الحاجة إلى تدخل بشري. هذا يلغي الحاجة إلى خبراء المجال واستخراج الميزات يدويًا. اختيار السمات لمجموعة البيانات له تأثير كبير على نجاح نموذج التعلم الآلي، حين أن استخراج السمات يدويًا سيكون عملية معقدة وتستغرق وقتًا طويلاً.

اليوم، بالإضافة إلى الشركات والمؤسسات، حتى الأشخاص الجوانب التكنولوجية يميلون إلى التعلم العميق، وعدد هذه الشركات والأفراد الذين يستخدمون التعلم العميق يتزايد يوميًا بعد يوم. لفهم هذا السبب، يجب على المرء أن ينظر إلى الفوائد التي يمكن اكتسابها باستخدام نهج التعلم العميق. يمكن تلخيص الفوائد الرئيسية لاستخدام هذه التقنية على النحو التالي

• لا حاجة لهندسة الميزات: في التعلم الآلي، تعد هندسة الميزات مهمة أساسية وهامة. هذا لأنه يحسن الدقة، وفي بعض الأحيان قد تتطلب هذه العملية معرفة المجال حول مشكلة معينة. تتمثل إحدى أكبر مزايا استخدام نهج التعلم العميق في قدرته على أداء هندسة الميزات تلقائيًا. في هذا النهج، تقوم الخوارزمية بمسح البيانات لتحديد الميزات ذات الصلة ثم دمجها لتسريع التعلم، دون إخبارها صراحة. تساعد هذه الإمكانية علماء البيانات على توفير قدر كبير من الوقت ثم تحقيق نتائج أفضل

• الاستخدام الأقصى للبيانات غير المهيكلة: تظهر الأبحاث أن نسبة كبيرة من بيانات المؤسسة غير المهيكلة ، لأن معظمها في تنسيقات مختلفة مثل الصور والنصوص وما إلى ذلك. بالنسبة لمعظم خوارزميات التعلم الآلي، يعد تحليل البيانات غير المهيكلة أمرًا صعبًا. هذا هو المكان الذي يكون فيه التعلم العميق مفيدًا. لأنه يمكنك استخدام تنسيقات بيانات مختلفة لتعليم خوارزميات التعلم العميق وأيضًا اكتساب رؤى تتعلق

بالغرض من التدريب. على سبيل المثال ، يمكنك استخدام خوارزميات التعلم العميق لاكتشاف العلاقات بين تحليل الصناعة وردشة الوسائط الاجتماعية والمزيد للتنبؤ بأسعار الأسهم المستقبلية للمؤسسة

• تقديم نتائج عالية الجودة: يصاب البشر بالجوع أو التعب وأحيانًا يرتكبون أخطاء. في

المقابل، ليس هذا هو الحال عندما يتعلق الأمر بالشبكات العصبية. يمكن لنموذج

التعلم العميق المدرب بشكل صحيح أن ينجز آلاف المهام الروتينية والمتكررة في فترة زمنية قصيرة نسبيًا مقارنة

بما يحتاجه الإنسان. بالإضافة إلى ذلك ، لن تتخفض جودة العمل أبدًا ، ما لم تحتوي بيانات التدريب على

بيانات أولية لا تشير إلى مشكلة تريد حلها.

• التعلم الانتقالي: يحتوي التعلم العميق على العديد من النماذج المدربة مسبقًا بأوزان وتحيزات ثابتة ، وبعضها

ممتاز في التنبؤ.

دقة عالية في النتائج: عندما يتم تعليم التعلم العميق بكميات هائلة من البيانات، يمكن أن يكون دقيقًا للغاية

مقارنة بخوارزميات التعلم الآلي التقليدية.

عيوب وتحديات التعلم العميق:

على الرغم من تزايد أهمية التعلم العميق وتطوراتها، إلا أن هناك بعض الجوانب أو التحديات السلبية التي يجب

معالجتها لتطوير نموذج التعلم العميق. أكبر قيود على نماذج التعلم العميق هو أنها تتعلم من خلال الملاحظة.

هذا يعني أنهم يعرفون فقط ما هو موجود البيانات التي يقومون بتعليمها وأنهم جيدون فقط التعيين بين المدخلات

والمخرجات. بمعنى آخر، لا يعرفون شيئًا عن سياق البيانات التي يستخدمونها. الواقع، تشير كلمة "عميق"

التعلم العميق إلى مرجع هندسة التكنولوجيا وعدد الطبقات المخفية هيكلها أكثر من كونها تشير إلى فهم عميق

لما يتم القيام به.

تعد نماذج التعلم العميق واحدة من أسوأ نماذج البيانات عالم التعلم الآلي. إنهم بحاجة إلى قدر هائل من

البيانات لتحقيق الأداء المطلوب وخدمتنا بالقدر التي نتوقعها منهم. ومع ذلك، فإن الحصول على هذا القدر من

البيانات ليس بالأمر السهل دائمًا. بالإضافة إلى ذلك ، حين أنه يمكننا الحصول على كميات كبيرة من البيانات

حول موضوع ما، إلا أنه غالبًا لا يتم تصنيفها ، لذلك لا يمكننا استخدامها لتعليم أي نوع من خوارزمية التعلم الخاضع للإشراف. باختصار، لا


تتعلم هذه النماذج بطريقة قابلة للتعميم إذا كان لدى المستخدم كمية صغيرة من البيانات. يمكن أن يعمل التعلم العميق بشكل أفضل عند توفر كمية كبيرة من البيانات عالية الجودة. مع زيادة البيانات المتاحة، يزداد أداء نظام التعلم العميق

تعد قضية التحيزات (biases) أيضًا مشكلة رئيسية لنماذج التعلم العميق. إذا تم تدريب نموذج على بيانات متحيزة، فإن النموذج يعيد إنتاج تلك التحيزات تنبؤاته.

على الرغم من أن نماذج التعلم العميق فعالة للغاية ويمكنها صياغة حل مناسب لمشكلة معينة بعد التدريب مع البيانات، إلا أنه لا غير قادرة على القيام بذلك لحل مشكلة مماثلة وتحتاج إلى إعادة التدريب. لتوضيح ذلك، ضع اعتبارك خوارزمية التعلم العميق التي تتعلم أن الحافلات المدرسية دائمًا ما تكون صفراء، ولكن فجأة تتحول الحافلات المدرسية إلى اللون الأزرق. ومن ثم، يجب إعادة تدريبها. على العكس من ذلك، ليس لدى الطفل البالغ من العمر خمس سنوات مشكلة التعرف على السيارة كحافلة مدرسية زرقاء. بالإضافة إلى ذلك، فهي أيضًا لا تعمل بشكل جيد المواقف التي قد تكون مختلفة قليلاً عن البيئة التي مارسوا فيها. على سبيل المثال، DeepMind دربت Google على هزيمة 49 لعبة Atari . ومع ذلك، كل مرة يهزم فيها النظام مباراة واحدة، يجب إعادة تدريبه لهزيمة المباراة التالية. يقودنا هذا إلى تحديد آخر للتعلم العميق، وهو أنه حين أن النموذج قد يكون جيدًا للغاية تعيين المدخلات إلى المخرجات، فقد لا يكون جيدًا فهم سياق البيانات التي يديرونها.


يتعلم نمط التعلم العميق أو بشكل عام خوارزميات التعلم الآلي الحالية بشكل منفصل: وفقًا لمجموعة بيانات التدريب، تعمل خوارزمية التعلم الآلي على مجموعة البيانات لإنتاج نموذج ولا تبذل أي جهد للحفاظ على

المعرفة المكتسبة واستخدامها تفعيل التعلم المستقبل. على الرغم من أن نموذج التعلم المنفصل هذا كان ناجحًا للغاية، إلا أنه يتطلب عددًا كبيرًا من أمثلة التدريب وهو مناسب فقط للمهام المحددة والمحدودة جيدًا. مع توفر مجموعات بيانات أكبر وخفض التكاليف الحسابية، أصبحت النماذج القادرة على حل المهام الأكبر متاحة. ومع ذلك، قد يكون تعليم نموذج كل مرة يحتاج فيها لتعلم مهمة جديدة أمرًا مستحيلًا. نظرًا لأن البيانات القديمة قد لا تكون متاحة، فقد لا يتم تخزين البيانات الجديدة بسبب مشكلات الخصوصية، أو قد لا يدعم تكرار تحديث النظم تدريب نموذج جديد مع تكرار جميع البيانات بشكل كافٍ. عندما تتعلم الشبكات العصبية العميقة مهامًا جديدة، فإن المعرفة الجديدة لها الأسبقية على المعرفة القديمة إذا لم يتم استخدام معايير معينة، مما يؤدي غالبًا إلى نسيان المعرفة الثانوية. يُعرف هذا بالنسيان الكارثي (catastrophic forgetting) (انظر الشكل 1 - 1). يحدث النسيان الكارثي عندما تكون الشبكة العصبية المدربة غير قادرة على الحفاظ على قدرتها على أداء المهام التي تعلمتها بالفعل عندما تتكيف مع المهام الجديدة.



مشكلة أخرى مع الشبكات العصبية العميقة هي أنها غالبًا ما يتم تدريبها على افتراضات العالم المغلق، أي أنه من المفترض أن يكون توزيع البيانات التجريبية مشابهًا لتوزيعة بيانات التدريب. ومع ذلك، عند استخدامه في العمل الواقعي، يكون هذا الافتراض غير صحيح ويؤدي إلى انخفاض كبير في أدائهم. عندما تعالج الشبكات العصبية العميقة البيانات التي لا تشبه التوزيع العالذي لوحظ أثناء التدريب، ما يسمى خارج التوزيع (Out-of-distribution)، فإنها غالبًا ما تقدم تنبؤات خاطئة وتعمل ذلك بثقة كبيرة. (انظر الشكل 1 - 2). في هذه الحالات، يرتبط إخراج الشبكة ارتباطًا مباشرًا بحل المشكلة، أي احتمال كل

فئة. ومع ذلك، يجب أن يكون مجموع تمثيلات متجه الإخراج واحدًا دائمًا. هذا يعني أنه عندما يتم عرض إدخال على الشبكة ليس جزءًا من توزيع التدريب، فإنه لا يزال يعطي الاحتمال لأقرب فئة بحيث يصل مجموع الاحتمالات إلى واحد. أدت هذه الظاهرة إلى المشكلة المعروفة المتمثلة في الإفراط في الثقة (overconfident) في الشبكات العصبية بمحتوى لم يسبق لهم رؤيته من قبل



أخيرًا، يتمثل أكثر نقاط الضعف المعروفة للشبكات العصبية افتقارها إلى الشفافية. بينما يمكن تتبع القرارات التي تتخذها النماذج المستندة إلى القواعد من خلال عبارات if and else ، فإن هذا لن يكون ممكنًا التعلم العميق. هذا النقص الشفافية هو ما يشار إليه التعلم العميق باسم "الصندوق الأسود"


المفاهيم الأساسية، الفرق بين ML وDL، وأبرز التطبيقات في التخصصات الاقتصادية والإدارية.

تعلم الآلة هو فرع من فروع الذكاء الاصطناعي الذي يُشير إلى منح الآلات القدرة على التعلم واتخاذ القرار بالاعتماد على نفسها دون الحاجة إلى برمجتها من قبل الإنسان، بحيث يمكنها التعلم من الإجراءات السابقة، وتخزين البيانات للاستفادة منها والتحسين من أدائها في أي عمل مستقبلي.

يتم ذلك عن طريق استخدام برامج يتم تصميمها لتوليد الأفكار من خلال البيانات التي تُعرض عليها، وتطبيقها على عمليات مثل اتخاذ القرارات، والتعرف على الأصوات، أو حتى التنبؤ بالمستقبل أصبح تعلم الآلة يدخل في كثير من المجالات التي نتفاعل معها على مدار اليوم، مثل البنوك، والتسوق الإلكتروني، واستخدام وسائل التواصل الاجتماعي وغيرها الكثير

هناك أيضا **التعلم العميق** (6) الذي يُمثل فرع من فروع تعلم الآلة، الذي تعتمد فكرته على تقليد عمل الخلايا العصبية الموجودة في العقل البشري من خلال ابتكار شبكة عصبية اصطناعية (Artificial Neural Network) تستطيع تحليل كميات ضخمة من البيانات غير المُنظمة مثل اللغات المختلفة والصور وترجمتها عبر تمريرها من خلال الشبكة العصبية للتعرف عليها من خلال عدة مراحل، من هنا جاء مصطلح "العميق". تشمل تطبيقات التعلم العميق على سبيل المثال، التعرف على الكلام، والأصوات، والصور.

مما سبق، نستخلص أن الذكاء الاصطناعي هو المجال الأوسع، في حين أن كلا من تعلم الآلة والتعلم العميق، هما بمثابة مجالات يتم من خلالها توظيف الذكاء الاصطناعي لتحقيق أهداف محددة، كما هو موضح بالشكل التالي.



التطبيقات الأساسية

1. **التنبؤ الاقتصادي والمالي (Forecasting — أسعار الأصول، مؤشرات اقتصادية، المبيعات)**
 - ما يُستخدم: شبكات زمنية عميقة (LSTM/GRU)، Transformers للبيانات الزمنية، نماذج هجينة. (CNN + LSTM)
 - الفائدة العملية: تحسين دقة التنبؤات مقارنةً بأساليب إحصائية تقليدية عند وجود بيانات ضخمة وغير خطية (أسعار أسهم، حجم مبيعات، مؤشرات الطلب).
 - قيود: الإفراط في التكيف على بيانات التاريخ، صعوبة تفسير النماذج، وحساسية للأحداث النادرة [MDPI+1](#).
2. **كشف الاحتيال والمخالفات المحاسبية (Fraud & Anomaly Detection / Auditing)**
 - ما يُستخدم: شبكات عميقة لاكتشاف الأنماط (Autoencoders)، CNN/RNN للمتسلسلات، GNN للشبكات المعاملاتية)، ونماذج تصنيف متقدمة.
 - الفائدة العملية: كشف سلوك احتيالي غير ظاهر في سمات متعددة وبُنى علاقات معقدة بين حسابات ومعاملات؛ تحسين الكشف التلقائي وتقليل الإنذارات الكاذبة عند ضبط النموذج جيداً.
 - قيود: ندرة أمثلة الاحتيال (imbalance)، متطلبات خصوصية/امتثال، وضرورة تفسير النتائج للمراجعة البشرية [ScienceDirect+1](#).
3. **التقييم الائتماني وإدارة المخاطر (Credit Scoring & Risk Modeling)**
 - ما يُستخدم: شبكات عميقة لمعالجة ميزات واسعة النطاق (دمج بيانات مالية، سلوكية ونصوص)، ونماذج تجسيد (embeddings) للمستندات.
 - الفائدة العملية: تحسين تقدير احتمالية التعثر، رصد التغيرات في سيولة العملاء، وتمكين تسعير مخاطر أكثر دقة.
 - قيود: مخاطر انحياز (bias) ضد مجموعات معينة إن كانت البيانات غير متوازنة؛ متطلبات الشفافية للتنظيم [arXiv](#).
4. **سلاسل الإمداد واللوجستيات (Supply Chain Optimization & Demand Forecasting)**
 - ما يُستخدم: نماذج للتنبؤ بالطلب (time-series DL)، التعلم التعزيزي العميق (Deep RL) لاتخاذ قرارات التوريد/التخزين، ونماذج للرؤية الحاسوبية لتحليل حالات المخزون من صور/كاميرات.

○ **الفائدة العملية:** تقليل نفاد المخزون، تحسين جداول التوريد، تقليل تكاليف المخزون وتحسين استجابة السلسلة للأحداث الطارئة.

○ **قيود:** جودة البيانات عبر الموردين، التكامل مع أنظمة ERP القديمة، وحاجة للنمذجة المتكاملة (بيانات طقس، أحداث، تسويق) [ScienceDirect+1](https://www.sciencedirect.com).

5. تحليل العملاء والتسويق الشخصي (Customer Analytics & Personalization)

○ **ما يُستخدم:** نماذج توصية عميقة (Deep Recommenders)، نماذج لغوية كبيرة

(LLMs/embeddings) لتحليل التعليقات والآراء، وتحليل سلوك المستخدم بالزمن الحقيقي.

○ **الفائدة العملية:** تخصيص عروض/حملات تسويقية، تحسين الاحتفاظ بالعملاء وزيادة القيمة

طويلة المدى للعميل. (CLV)

○ **قيود:** خصوصية البيانات، الحاجة لآليات تفسير لقرارات التوصية، ومدى قابلية النقل عبر

قطاعات مختلفة.

6. استخلاص المعرفة من النصوص والوثائق (NLP) للبيانات غير المنظمة — تقارير شركات،

عقود، مواقع تواصل)

○ **ما يُستخدم:** نماذج تحويلية (Transformers)، استخراج الكيانات والملخصات، تصنيف

المشاعر، وتحويل اللغة إلى خصائص كمية للاستخدام في نماذج اقتصادية.

○ **الفائدة العملية:** قياس معنويات السوق، استخراج إشارات مبكرة من تقارير الشركات، أتمتة مراجعة

العقود والامتثال.

○ **قيود:** الحاجة لتخصيص لغوي/قطاعي؛ النصوص المالية قد تحتوي مصطلحات خاصة تتطلب

تدريب خاص.