

حوار حول التعلم العميق

موضوعات التعلم العميق بأسلوب حوارى بين استاذ وطالبتة

اعداد: د.علاء طعيمة



بِسْمِ تَعَالَى

حوار حول التعلم العميق

موضوعات التعلم العميق بأسلوب حوارى بين استاذ وطالبته

اعداد:

د. علاء طعيمة

مقدمة المؤلف

في هذا الكتيب، نتجول في عالم التعلّم العميق وشبكات التعلّم العميق، ذلك المجال المتفرّع عن الذكاء الاصطناعي، والذي أصبح اليوم محوراً بارزاً في تطوير التقنيات الحديثة. سنستعرض من خلال حواراتٍ شيّقة ومبسّطة أهم الأسس المفاهيمية، ونستكشف تطبيقات التعلّم العميق في مختلف الميادين، من التعلّم على الصور والأصوات وصولاً إلى التحليل اللغوي وتوليد المحتوى الإبداعي.

لقد ولدت فكرة هذا الحوار من طالبتي حوراء، التي أبدت حماساً وفضولاً كبيراً لمعرفة تفاصيل هذا المجال المعقّد، فاقترحت أن نعرض المعرفة من خلال نقاشات بين استاذ وطالبتة، بأسلوب تسهل متابعته على القراء. أمل أن يجد القارئ في هذه الصفحات مقدّمة مفيدة تُعينه على فهم التعلّم العميق، وتفتح أمامه آفاقاً جديدة للإبداع والاكتشاف.

في طيّات هذه الصفحات، سنحاولُ الإجابة عن أسئلة كثيرة، وسنفتح مساحات للنقاش والتأمل في عالم لا يزال يَمورُ بالابتكار والتطور، آمليْن أن يكون هذا الكتيب خطوة أولى لكل متعطّش لمعرفة آفاق التعلّم العميق ورسم معالم رحلته العلمية والعملية.

لقد حاولت قدر المستطاع ان اجمع الأسئلة الأكثر طرحاً مع الأجوبة المناسبة والكافية، ومع هذا يبقى عملاً بشرياً يحتمل النقص، فاذا كان لديك أي ملاحظات حول هذا الكتيب، فلا تتردد بمراسلتنا عبر بريدنا الإلكتروني

. alaa.taima@qu.edu.iq

نأمل ان يساعد هذا الكتيب كل من يريد ان يدخل في مجالات التعلّم العميق ومساعدة القارئ العربي على تعلم هذا المجالات. اسأل الله التوفيق في هذا العمل

لأثراء المحتوى العربي الذي يفتقر أشد الافتقار إلى محتوى جيد ورصين في مجال
التعلم الآلي والتعلم العميق وعلم البيانات. ونرجو لك الاستمتاع مع الكتاب ولا
تنسونا من صالح الدعاء.

د. علاء طعيمة

كلية علوم الحاسوب وتكنولوجيا المعلومات

جامعة القادسية / العراق

المحتويات

- 6 الحوارية الاولى: مقدمة في التعلم العميق
- 11 الحوارية الثانية: اساسيات التعلم العميق
- 20 الحوارية الثالثة: الشبكات العصبية امامية التغذية
- 27 الحوارية الرابعة: الشبكات العصبية الالتفافية
- 38 الحوارية الخامسة: الشبكات العصبية المتكررة
- 45 الحوارية السادسة: شبكات الخصومة التوليدية

الحوارية الاولى: مقدمة في التعلم العميق

(مكتب الدكتور علاء طعيمة في الجامعة، مكتب منظم، بعض الكتب والأوراق مبعثرة على الطاولة، شاشة حاسوب تعرض أبحاثاً جديدة. تدخل حوراء إلى المكتب وتحمل دفتر ملاحظات).

حوراء (تطرق الباب بلطف): صباح الخير دكتور علاء طعيمة، هل يمكنني الدخول؟

الدكتور علاء طعيمة (يتطلع نحو الباب): تفضلي يا حوراء، ادخلي. كيف حالك اليوم؟

حوراء (بابتسامة ودودة): بخير، شكراً لك. وأنت؟

الدكتور علاء طعيمة (يعدل نظارته ويشير لها بالجلوس): أنا بخير أيضاً. اجلسي، ما الذي يجلبك اليوم؟

حوراء (تجلس وتفتح دفترها): كنت أراجع معلومات حول الذكاء الاصطناعي والتعلم العميق في كتابك (التعلم العميق من الأساسيات حتى بناء شبكة عصبية عميقة بلغة البايثون) وقرأت مقدمة طويلة عن الموضوع. لدي بعض الأسئلة وأريد توضيحات أكثر.

الدكتور علاء طعيمة (يقرب الكرسي نحو مكتبه): ممتاز. يسعدني دائماً مساعدة طلابي في فهم هذه المفاهيم. اطرحي ما لديك من أسئلة.

حواء (تنظر في ملاحظاتها): قرأت أن الذكاء الاصطناعي هو المجال الكبير الذي يحاول محاكاة الذكاء البشري، وأن التعلم الآلي هو مجموعة فرعية منه، والتعلم العميق مجموعة فرعية من التعلم الآلي. هل يمكنك تأكيد هذه العلاقة وشرحها ببساطة؟

الدكتور علاء طعيمة (يميل للأمام على مكتبه): بالتأكيد. الذكاء الاصطناعي هو المجال العام الذي يهدف إلى جعل الآلات قادرة على أداء مهام تتطلب عادةً ذكاءً بشرياً. التعلم الآلي هو طريقة واحدة لتحقيق ذلك، حيث نسمح للبرامج بالتعلم من البيانات بدلاً من برمجتها صراحة. أما التعلم العميق فهو أسلوب محدد من أساليب التعلم الآلي يستخدم الشبكات العصبية الاصطناعية متعددة الطبقات لاستخراج الميزات تلقائياً من كميات كبيرة من البيانات وتحسين الأداء مع كل طبقة.

حواء (بتعبير مهتم): فهتمت. إذن التعلم العميق هو نوع متخصص من التعلم الآلي يعتمد على الشبكات العصبية العميقة؟

الدكتور علاء طعيمة (يبتسم ويشير بإصبعه تأكيداً): تماماً. هذه الشبكات العصبية تشبه الطريقة التي يتعلم بها الطفل. في البداية، يتعرف الطفل على ميزات بسيطة جداً، ثم يبني فوقها مفاهيم أكثر تعقيداً، تماماً كما تبني الشبكات العصبية مفاهيمها الطبقيّة.

حواء (تقلب صفحة في دفترها): قرأت عن ميزات أخرى للتعلم العميق مثل أنه لا يحتاج إلى هندسة ميزات يدوية، ويستفيد من البيانات الضخمة، ويقدم دقة عالية. لكن ماذا عن عيوبه؟

الدكتور علاء طعيمة (يضع قلمه جانباً): صحيح. للتعلم العميق بعض التحديات:

- يحتاج لكميات هائلة من البيانات عالية الجودة.
- هو بمثابة "صندوق أسود" يصعب تفسيره.
- يعاني من مشكلة "النسيان الكارثي" عند تعلم مهام جديدة.
- قد يكون مفرط الثقة عند التعامل مع بيانات مختلفة عن تلك التي تدرب عليها.
- ويصعب أحياناً فهم قراراته، ما يثير قضايا أخلاقية وتنظيمية.

حوراء (بحاجيين مرفوعين): هذا يبدو معقداً. هل هناك اتجاهات مستقبلية لمحاولة معالجة هذه العيوب؟

الدكتور علاء طعيمة (يستند إلى الخلف في كرسيه): نعم، هناك أبحاث كثيرة تهدف إلى الجمع بين التعلم العميق وأساليب أخرى، مثل التفكير الرمزي أو المعرفة المسبقة، مما قد يساهم في جعل الأنظمة أكثر مرونة وقدرة على الاستدلال. هناك باحثون مثل غاري ماركوس يقترحون مناهج هجينة، وإضافة قواعد معرفية، وبناء أطر معرفية ثرية، واستخدام آليات تمثيل واستقراء أفضل.

حوراء (تدوّن الملاحظات): مثير جداً. وماذا عن التطبيقات الحالية للتعلم العميق؟ أين نراه في حياتنا اليومية؟

الدكتور علاء طعيمة (يشير إلى الشاشة بجواره): في كل مكان تقريباً.

- المساعدون الافتراضيون مثل Siri و Alexa يتعلمون من صوتك ويستجيبون لأوامرك.
- تجميع الأخبار واكتشاف الأخبار المزيفة يعتمد على التعلم العميق.

- في الرعاية الصحية، نماذج تشخيص الأمراض وتحليل الصور الطبية.
- في القطاع المالي، نماذج كشف الاحتيال.
- في صناعة السيارات، أنظمة القيادة الذاتية.
- وفي العديد من تطبيقات معالجة اللغة الطبيعية والرؤية الحاسوبية.

حوراء (مندهشة): رائع. إذن التعلم العميق تقنية ذات تأثير واسع. هل تعتقد أننا سنصل إلى ذكاء اصطناعي عام يشبه ذكاء البشر باستخدام التعلم العميق وحده؟

الدكتور علاء طعيمة (متأملاً): هذا موضوع نقاش كبير. بعض الباحثين يؤمنون بأن التعلم العميق كافٍ لحل كل المشكلات، والبعض الآخر يشير إلى أوجه القصور. حالياً، لا نستطيع الوصول إلى ذكاء اصطناعي عام يشبه البشر فقط بالتعلم العميق. نحتاج إلى إضافة التفكير المنطقي وفهم السياق واستخدام المعرفة المسبقة. لكن من يدري ما قد يحمله المستقبل؟

حوراء (تبتسم وتميل برأسها تقديراً): شكراً لك يا دكتور. أصبحت لدي صورة أوضح حول الذكاء الاصطناعي والتعلم العميق، وفهمت تشابكهما مع التعلم الآلي ومزاياهما وعيوبهما.

الدكتور علاء طعيمة (ينهض ويسلمها بعض الأوراق): على الرحب والسعة يا حوراء. إليك بعض المراجع الإضافية قد تساعدك في بحثك. وإن احتجت لمزيد من الاستفسار، مكنتي مفتوح دائماً.

حوراء (تمسك بالأوراق): شكراً جزيلاً لك دكتور علاء طعيمة. سأعود إذا احتجت لمزيد من التوضيحات.

الدكتور علاء طعيمة (بابتسامة ودية): بالتوفيق يا حوراء. أراك لاحقاً.

الحوارية الثانية: اساسيات التعلم العميق

(مكتب الدكتور علاء طعيمة في الجامعة، حيث توجد طاولة مكتظة بالكتب وأوراق بحثية، وعلى الشاشة خلفه تظهر أبحاث متعلقة بالتعلم العميق. تدخل حوراء، طالبة مجتهدة، ويدها دفتر ملاحظات.)

حوراء (تطرق الباب بلطف): صباح الخير يا دكتور علاء طعيمة، هل يمكنني الدخول؟

الدكتور علاء طعيمة (يرفع رأسه ويبتسم): صباح النور يا حوراء. تفضلي، اجلسي. كيف حالك اليوم؟

حوراء (تجلس أمام المكتب): بخير، شكراً. دكتور، قرأت نصاً طويلاً حول البيانات والتعلم الآلي والتعلم العميق، والتقنيات المختلفة المستخدمة، بالإضافة إلى طرق التقييم والتجزئة وأدوات مثل بايثون و Jupyter و Colab. شعرت بتشعب الأفكار. أريد تلخيص وفهم هذه المعلومات في حوارٍ منظم.

الدكتور علاء طعيمة (بهدهوء): ممتاز. هات ما لديك من أسئلة.

حوراء (تقلب صفحات دفترها): في البداية، ما الهدف من استعراض مفاهيم التعلم الآلي قبل التعلم العميق؟

الدكتور علاء طعيمة: التعلم العميق هو مجموعة فرعية من التعلم الآلي، والتعلم الآلي بدوره مجموعة فرعية من الذكاء الاصطناعي. لفهم التعلم العميق جيداً، نحتاج أن نفهم أساسيات التعلم الآلي: ما هي البيانات؟ وكيف نصنف طرق التعلم؟ وكيف نقوم بتقييم النموذج؟ كل هذا يشكل أساساً قبل الخوض في التعلم العميق.

حوراء (تنظر للملاحظات): تحدث النص في الكتاب عن البيانات وعرفها. ما المقصود بالبيانات في هذا السياق؟

الدكتور علاء طعيمة: البيانات هي معلومات مميزة تم تنسيقها وتخزينها لتحقيق غرض معين. تأتي بأشكال عديدة: أرقام، نصوص، بايتات إلكترونية. في علم الحاسوب، غالباً ما تكون البيانات مدخلات لخوارزميات المعالجة. ونحن نحتاج لكثير من البيانات لتدريب نماذج التعلم الآلي والتعلم العميق.

حوراء: وما الفرق بين البيانات المقروءة آلياً وتلك المقروءة بشرياً؟

الدكتور علاء طعيمة: البيانات المقروءة آلياً هي بيانات بتنسيقات منظمة تفهمها الحواسيب بسهولة، مثل CSV أو JSON، وهي سهلة الاستخراج والمعالجة. أما البيانات المقروءة بشرياً فقد تكون نصوص في PDF أو نص حر يصعب على الآلة فهمه مباشرة، إذ تحتاج لتحويل أو معالجة خاصة.

حوراء (تدوّن): فهمت. وذكر النص مصطلحات مثل البيانات المهيكلة وغير المهيكلة والبيانات الضخمة. ما المقصود بها؟

الدكتور علاء طعيمة (يفتح يديه بتوضيح):

- البيانات المهيكلة: بيانات منظمة في حقول ثابتة مثل جداول قواعد البيانات.
- البيانات غير المهيكلة: مثل الصور والفيديو والنص الحر الذي لا يتبع قالباً ثابتاً.

- البيانات الضخمة: كميات هائلة من البيانات من مصادر متنوعة، تحتاج لأدوات تحليل خاصة.

أيضاً ذكر النص مفاهيم مثل البيانات الوصفية (Metadata) وهي بيانات عن البيانات، والبيانات الخام (Raw data) التي لم يتم تحليلها أو تنسيقها.

حوراء: وماذا عن أنواع البيانات من حيث الخصائص العددية والفئوية؟

الدكتور علاء طعيمة:

- البيانات الرقمية (المستمرة): مثل درجة الحرارة بالأرقام، يمكن أن تأخذ قيماً لانهائية.
- البيانات الفئوية (الاسمية): مثل لون العين أو لون الهاتف، فئات لا يمكن ترتيبها رياضياً.

وبالنسبة للتصنيف، قد تكون البيانات رقمية أو فئوية، وذلك يؤثر على نوع العمليات الإحصائية الممكنة.

حوراء: النص تحدث عن مجموعات البيانات (Dataset) والميزات (Features). ماذا يقصد بذلك؟

الدكتور علاء طعيمة: مجموعة البيانات عبارة عن جدول يمثل كل صف فيه عينة أو نقطة بيانات، وكل عمود يمثل ميزة (سمة) من سمات هذه البيانات. الميزة هي متغير تفسيري يصف جانباً معيناً من بياناتك، وقد تكون رقمية أو وصفية. في التعلم الآلي، كثيراً ما نقوم بتمثيل كل عينة بمتجه ميزات.

حواء (تقلب الصفحة): الآن، دعنا ننتقل إلى طرق التعلم الآلي. ماهو الفرق بين التعلم بإشراف والتعلم بدون إشراف؟

الدكتور علاء طعيمة:

- **التعلم بإشراف (Supervised Learning)** : لدينا بيانات مدخلة وعليها تسميات (مخرجات) معروفة. نستخدم هذه البيانات المصنفة لتدريب النموذج وتعلم العلاقة بين المدخلات والمخرجات. أمثلة: التصنيف (Classification) والانحدار (Regression).
- **التعلم بدون إشراف (Unsupervised Learning)** : لا توجد تسميات. نحاول اكتشاف الأنماط والبنية الكامنة في البيانات. أمثلة: التجميع (Clustering)، وتقليل الأبعاد (Dimensionality Reduction).

حواء: في التعلم بإشراف، ما هو التصنيف وما هو الانحدار؟

الدكتور علاء طعيمة:

- **التصنيف:** تعيين المدخلات إلى فئات منفصلة (مثل: بريد عادي مقابل بريد مزعج). ينقسم إلى تصنيف ثنائي (فئتين) أو متعدد الفئات، وقد يكون أيضاً متعدد العلامات (عينة واحدة لها عدة تسميات).
- **الانحدار:** التنبؤ بقيمة عددية مستمرة (مثل: التنبؤ بسعر منزل).

حوراء: وماذا عن مزايا وعيوب التعلم بإشراف؟

الدكتور علاء طعيمة:

- المزايا: النتائج عادة أكثر دقة، ويمكن فهم العملية بسهولة. لا تحتفظ ببيانات التدريب في الذاكرة دائماً.
- العيوب: جمع وتصنيف البيانات مكلف، وقد لا يتعامل النموذج جيداً مع بيانات جديدة من خارج نطاق التدريب، كما أن التدريب قد يستغرق وقتاً طويلاً.

حوراء: والتعلم بدون إشراف؟

الدكتور علاء طعيمة:

- المزايا: أسهل الحصول على بيانات غير موسومة، ويمكنه اكتشاف أنماط غير معروفة سابقاً.
- العيوب: تفسير النتائج يحتاج تدخلاً بشرياً، ولا يوجد معيار لمعرفة دقة النتائج نظراً لغياب التسميات، وقد يكون أقل دقة.

حوراء (تبتسم): والنص ذكر أيضاً التعلم المعزز (Reinforcement Learning). ما فكرته؟

الدكتور علاء طعيمة: التعلم المعزز مقتبس من سيكولوجيا تعلم الحيوانات. يتعلم الوكيل باتخاذ إجراءات في بيئة معينة ويحصل على مكافآت أو عقوبات. الهدف هو تعظيم المكافأة عبر سياسة مثلى. لا توجد تسميات صريحة، بل تعلم من التجربة.

حوراء (تشير لبعض الملاحظات): تحدّث النص عن اختيار النموذج وتقييمه، وتجهيز البيانات. ما المقصود بذلك؟

الدكتور علاء طعيمة:

- اختيار النموذج (Model Selection) : اختيار أفضل نموذج أو أفضل معاملات فائقة (Hyperparameters) من بين عدة نماذج.
- تقييم النموذج (Model Evaluation) : تقدير أداء النموذج على بيانات لم يسبق له رؤيتها. نستخدم عادة تجزئة البيانات إلى: تدريب (Training) ، تحقق (Validation) ، واختبار (Test).
- نستخدم التحقق المتقاطع (Cross-Validation) خاصةً عند قلة البيانات، لتقليل التحيز والتباين.

حوراء: ما هو التحيز والتباين في السياق هذا؟

الدكتور علاء طعيمة: التحيز (Bias) هو الخطأ الناتج عن تبسيط النموذج أكثر من اللازم، وعدم قدرته على التقاط الأنماط الحقيقية المعقدة. التباين (Variance) هو حساسية النموذج لتقلبات بيانات التدريب، يؤدي إلى تجهيزه الزائد (Overfitting) . نريد تحقيق توازن بين التحيز والتباين.

حوراء: وكيف نقيس الأداء؟ ذكر النص مصفوفة الارتباك (Confusion Matrix) والدقة والاستدعاء وغيرهما.

الدكتور علاء طعيمة:

- مصفوفة الارتباك (Confusion Matrix): جدول يحصي التنبؤات الصحيحة والخاطئة. (TP, FP, FN, TN)
- الدقة (Accuracy): نسبة التنبؤات الصحيحة.
- الاستدعاء (Recall): قدرة النموذج على اكتشاف الحالات الإيجابية من بين كل الحالات الإيجابية الحقيقية.
- الدقة (Precision): نسبة الحالات الإيجابية المتنبأ بها الصحيحة.
- درجة F1 (F1-Score): مقياس يجمع بين الدقة والاستدعاء. الهدف هو فهم مدى موثوقية النموذج، وليس فقط نسبة الدقة.

حوراء: النص تحدث أيضاً عن الأدوات والمكتبات. كيف نبدأ مع بايثون وما الأدوات المفيدة؟

الدكتور علاء طعيمة:

- يمكن تثبيت بايثون من الموقع الرسمي وتشغيله عبر IDLE أو سطر الأوامر.
- نستخدم pip لتثبيت المكتبات مثل (NumPy).
- **Jupyter Notebook:** أداة تفاعلية لكتابة الأكواد وعرض النتائج مع النصوص والمعادلات والوسائط.
- **Google Colab:** خدمة سحابية تشبه Jupyter Notebook، توفر وحدات GPU و TPU مجاناً، تسهل التعاون والمشاركة، لكنها أقل خصوصية.

حوراء (تهزأها بتقدير): وماذا عن أطر التعلم العميق؟

الدكتور علاء طعيمة:

- **PyTorch**: سهلة ومرنة، مثالية للبحث والتطوير السريع.
- **TensorFlow**: قوية ومدعومة من Google ، صعبة بعض الشيء لتعلمها، لكن لها دعم واسع للنشر.
- **Keras**: واجهة برمجة عالية المستوى تعمل فوق TensorFlow، سهلة جداً ومناسبة للمبتدئين والمشاريع الصغيرة.

حوار: إذاً Keras للمبتدئين، PyTorch للمرونة، TensorFlow للأداء والنشر. هل هذا تلخيص جيد؟

الدكتور علاء طعيمة (يبتسم): ممتاز. كراس الأسهل والأنسب للبدء، PyTorch مرنة وسهلة تصحيح الأخطاء، و TensorFlow قوية وغنية ولكنها ذات منحى تعلم أكثر حدة.

حوار (تجمع أغراضها): شكراً جزيلاً يا دكتور. الآن أصبحت لدي صورة شاملة: من البيانات وأنواعها، إلى طرق التعلم (بإشراف وبدون إشراف)، والتعلم المعزز، وتقنيات التقييم واختيار النموذج، وصولاً إلى الأدوات والمكتبات وأطر التعلم العميق. هذا سيجعلني أكثر استعداداً لدراسة التعلم العميق لاحقاً.

الدكتور علاء طعيمة (مرتاحاً): أنا سعيد بمساعدتك. إذا احتجت لأي توضيح إضافي، فمكتبي مفتوح دائماً.

حوار (واقفة): شكراً لك دكتور. سأراجع ما دَوّنته وأعود لك بأي استفسارات.

الدكتور علاء طعيمة (يودعها باهتمام): بالتوفيق يا حوراء. أراك قريباً.

الحوارية الثالثة: الشبكات العصبية امامية التغذية

(مكتب الدكتور علاء طعيمة في الجامعة. يجلس الدكتور خلف مكتبه المنظم، ويبيده بعض الأوراق البحثية حول الشبكات العصبية، بينما تدخل حوراء، الطالبة المجتهدة، وفي يدها دفتر ملاحظات).

حوراء (تطرق الباب بلطف): صباح الخير دكتور علاء طعيمة، هل يمكنني الدخول؟

الدكتور علاء طعيمة (يبتسم ويشير لها بالجلوس): صباح النور يا حوراء، تفضلي. ما الجديد اليوم؟

حوراء (تجلس وتقلب صفحات دفترها): دكتور، كنت أقرأ عن بُنية الشبكات العصبية الاصطناعية والبرسيبترون ومتعددي الطبقات، واستخدام دوال التنشيط، وفهمت أن هذه كلها مفاهيم أساسية للتعلم العميق. لكنني بحاجة إلى حوار يوضح لي هذه المفاهيم خطوة بخطوة. هل يمكنك مساعدتي؟

الدكتور علاء طعيمة (يشبك يديه): طبعًا. ابدئي بالسؤال من أي نقطة تجدينها غامضة.

حوراء (تنظر إلى ملاحظاتها): قرأت أن الشبكات العصبية الاصطناعية (ANN) تحاول محاكاة طريقة عمل الخلايا العصبية في الدماغ. كيف تُبنى هذه الشبكات؟

الدكتور علاء طعيمة: الشبكات العصبية الاصطناعية تتكون من طبقات: طبقة إدخال، طبقات مخفية، وطبقة إخراج. كل طبقة تحوي عصبونات اصطناعية. تأخذ طبقة الإدخال البيانات الخام، ثم تمررها للطبقات المخفية، كل طبقة مخفية تحول

المدخلات إلى شكل مفيد للطبقة التالية. الطبقة الأخيرة تنتج المخرج الذي نريده. هذه الهيكلية تحاول تقليد أسلوب معالجة الدماغ للمعلومات بشكل هرمي.

حوراء: وفهمت أيضًا أن البيرسيبترون (Perceptron) هو أبسط نموذج للخلايا العصبية الاصطناعية. كيف يعمل؟

الدكتور علاء طعيمة: البيرسيبترون يأخذ مجموعة من المدخلات العددية، يضرب كل مدخل في وزن معين، ثم يجمعها معًا ويضيف قيمة تحيَّز (bias). الناتج يمر بدالة تنشيط تُحوّل المجموع إلى ناتج نهائي. إذا كانت دالة التنشيط بسيطة مثل (step function)، سترجع صفر أو واحد. هذا يجعل البيرسيبترون مصنعًا خطيًا بسيطًا.

حوراء (بفضول): إذا كان البيرسيبترون يستطيع حل المشاكل الخطية، فماذا عن المشاكل غير القابلة للفصل خطيًا مثل XOR؟

الدكتور علاء طعيمة (يشير بيده): البيرسيبترون أحادي الطبقة يفشل في التعامل مع المشاكل غير الخطية مثل XOR. لحل هذه المشاكل نستخدم شبكات بيرسيبترون متعدد الطبقات (MLP) التي تحتوي على طبقات مخفية ودوال تنشيط غير خطية. هذا يسمح للشبكة بتعلم حدود قرار غير خطية، وبذلك يمكن التعامل مع مشاكل أكثر تعقيداً.

حوراء: إذن الطبقات المخفية ودوال التنشيط غير الخطية مثل ReLU ، Sigmoid، tanh هي التي تعطي الشبكة قوتها؟

الدكتور علاء طعيمة: بالضبط. دوال التنشيط غير الخطية مهمة جداً. بدونها، تكون الشبكة مجرد نمط خطي مهما زاد عمقها. Sigmoid تعطي مخرجات بين 0 و1، tanh بين -1 و1، أما ReLU فهي تُخرج المدخل كما هو إذا كان موجباً، وصفر إن كان سالباً. ولكل دالة مزايا وعيوب، خاصة فيما يتعلق بتلاشي الاشتقاق (Vanishing Gradient) ومشكلة الخلايا العصبية الميتة.

حوراء (تدون الملاحظات): قرأت عن مشاكل مثل تلاشي الانحدار والانحدار المتفجر. ماذا تعني هذه المصطلحات؟

الدكتور علاء طعيمة: عند حساب الانحدار الخلفي لتحديث الأوزان، قد تصبح التدرجات صغيرة جداً فتختفي تقريباً (Vanishing Gradient)، مما يوقف تعلم الطبقات المبكرة. أما لو كانت كبيرة جداً فقد تنفجر القيم (Exploding Gradients) وتمنع الاستقرار. اختيار دالة تنشيط مناسبة وتهيئة الأوزان بشكل جيد يساعد في تجنب هذه المشاكل.

حوراء: تهيئة الأوزان؟ كيف نفعل ذلك؟

الدكتور علاء طعيمة: تهيئة الأوزان بعناية مهمة كي لا تتلاشى الإشارات أو تنفجر عند الانتقال عبر الطبقات. مثلاً، تهيئة Xavier أو He (Variance scaling) تساعد في الحفاظ على ثبات التباين. هذه التهيئات المختارة بعناية تساعد الشبكة على التعلم بشكل أفضل.

حوراء: فهمت. ذكرت الانحدار الاشتقائي (Gradient Descent) كخوارزمية تحسين. كيف يتم التدريب بالضبط؟

الدكتور علاء طعيمة: التدريب يتضمن ما يلي:

1. الانتشار الأمامي (Forward propagation) : ندخل البيانات، تمر عبر الشبكة، وتحصل على ناتج.
2. نحسب دالة الخطأ (Loss Function) مثل MSE للانحدار أو Cross Entropy للتصنيف.
3. الانتشار الخلفي (Backpropagation) : نستخدم المشتقات ونرجع عبر الشبكة لحساب تدرجات الأوزان.
4. تحديث الأوزان باستخدام خوارزمية تحسين مثل الانحدار الاشتقاقي أو نسخة محسنة منه. (Adam, RMSprop, Adagrad ...)

حوار (بحماس) : ما الفرق بين هذه الخوارزميات المختلفة للانحدار الاشتقاقي؟

الدكتور علاء طعيمة:

- SGD : يستخدم عينة أو مجموعة صغيرة (Mini-Batch) لحساب التدرج في كل مرة.
- Momentum : يضيف ذاكرة للخطوات السابقة لتسريع التعلم.
- NAG (Nesterov) : يحسّن استخدام الزخم.
- Adam , RMSprop , Adagrad : تقوم هذه الخوارزميات بتكييف معدل التعلم لكل معامل Adam . من الأكثر استخدامًا، يجمع بين مزايا RMSprop و Momentum .

حوراء: زائع. وماذا عن مفهوم التعميم (Generalization) والضبط الزائد (Overfitting)؟

الدكتور علاء طعيمة: الهدف من النموذج هو التعميم على بيانات جديدة غير مرئية. إذا أدى النموذج جيداً على بيانات التدريب ولكنه فشل على بيانات الاختبار، فهذا يعني Overfitting . هنالك طرق لمنع ذلك مثل التوقف المبكر (Early Stopping)، الحذف العشوائي (Dropout) ، والتسوية الجماعية (Batch Normalization) .

حوراء (تكتب بحرص): إذن التوقف المبكر يراقب أداء النموذج على مجموعة التحقق، وحين يتدهور الأداء، يوقف التدريب. وال Dropout يزيل بعض الخلايا العصبية عشوائياً أثناء التدريب لتقليل اعتماد الشبكة على ميزات معينة ومنع حفظ البيانات. والتسوية الجماعية تعيد توزيع المدخلات لكل طبقة مما يسرع التدريب ويعزز الاستقرار.

الدكتور علاء طعيمة (بايماءة تأكيد): صحيح جداً.

حوراء: ماذا عن استخدام كيراس (Keras) ؟ قرأت أنك تستطيع بناء شبكة عصبية بسهولة شديدة.

الدكتور علاء طعيمة: مع Keras، تكتب أسطرًا بسيطة لبناء النموذج (model)، إضافة الطبقات (Dense layers)، وتحديد الخوارزمية (optimizer) ودالة الخطأ (loss). ثم تستدعي fit لتدريب النموذج. Keras تخيئ لنا التعقيدات، مما يسمح بالتركيز على التصميم.

حوراء: جربت مثال بسيط لتصنيف أسعار المنازل ونجح. رأيت كيف نتدرب على مجموعة تدريب ونستخدم مجموعة تحقق (Validation) ونقيس دقة النموذج. هل هذا نفس المفهوم لجميع المهام الأخرى؟

الدكتور علاء طعيمة: نعم، المبدأ واحد. نختار دالة خطأ مناسبة (MSE للانحدار و Cross Entropy للتصنيف)، نختار محسن مثل (Adam)، نهندس المعاملات الفائقة (مثل عدد الطبقات، عدد الخلايا العصبية، معدل التعلم)، نطبق تقنيات التنظيم كالحذف العشوائي لو احتجنا لتقليل overfitting .

حوراء (تبتسم): الآن الصورة أكثر وضوحاً. فهتمت الشبكات العصبية، البيرسيترون، المتعدد الطبقات، الانتشار الخلفي، دوال التنشيط، خوارزميات التحسين، ودوال الخطأ وكيفية التعامل مع overfitting . كما فهتمت دور Keras في تسهيل الأمور.

الدكتور علاء طعيمة (يعيد ترتيب أوراقه): ممتاز يا حوراء. هذه الأساسيات هي لبنة البناء للتعلم العميق. مع الوقت والتجارب ستتعين هذه المفاهيم أكثر.

حوراء (تنظر بسعادة): شكراً جزيلاً، دكتور. سأراجع هذه المفاهيم وأطبق بعض الأمثلة العملية.

الدكتور علاء طعيمة (بابتسامة تشجيعية): بالتوفيق يا حوراء. يمكنك العودة بأي وقت إذا احتجت المزيد من التوضيحات.

حوراء (تقف وتجمع ملاحظاتها): بالتأكيد سأفعل. شكراً لك مرة أخرى. إلى اللقاء دكتور.

الدكتور علاء طعيمة: مع السلامة. أتمنى لك دراسة ممتعة.

الحوارية الرابعة: الشبكات العصبية الالتفافية

(مكتب الدكتور علاء طعيمة في الجامعة. تجلس حوراء أمامه ويدها دفتر ملاحظات. قررت حوراء هذا اليوم مناقشة موضوع الشبكات العصبية الالتفافية (CNN) بالتفصيل مع الدكتور علاء طعيمة. الحوار طويل ومفصل، وسيشمل كامل النص التالي دون استثناء أي جزء)

حوراء (بلهفة): صباح الخير دكتور علاء طعيمة، أرغب اليوم في فهم الشبكات العصبية الالتفافية (CNN) بالتفصيل. سمعت أنها مهمة جدًا في معالجة الصور!

الدكتور علاء طعيمة (يبتسم بثقة): صباح النور يا حوراء. حسنًا، فلنبدأ من المقدمة. في هذا الفصل، نقدم مفاهيم الشبكات العصبية الالتفافية (Convolutional neural network)، أو اختصارًا CNN. تتضمن هذه المفاهيم المكونات الرئيسية للشبكة التي تشكل بنية الشبكة العصبية الالتفافية. تعمل الشبكات العصبية الالتفافية بشكل جيد للغاية بالنسبة للبيانات غير المهيكلة مثل الصور. بعد التعرف الكامل على بنية الشبكات العصبية الالتفافية، في نهاية الفصل سنقوم بتنفيذ مثال عملي باستخدام الشبكات العصبية الالتفافية في keras.

حوراء (تدوّن): ممتاز، ما هي الـ CNN بالضبط؟

الدكتور علاء طعيمة: الشبكات العصبية الالتفافية (CNN) هي فئة من الشبكات العصبية أمامية التغذية (Feedforward) تستخدم طبقات الالتفاف (Convolution) لتحليل المدخلات ذات الطبيعة التوبوغرافية كالصور ومقاطع الفيديو.

في الشبكات العصبية أمامية التغذية المتصلة بالكامل، يتم توصيل جميع العقد الخاصة بطبقة واحدة بجميع عقد الطبقة التالية، مما يؤدي لعدد هائل من الأوزان. تخيلي: إذا كان لدينا صورة 64×64 بكسل تدرج رمادي، حجم القناة 1، فعدد المدخلات 4096. إن كانت الطبقة التالية بها 500 عقدة، فسيوجد 2,048,000 وزن! هذا كبير جدًا. ومع الطبقات المخفية المتعددة تتعقد الأمور أكثر.

حوراء (مندهشة): عدد كبير جدًا من الأوزان سيصعب التعلم ويزيد خطر الضبط الزائد Overfitting !

الدكتور علاء طعيمة (مؤكدًا): صحيح. ولحل هذه المشكلات، طُرحت الشبكات العصبية الالتفافية CNN . الـ CNN هي شبكات تستخدم الالتفاف بدل الضرب بالمصفوفات في طبقة على الأقل.

ما يميز CNN هو هيكلها المستوحى من القشرة البصرية في الدماغ البشري. على عكس الشبكات الأمامية العادية، في CNN الطبقات لها ثلاثة أبعاد: عرض وارتفاع وعمق.

حوراء: كيف يتم تقسيم الأجزاء الرئيسية لـ CNN ؟

الدكتور علاء طعيمة: تنقسم بنية الـ CNN لجزأين رئيسيين:

1. استخراج الميزات: (Features Extraction) حيث تطبق عمليات الالتفاف (convolution) والتجميع (pooling) لاستخراج الخصائص المهمة من الصورة، كالخطوط والحواف والأنماط المحلية. الطبقات القريبة من الإدخال

تتعلم خصائص بسيطة كالحواف edges، والطبقات الأعمق تجمع الخصائص البسيطة لتشكيل سمات أكثر تعقيداً.

2. التصنيف (Classification) : بعد استخراج الميزات، تأتي طبقة متصلة بالكامل تعمل كمصنف، وتتوقع الفئة المناسبة للصورة بناءً على الخصائص المستخرجة.

(يشير إلى الشكل 4-1 في الكتاب) هذا الشكل يوضح فكرة عامة عن هيكل الـ CNN.

حوارة (تنظر باستيعاب): فهمت. ما الخصائص التي تميز CNN عن غيرها من الشبكات العصبية؟

الدكتور علاء طعيمة: هناك ثلاث خصائص مميزة:

1. المجالات المحلية الاستقبالية (local receptive fields) كل خلية عصبية في CNN تنظر إلى منطقة محلية من بيانات الإدخال. هذا يسمح بتعلم أنماط محلية كالحواف.

2. مشاركة المعاملات (parameters sharing) والارتباط المحلي (Local connectivity): تحتوي كل طبقة التلافافية على عدة فلاتر (kernels). يطبق كل فلتر على مناطق الإدخال، وينتج خريطة ميزات. الأوزان نفسها تُستخدم لكل مواقع الصورة، وهذا يقلل المعاملات ويزيد الكفاءة.

3. التجميع (Pooling) أو جمع العينات (sub-sampling) : بعد الالتفاف، نطبق تجميعاً لتقليل الأبعاد، وتقليل عدد المعاملات، والتخفيف من مشكلة الضبط الزائد.

لعبت CNN دورًا مهمًا في تاريخ التعلم العميق، وكانت بين أولى الشبكات العصبية القادرة على حل مشكلات عملية مهمة في مجال معالجة الصور.

حوراء: فهتت أهمية CNN . كيف يُعرّف عامل الالتفاف (Convolution) نفسه؟

الدكتور علاء طعيمة: الالتفاف ثنائي الأبعاد عملية بسيطة نسبيًا. لدينا كيرنل (فلتر) وهي مصفوفة أوزان صغيرة. نزلق بهذه الكيرنل فوق بيانات الإدخال ثنائية الأبعاد، ونضرب القيم ونجمّعها لنحصل على قيمة إخراج.

في المثال (شكل 4-2 في الكتاب)، إذا كانت خصائص الإدخال 5×5 والإخراج 3×3 ، يمكن للالتفاف إنجاز العمل بعدد معاملات أقل بكثير من الطبقات المتصلة بالكامل. الالتفاف يؤكد على حدود الأشكال ويستخرج الخصائص المهمة. الشبكة تتعلم الكيرنلات المناسبة أثناء التدريب.

حوراء (بحماس): رائع، الطبقة الالتفافية إذن هي الأساس؟

الدكتور علاء طعيمة (يومئ برأسه): نعم، طبقة الالتفاف هي أهم لبنة في CNN . تحتوي على مجموعة فلاتر تُطبق على صورة الإدخال لاستخراج الخصائص.

تشمل المعاملات الفائقة في طبقة الالتفاف:

- حجم الكيرنل (K).
- عدد الكيرنلات (filters) والذي يحدد عمق إخراج الطبقة.
- الخطوة (Stride) وهي عدد البيكسلات التي تتحرك بها الكيرنل.
- الحشو (Padding) للحفاظ على أبعاد المخرجات.

- التمدد (Dilation) لزيادة مجال الرؤية دون زيادة الحجم الفعلي للكيرنل.

يتم حساب حجم الإخراج اعتمادًا على W, K, S, d, P بالمعادلة:

$$W_o = \lfloor (W + 2P - K - (K-1)(d-1)) / S \rfloor + 1.$$

حوراء (تدوّن المعادلة): جميل. وما مزايا استخدام الالتفاف؟

الدكتور علاء طعيمة: ثلاث مزايا مهمة:

1. **Sparse interactions**: تفاعلات متفرقة، لأن كل ناتج يعتمد على مجموعة جزئية من المدخلات.
2. **Parameter sharing**: مشاركة المعاملات، نفس الفلتر يستخدم لجميع المواقع.
3. **Equivariance**: إذا أُزِحت المدخلات، يُزاح الإخراج بنفس الطريقة. هذه الخاصية مهمة لمعالجة الصور.

حوراء: وكيف نضيف طبقة التفاف في keras؟

الدكتور علاء طعيمة: نستخدم:

```
from keras.layers import Conv2D
Conv2D(filters, kernel_size, strides, padding,
activation='relu', input_shape)
```

- filters: عدد الفلاتر
- kernel_size: حجم الكيرنل

- strides: الخطوة
- padding: "valid" أو "same"
- activation: غالبًا relu
- input_shape: عند استخدام الطبقة الأولى فقط.

حوراء: ماذا عن طبقة التجميع (Pooling) ؟

الدكتور علاء طعيمة: التجميع يقلل الأبعاد. يستخدم غالبًا max pooling أو

average pooling. الأكثر شيوعًا هو max pooling بحجم خلية 2×2 .

طبقات التجميع لا تضيف معاملات جديدة، فقط تُلخص القيم.

حوراء: فهمت المفاهيم النظرية. هل يمكننا مثال عملي؟

الدكتور علاء طعيمة: نعم. سنتعامل مع مجموعة بيانات CIFAR-10.

CIFAR-10:

- صور $32 \times 32 \times 3$
- 10 فئات: طائرة، سيارة، عصفور، قطة، غزال، كلب، ضفدع، حصان، سفينة، شاحنة
- 50000 للتدريب و10000 للاختبار.

نستورد البيانات:

```
from keras.datasets import cifar10
(x_train, y_train), (x_test, y_test) = cifar10.load_data()
```



```
x_train shape: (50000, 32, 32, 3)
y_train shape: (50000, 1)
```

كل صورة لها تسمية واحدة. مثلا $y_train[0] = [6]$ تعني "ضفدع".

حوراء (تقلب صفحات ملاحظاتها): والرموز للأصناف؟

الدكتور علاء طعيمة: نعم.

0 : طائرة.

1 : سيارة.

2 : عصفور.

3 : قطة.

4 : غزال.

5 : كلب.

6 : ضفدع.

7 : حصان.

8 : سفينة.

9 : شاحنة.

نحتاج تحويل y إلى one-hot :

```
from keras.utils import np_utils
y_train_one_hot = np_utils.to_categorical(y_train,10)
y_test_one_hot = np_utils.to_categorical(y_test,10)
```

الآن $y_train_one_hot[1] = [0000000001]$ تعني شاحنة.

حوراء: وماذا عن المعالجة المسبقة للصور؟

الدكتور علاء طعيمة: نقسم كل بيكسل على 255 لنجعل القيم بين 0 و1:

```
x_train = x_train.astype('float32')/255
x_test = x_test.astype('float32')/255
```

حوراء: جيد. ما المعمارية المقترحة للـ CNN؟

الدكتور علاء طعيمة: المعمارية:

- Conv Layer (32 Filter size 3×3)
- Conv Layer (32 Filter size 3×3)
- Max Pool (2×2)
- Dropout(0.25)
- Conv Layer (64 Filter size 3×3)
- Conv Layer (64 Filter size 3×3)
- Max Pool (2×2)
- Dropout(0.25)
- Flatten
- Dense(512 relu)
- Dropout(0.5)
- Dense(10 softmax)

حوراء (مبتسمة): تبدو معمارية كبيرة لكن يمكن تنفيذها بسهولة بـ keras ، أليس

كذلك؟

الدكتور علاء طعيمة: بالضبط.

```
from keras.models import Sequential
from keras.layers import Dense, Dropout, Flatten, Conv2D,
MaxPooling2D

model = Sequential()
model.add(Conv2D(32, (3, 3), activation='relu', padding='same', i
nput_shape=(32, 32, 3)))
model.add(Conv2D(32, (3, 3), activation='relu', padding='same'))
model.add(MaxPooling2D(pool_size=(2, 2)))
model.add(Dropout(0.25))

model.add(Conv2D(64, (3, 3), activation='relu', padding='same'))
model.add(Conv2D(64, (3, 3), activation='relu', padding='same'))
model.add(MaxPooling2D(pool_size=(2, 2)))
model.add(Dropout(0.25))

model.add(Flatten())
model.add(Dense(512, activation='relu'))
model.add(Dropout(0.5))
model.add(Dense(10, activation='softmax'))
```

ثم `model.summary()` يعطينا ملخص المعمارية.

حوراء: كيف نختار دالة الخطأ والمحسن؟

الدكتور علاء طعيمة : نستخدم 'categorical_crossentropy' وفوقها adam

كمحسن:

```
model.compile(loss='categorical_crossentropy',
optimizer='adam', metrics=['accuracy'])
```

ثم ندرّب النموذج:

```
hist = model.fit(x_train, y_train_one_hot, batch_size=32,
epochs=20, validation_split=0.2)
```

حوراء: سيعرض الناتج قيم الخسارة والدقة لكل مرحلة.

الدكتور علاء طعيمة: نعم. بعد التدريب، يمكننا رسم الخطأ والدقة:

```
plt.plot(hist.history['loss'])
plt.plot(hist.history['val_loss'])
...
```

سنلاحظ حدوث overfitting بإمكانك التلاعب بالمعاملات لتحقيق نتائج أفضل.

ثم نقيم على مجموعة الاختبار:

```
model.evaluate(x_test, y_test_one_hot)[1]
```

يعطي تقريبًا 0.69 دقة، أي أفضل من التخمين العشوائي.

يمكننا حفظ النموذج:

```
model.save('my_cifar10_model.h5')
```

ولتحميله لاحقًا:

```
from keras.models import load_model
model = load_model('my_cifar10_model.h5')
```

حواء: ممتاز! هل يمكننا تجربة صورة خارجية؟

الدكتور علاء طعيمة: نعم، نفترض لدينا صورة "cat.jpg" نقرأها ونغيّر حجمها

3×32×32:

```
my_image = plt.imread("cat.jpg")
from skimage.transform import resize
my_image_resized = resize(my_image, (32, 32, 3))
```

ثم:

```
probabilities = model.predict(np.array([my_image_resized,]))
```

يعطينا احتمالات كل فئة.

نعرف الفئات:

```
number_to_class = ['airplane',
'automobile', 'bird', 'cat', 'deer', 'dog', 'frog', 'horse', 'ship',
'truck']
```

نجد أعلى احتمالات ونرى الفئة الأقرب.

النموذج تعرف على أنها قطعة، وإن لم يكن بدقة عالية.

حوراء (تتهجد بإعجاب): رائع، إذاً تعلمت كيف يعمل الـ CNN ، وكيف نطبقه عملياً، وكيف نقوم بالتصنيف حتى مع صور خارجية، وكيف نحفظ النموذج.

الدكتور علاء طعيمة (يبتسم): بالضبط. قد لا يكون هذا النموذج الأفضل، لكنه يوضح المبادئ الأساسية. يمكنك الآن تعديل المعمارية، زيادة الطبقات، تغيير معدل التعلم، استخدام تقنيات تنظيم إضافية للحصول على نتائج أفضل. هذا هو أساس الشبكات العصبية الالتفافية وتصنيف الصور.

حوراء (بامتنان): شكراً جزيلاً يا دكتور، لقد استوعبت النص كاملاً دون استثناء، والآن لدي فهم أعمق لشبكات CNN!

الدكتور علاء طعيمة (مسرور): على الرحب والسعة يا حوراء، أتمنى لك التوفيق في مشاريعك المقبلة.

الحوارية الخامسة: الشبكات العصبية المتكررة

(مكتب الدكتور علاء طعيمة في الجامعة، حيث تجلس حوراء، الطالبة المهتمة بمجال تعلم الآلة، ويدها دفتر ملاحظات. الحوار سيكون طويلاً ومفصلاً ليشمل جميع ما ورد في النص).

حوراء (بحماس): صباح الخير دكتور علاء طعيمة. في الفصول السابقة تعلمت عن الشبكات العصبية الأمامية والتلافيفية، لكنني قرأت عن شيء جديد يُدعى "الشبكات العصبية المتكررة (RNN)". هل يمكنك أن تشرح لي ما هي RNN؟

الدكتور علاء طعيمة (يبتسم ويرتب أوراقه): صباح النور يا حوراء. بالطبع. في الفصول السابقة، تذكرين أننا ناقشنا شبكات تستقبل مدخلات بحجم ثابت وتنتج مخرجات بحجم ثابت. الآن، الشبكات العصبية المتكررة (Recurrent Neural Networks - RNN) مصممة للتعامل مع التسلسلات متغيرة الطول. تمتلك RNN حلقة تغذية راجعة تمكنها من حفظ حالة سابقة واستخدامها عند معالجة المدخلات اللاحقة. هذه القدرة تجعلها مفيدة في مهام مثل نمذجة اللغة والتعرف على الكلام. نظرياً، RNN يمكنها أن تكون Turing-Complete، أي يمكنها نمذجة أي برنامج معقد.

حوراء (تدوّن الملاحظات): فهمت. إذن الفكرة الأساسية أن RNN لها نوع من "الذاكرة" للمعلومات السابقة، صحيح؟

الدكتور علاء طعيمة: بالضبط. في الشبكات العصبية الأمامية (feedforward) التقليدية، بعد التدريب تصبح الأوزان ثابتة ويعتمد الإخراج على عينة الإدخال فقط. لكن في بعض المشاكل، تحتاج النموذج لأن يأخذ في الاعتبار تاريخ (ماضي) المدخلات،

مثل السلاسل الزمنية. هنا تأتي RNN ، فهي تمد الخلايا العصبية بذاكرة محدودة عبر الوقت بفضل اتصال راجعي.

حوراء: هل هذا يعني أن RNN تنظر إلى الوراء في الزمن؟

الدكتور علاء طعيمة: نعم، بالضبط RNN. لديها بنية سلسلة، حيث يتم تمثيل الحالة في الزمن $h_t = f(h_{(t-1)}, x_t)$. هذا يعني أن ناتج الحالة الحالية يعتمد على الحالة السابقة والمدخل الحالي، وليس المدخل الحالي فقط. على عكس الشبكات التقليدية التي تأخذ مدخلاً الآن لتنتج مخرجاً الآن، RNN تأخذ سلسلة مدخلات بمرور الزمن، وكل خطوة زمنية تساهم في مخرجات الخطوات اللاحقة.

حوراء (باستيعاب): هذا رائع. كيف يتم حساب المخرجات رياضياً؟

الدكتور علاء طعيمة: تملك RNN ثلاث مجموعات أوزان: U و W و V . المعادلات:

$$h_t = f(h_{(t-1)}W + x_tU)$$

$$y_t = h_t * V$$

حيث f دالة تنشيط غير خطية. h_t تمثل الحالة المخفية في الزمن t ، وتستند إلى الحالة السابقة $h_{(t-1)}$ والمدخل x_t . هذا يخلق ذاكرة، فالحالة h_t تحتوي على معلومات من الزمن السابق.

حوراء: ما هي أنواع المعماريات الممكنة لـ RNN؟

الدكتور علاء طعيمة: هناك عدة أشكال:

- واحد لواحد (One to One) : مثل الشبكات التقليدية. مثال: تصنيف الصور.
- واحد إلى متعدد (One to Many) : مدخل واحد وإخراج متسلسل. مثال: وصف الصور بصورة نصية.
- متعدد إلى واحد (Many to One) : عدة مدخلات متسلسلة وإخراج وحيد. مثال: تحليل المشاعر (الجملة كمدخل وخروج صنف المشاعر).
- متعدد إلى متعدد (Many to Many) : مثال الترجمة الآلية، يأخذ تسلسل بلغة ويخرج تسلسل بلغة أخرى.

حوراء (مندهشة): يا لها من مرونة. وماذا عن تطبيقات عملية مثل توليد النص؟

الدكتور علاء طعيمة: يستخدم RNN في نماذج اللغة والتوليد النصي. يمكنك إعطاء نص مثل "الحرب والسلام" لتولستوي، وتحصل على نص جديد مشابه للأسلوب. قمنا بمثال عملي بتحميل نص "warpeace_input.txt" ومعالجته. بإمكانك تدريب RNN على سلسلة الأحرف وتحويلها إلى توزيع احتمالي للأحرف التالية، ما يسمح بتوليد نص جديد.

حوراء (تكتب بسرعة): كيف نجهز البيانات لهذا النموذج؟

الدكتور علاء طعيمة: نفترض طول تسلسل ثابت، مثل 100 حرف. إذا كان النص طويلاً جداً، نقسمه لمتتاليات طولها 100 حرف لكل عينة تدريب. مدخلات تدريبية X ومخرجات Y هي نفس النص لكن مزاح shifted بحرف واحد. ثم نستخدم ترميز one-

hot للحروف. يمكننا بذلك إدخال المتتاليات للنموذج ليتعلم الأنماط. استخدمنا قاموس chars لحروف النص وعددها 57. ثم حولنا كل تسلسل إدخال وإخراج إلى مصفوفة One-Hot ذات أبعاد (n_vocab, seq_length, n_seq).

حوراء: وبعد ذلك؟

الدكتور علاء طعيمة: بنينا نموذج RNN بسيط باستخدام SimpleRNN في Keras مع `return_sequences=True` و `TimeDistributed(Dense(n_vocab))` و `optimizer=RMSprop`. عند التدريب و `Activation(softmax)`. استخدمنا `optimizer=RMSprop`. عند التدريب لفترات طويلة (~300 حقبة)، النموذج يحسن من جودة النص. لكن RNN بسيط قد يواجه مشكلة تلاشي التدرج (Vanishing gradient) مما يقلل قدرته على تعلم التبعيات الطويلة.

حوراء (بفضول): تلاشي التدرج! سمعت أن LSTM يعالج هذه المشكلة؟

الدكتور علاء طعيمة: صحيح، LSTM (Long Short Term Memory) هو نوع من RNN صمم للتعامل مع التبعيات طويلة المدى. يحوي LSTM بوابات: بوابة النسيان f، بوابة الإدخال i، بوابة الإخراج o، وخلايا حالة c_t. هذه البوابات تنظم تدفق المعلومات، مما يقلل من مشكلة تلاشي التدرج.

حوراء: كيف تعمل LSTM رياضياً؟

الدكتور علاء طعيمة: المعادلات:

$$f_t = \sigma(W_f h_{(t-1)} + U_f x_t + b_f)$$

$$i_t = \sigma(W_i h_{(t-1)} + U_i x_t + b_i)$$

$$a_t = \tanh(W_c h_{(t-1)} + U_c x_t + b_c)$$

$$o_t = \sigma(W_o h_{(t-1)} + U_o x_t + b_o)$$

$$c_t = f_t * c_{(t-1)} + i_t * a_t$$

$$h_t = o_t * \tanh(c_t)$$

بوابة النسيان f_t تتحكم بما نحتفظ به من الذاكرة. بوابة الإدخال i_t تضيف معلومات جديدة، وبوابة الإخراج o_t تتحكم فيما نخرجه. بهذه الطريقة يمكن LSTM حفظ المعلومات لفترات أطول.

حوراء (معجبة): رائع. وكيف كانت نتيجة توليد النص مع LSTM مقارنة بـ RNN العادي؟

الدكتور علاء طعيمة: استخدمنا LSTM مع 2 طبقة كل منها 800 وحدة، وتسلسل أطول (160 حرف). النتائج كانت أفضل، النص الناتج أكثر واقعية واتساقاً. هذا يظهر قوة LSTM في التعامل مع تبعيات طويلة المدى.

حوراء: ممتاز. ماذا عن تصنيف النص متعدد العلامات باستخدام RNN أو LSTM؟

الدكتور علاء طعيمة: أعطينا مثلاً على مجموعة بيانات التعليقات السامة من Kaggle 6 علامات toxic :

(evere_toxic, obscene, threat, insult, identity_hate).

استخدمنا طريقة إخراج متعددة العلامات: طبقة Dense مع 6 وحدات تنشيط sigmoid.

الإجراء:

1. تنظيف النص preprocessing .
2. تحويل النصوص إلى تسلسل أعداد صحيحة (Tokenize) .
3. استخدام embeddings مثل GloVe لتحويل الكلمات إلى متجهات.
4. بناء نموذج LSTM بنواتج متعددة.
5. حققنا دقة عالية (~99%) .

حوار (مندهشة): ممتاز جداً. وما عن تحليل المشاعر؟

الدكتور علاء طعيمة: استخدمنا مجموعة بيانات IMDB المضمنة في Keras . تحتوي على مراجعات أفلام مصنفة إيجابي/سلي. استخدمنا Embedding + LSTM + Dense(1, sigmoid). تمكن النموذج من تحقيق دقة ~86%. هذا مثال آخر على قوة LSTM في فهم السياق النصي.

حوار: سمعت عن المفردات و Embedding. كيف يعمل Embedding ؟

الدكتور علاء طعيمة: Embedding يحول الكلمات إلى متجهات عددية صغيرة، بحيث تصبح الكلمات ذات المعنى المتشابه قريبة في الفضاء المتجهي. يمكن تدريب Embedding مع النموذج أو استخدام Embeddings مدربة مسبقاً مثل GloVe . هذه خطوة مهمة لتحويل النص الخام إلى شكل يفهمه النموذج.

حوراء (تبتسم): فهمت كل شيء. RNN للتسلسلات، LSTM لحل مشكلة التلاشي، استخدامها في توليد النص، تصنيف متعدد العلامات، وتحليل المشاعر. وأيضاً تعلمت الفرق بين RNN و LSTM و Embedding .

الدكتور علاء طعيمة: أحسنت يا حوراء. تذكري أن RNN له أنواع مختلفة من المعماريات (واحد-لواحد، واحد-لمتعدد، ...). وأن LSTM يحل مشكلة التلاشي، ويمكنه تذكر المعلومات لفترة أطول. وبتطبيقات متنوعة: توليد نص، تصنيف نص، تحليل المشاعر.

أيضاً، يمكن تحسين النتائج عبر تجربة معاملات فائقة مختلفة، أو استخدام GRU أو نماذج أكبر، أو تطبيق تقنيات تنظيم لمنع overfitting .

حوراء (تحبي الدكتور): شكراً جزيلاً دكتور. لقد تناولنا كل ما ورد في النص بالتفصيل، والآن لدي صورة شاملة عن RNN و LSTM واستخداماتهما.

الدكتور علاء طعيمة (بسعادة): على الرحب والسعة يا حوراء. أتمنى لك التوفيق في أبحاثك ودراساتك المقبلة.

الحوارية السادسة: شبكات الخصومة التوليدية

(مكتب الدكتور علاء طعيمة في الجامعة، تجلس حوراء أمامه ويدها دفتر ملاحظات. ترغب حوراء هذا اليوم في فهم النماذج المولدة (generative models) وشبكات الخصومة التوليدية (GAN) بعناية. سيشمل الحوار كافة التفاصيل الواردة في النص).

حوراء (بحماس): صباح الخير دكتور علاء طعيمة، قرأت مؤخراً عن النماذج المولدة والشبكات الخصومة التوليدية (GAN)، لكنني أريد شرحاً وافياً لكل ما قرأته. يمكننا بدء النقاش من البداية؟

الدكتور علاء طعيمة (يبتسم): صباح النور يا حوراء. بالتأكيد. في هذا الفصل من الكتاب سنتحدث عن نماذج مولدة تعتمد على مفاهيم من نظرية اللعبة. هذه النماذج تتضمن مكونين: أحدهما "مولد" ينتج بيانات مزيفة، والآخر "مميز" يميز بين البيانات الحقيقية والمزيفة. طريقة التدريب هنا معادية (خصومة)، المولد يحاول إنتاج بيانات أقرب للحقيقة، والمميز يحاول كشف التزييف، وبهذا التنافس يصلان لأداء رائع.

حوراء: فهمت. ولكن ما هو النموذج المولد بالضبط، وكيف يختلف عن النموذج المميز؟

الدكتور علاء طعيمة: هناك نوعان رئيسيان من النماذج في التعلم الآلي:

- النموذج المميز (Discriminative): يهتم بتصنيف البيانات إلى فئات. كأن يقول لك ما إذا كانت الصورة قطة أو كلب.

- النموذج المولد (Generative) : لا يحاول التصنيف، بل يحاول نمذجة التوزيع الاحتمالي للبيانات وإنشاء عينات جديدة من هذا التوزيع.

ببساطة، النموذج المولد يركز على تعلم التوزيع الذي جاءت منه البيانات، بحيث يمكنه توليد بيانات جديدة شبيهة بتلك الموجودة في مجموعة التدريب. بينما النموذج المميز يركز على إيجاد حدود أو قواعد تفصل بين الفئات المختلفة.

حوراء (تدوّن): إذن النموذج المولد يحاول تقدير كثافة الاحتمال للبيانات ويتعلم توزيعها. هذا يعني أنه يمكنه إنتاج عينات جديدة غير موجودة في مجموعة التدريب، ولكنها مشابهة لها، أليس كذلك؟

الدكتور علاء طعيمة: صحيح تماماً. الهدف الأساسي للمولد هو تقدير توزيع البيانات الحقيقية عن طريق نموذج تقريبي. وبعدها، يمكنه توليد عينات جديدة تشبه البيانات الأصلية. هذا يساعد في فهم البيانات غير المصنفة واكتشاف أنماط فيها.

حوراء: سمعت أن للنماذج المولدة أهمية مستقبلية في الذكاء الاصطناعي. لماذا؟

الدكتور علاء طعيمة: هناك ثلاثة أسباب رئيسية:

1. من الناحية النظرية، القدرة على توليد البيانات تعني فهم أعمق لكيفية إنشاء البيانات، وليس مجرد تصنيفها.
2. النمذجة التوليدية قد تكون مهمة جداً في مجالات أخرى مثل التعلم المعزز. على سبيل المثال، يمكن لوكيل تعلم البيئة التخيلية التي يولدها نموذج مولد بدلاً من الاعتماد على محاكاة حاسوبية معقدة.

3. إذا أردنا ذكاء اصطناعي أقرب للذكاء البشري، فالنمذجة التوليدية جزء أساسي. نحن البشر قادرون على تخيل والتنبؤ بالمستقبل وابتكار سيناريوهات مختلفة في أذهاننا. هذا بالضبط ما يفعله النموذج المولد الممتاز.

حوراء (بإعجاب): الآن نصل إلى شبكات الخصومة التوليدية (GAN). ما هي GAN؟

الدكتور علاء طعيمة: شبكات الخصومة التوليدية (Generative Adversarial Networks) تتكون من نموذجين يتدربان معاً:

- مولد (Generator): يحاول إنتاج بيانات مزيفة تشبه الحقيقية.
- مميز (Discriminator): يحاول التمييز بين البيانات الحقيقية والمزيفة.

إنها لعبة خصومية: المولد يسعى لخداع المميز بإنتاج عينات واقعية، والمميز يسعى لكشف التزييف. بهذه العملية، كلاهما يتحسن مع الوقت.

حوراء: فهمت. إذاً "التوليد" يشير لإنتاج بيانات جديدة، و"الخصومة" تشير للتنافس بين المولد والمميز. ولماذا نستخدم الشبكات العصبية هنا؟

الدكتور علاء طعيمة: الشبكات العصبية تُستخدم عادةً لتمثيل المولد والمميز، نظرًا لقدرتها على نمذجة العلاقات المعقدة. بإمكاننا استخدام شبكات بسيطة أو ملتفة أو حتى معقدة. الهدف الرئيسي هو أن يتعلم المولد إنتاج بيانات لا يمكن للمميز تمييزها عن الحقيقية، بينما يصبح المميز أكثر دقة في كشف المزيفة.

حوراء: ما الرياضيات خلف GAN؟

الدكتور علاء طعيمة: الرياضيات معقدة نوعاً ما، لكن فكرة بسيطة: المولد يأخذ متجه عشوائي z (ضجيج)، ومنه ينتج عينة x . المميز $D(x)$ يعطي احتمال أن x حقيقية. المولد $G(z)$ يحاول جعل $D(G(z))$ كبيراً (أي يعتبرها حقيقية). المميز يحاول جعل $D(x)$ كبيراً للعينات الحقيقية، و $D(G(z))$ صغيراً للعينات المزيفة. إنها لعبة minimax المولد يريد تصغير خسارته وزيادة خطأ المميز، والمميز يريد تقليل خطئه.

حوراء: رائع. هل هناك مثال واقعي لفهم GAN بشكل أفضل؟

الدكتور علاء طعيمة: نعم. تخيلي مزوراً (المولد) يحاول رسم لوحات شبيهة بدافنشي، وخبير فني (المميز) يحاول كشف التزوير. كلما تحسّن المزور في إنتاج لوحات واقعية، احتاج الخبير لمهارة أعلى لكشفها. وكلما زادت مهارة الخبير، اضطر المزور لبذل جهد أكبر. مع الوقت، يحصل المزور على مهارة كبيرة في إنتاج لوحات يصعب كشفها.

حوراء: كيف يتم التدريب؟

الدكتور علاء طعيمة: التدريب خصومي:

- المميز يدرب أولاً على التمييز بين بيانات حقيقية ($label=1$) وبيانات مزيفة من المولد ($label=0$).
- المولد يدرب بجعل المميز يخطئ. أي عندما يمرر المولد بياناته للمميز ويحصل على تنبؤ خاطئ، يتعلم المولد ويعدل أوزانه.

كلاهما يحدث بالتناوب: نحدث أوزان المميز، ثم نجمد المميز، ونحدث أوزان المولد، وهكذا حتى يصلان لتوازن.

حوراء: ماذا عن استخدام GAN لتوليد الصور مثل MNIST ؟

الدكتور علاء طعيمة: مثلاً، استخدمنا MNIST (صور أرقام مكتوبة بخط اليد). دربنا مولداً بسيطاً ومميزاً بسيطاً. المولد يأخذ ضوضاء عشوائية ويحاول إنتاج صورة رقم، والمميز يحاول التفريق بين هذه الصورة وبين صورة MNIST حقيقية. بمرور العصور التدريبية، تتحسن جودة الأرقام المنتجة. في البداية، تكون ضبابية وعشوائية، ومع الوقت تصبح شبيهة بأرقام MNIST الحقيقية.

حوراء (منهرة): جميل! وهل هناك تحديات في تدريب GAN؟

الدكتور علاء طعيمة: نعم. تدريب GAN صعب:

- هناك العديد من المعلمات: بنية المولد والمميز ومعدلات التعلم وغيرها.
- الوضع قد يكون غير مستقر، وقد يحدث "انهيار الأنماط (mode collapse)"، حيث ينتج المولد مجموعة محدودة جداً من الأنماط بدلاً من التنوع.
- قد يهيمن المميز أو المولد، ما يعطل العملية.

اقتراحات لمواجهة هذه التحديات تشمل تقنيات مثل تسوية الدفعات (batch normalization)، واستخدام بيانات معنونة (labelled)، وما إلى ذلك.

حوراء: هل إضافة تصنيفات للبيانات يساعد على تجنب المشكلات؟

الدكتور علاء طعيمة: نعم، إضافة تسميات تسمى أحياناً "Conditional GAN" تمنح المولد والمميز المزيد من المعلومات، ويساعد ذلك في توجيه المولد لإنتاج بيانات من فئات محددة، وتحسين الجودة.

حوراء (تبتسم): إذن الخلاصة:

1. النموذج المولد يحاول تعلم توزيع البيانات لإنشاء عينات مشابهة.
2. GAN إطار عمل يحتوي مولد ومميز يتدربان معاً.
3. المولد يحاول خداع المميز بإنتاج بيانات مزيفة شبيهة بالحقيقية.
4. المميز يحاول التمييز بين الحقيقي والمزيف.
5. النتيجة لعبة minimax، وبعد تدريبات عديدة يصبح المولد بارعاً في التوليد.
6. GAN مهمة جداً للمستقبل، وصعبة في التدريب لكنها قوية في إنشاء بيانات جديدة.

الدكتور علاء طعيمة (مسرور): ممتاز يا حوراء. لقد لخصت النقاط الأساسية بدقة. إن النماذج المولدة وخاصة GAN قدمت ثورة في مجال التعلم غير الخاضع للإشراف وإنتاج البيانات الاصطناعية المشابهة للواقعية.

حوراء (تجمع ملاحظاتها): شكراً جزيلاً، دكتور علاء طعيمة. الآن أصبحت لدي صورة واضحة عن النماذج المولدة وال GAN وكيفية عملها وتحدياتها.

الدكتور علاء طعيمة (بابتسامة): على الراح والسعة، يا حوراء. أتمنى لك التوفيق في أبحاثك ودراساتك.