


حوار حول تعلم الآلة

موضوعات تعلم الآلة بأسلوب حوارى بين استاذ وطالبته

اعداد: د.علاء طعيمة



MACHINE LEARNING



بِسْمِ تَعَالَى

حوار حول تعلم الآلة

موضوعات تعلم الآلة بأسلوب حوار بين استاذ وطالبته

اعداد:

د. علاء طعيمة

مقدمة المؤلف

في هذا الكتيب، نتجول في عالم تعلم الآلة Machine Learning، ذلك المجال الحيوي الذي يشكل عصب الذكاء الاصطناعي. من خلال حواراتٍ شيقة ومبسطة، سنستعرض أهم الأسس المفاهيمية لتعلم الآلة، بدءاً من تعريفه الأساسي، مروراً بمبادئه وتقنياته، وصولاً إلى تطبيقاته العملية التي تلامس حياتنا اليومية. سواء كنت مبتدئاً في هذا المجال أو لديك معرفة مسبقة وتبحث عن تطوير مهاراتك، فإن هذا الكتيب سيوفر لك المعلومات الأساسية لفهم هذا العالم المثير والواعد.

لقد ولدت فكرة هذا الحوار من طالبتي حواء، التي أبدت حماساً وفضولاً كبيراً لمعرفة تفاصيل هذا المجال المعقد، فاقترحت أن نعرض المعرفة من خلال نقاشات بين استاذ وطالبته حول كتاب "تعلم الآلة وعلم البيانات: الأساسيات والمفاهيم والخوارزميات والأدوات" للاستاذ ميلاد وزان، بأسلوب تسهل متابعته على القراء. أمل أن يجد القارئ في هذه الصفحات مقدّمة مفيدة تُعينه على فهم تعلم الآلة، وتفتح أمامه آفاقاً جديدة للإبداع والاكتشاف.

في طيّات هذه الصفحات، سنحاولُ الإجابة عن أسئلة كثيرة، وسنفتح مساحات للنقاش والتأمل في عالمٍ لا يزال يموّز بالابتكار والتطور، آمليْن أن يكون هذا الكتيب خطوة أولى لكل متعطّش لمعرفة آفاق تعلم الآلة 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 تردد بمراسلتنا عبر بريدنا الإلكتروني alaa.taima@qu.edu.iq.

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

العربي الذي يفتقر أشد الافتقار إلى محتوى جيد وورصين في مجال تعلم الآلة 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: ماهو تعلم الآلة (1)
11	الحوارية الثانية: ماهو تعلم الآلة (2)
15	الحوارية الثالثة: ماهو تعلم الآلة (3)
18	الحوارية الرابعة: ماهو تعلم الآلة (4)
22	الحوارية الخامسة: ماهو تعلم الآلة (5)
26	الحوارية السادسة: ماهو تعلم الآلة (6)
31	الحوارية السابعة: ماهو تعلم الآلة (7)
35	الحوارية الثامنة: ماهو تعلم الآلة (8)
39	الحوارية التاسعة: ماهو تعلم الآلة (9)
43	الحوارية العاشرة: كيف يعمل تعلم الآلة (1)
48	الحوارية الحادية عشر: كيف يعمل تعلم الآلة (2)
51	الحوارية الثانية عشر: تطبيقات تعلم الآلة
56	الحوارية الثالثة عشر: علاقة تعلم الآلة بالتخصصات الاخرى
60	الحوارية الرابعة عشر: أدوات وبيئة العمل لتعلم الآلة (1)
65	الحوارية الخامسة عشر: أدوات وبيئة العمل لتعلم الآلة (2)
69	الحوارية السادسة عشر: قيود تعلم الآلة (1)
73	الحوارية السابعة عشر: قيود تعلم الآلة (2)
77	الحوارية الثامنة عشر: مناهج تعلم الآلة

الحوارية الاولى: ما هو تعلم الآلة (1)

(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).

الدكتور علاء طعيمة (وهو ينظر من النافذة وقد بدا عليه التأمل): مرحباً حوراء، كيف حالك اليوم؟ هل أنت جاهزة لنقاشنا حول تعلم الآلة؟

حوراء (بابتسامة وتحمس): أهلاً دكتور علاء، أنا بخير والحمد لله. قرأت نصّاً عن تعلم الآلة وأود أن أناقشه معك لأفهمه بشكل أفضل. كان النص يتحدث عن كيف نتعلم نحن البشر من التجربة، فتساءلت كيف يمكن للحواسيب أن تتعلم أيضاً؟

الدكتور علاء (يستدير باتجاهها مشيراً إلى لوح خلفه): سؤال ممتاز. دعيني أوضح بدايةً مفهوم تعلم الآلة Machine Learning. تعلمنا نحن البشر أن نستنتج أشياء من خلال خبراتنا: بعد المطر أو الشعور بالنسيم اللطيف أو رؤية غروب الشمس المتوهج؛ غالباً ما نتنبأ أن الطقس سيكون جيداً في اليوم التالي. وبالمثل، عندما نبذل جهداً كبيراً في الدراسة نتوقع أن نحصل على درجات جيدة. هذا كله قائم على خبرات سابقة.

حوراء (تومئ برأسها موافقة): صحيح، وكنت أفكر أيضاً: بما أننا نتعلم من خبراتنا، فهل من الممكن للحاسوب أن يقوم بالشيء ذاته؟

الدكتور علاء (بحماس): بالضبط، وهذا هو جوهر تعلم الآلة. تعلم الآلة هو طريقة تُستخدَم لتحسين أداء الأنظمة الحاسوبية بواسطة التعلم التجريبي باستخدام أساليب حسابية. آرثر صموئيل، أحد رواد ألعاب الكمبيوتر والذكاء الاصطناعي، هو من صاغ مصطلح "تعلم الآلة" في عام 1959. وقد وصفه بأنه قدرة الحاسوب على التعلم دون أن تتم برمجته بشكل صريح ومباشر.

حوراء (بدهشة): إذن الذكاء الاصطناعي لديه فرع خاص يهتم بتمكين الحواسيب من التعلم من التجربة. هل يمكنك أن تعطيني تعريفاً عاماً للتعلم الآلي كما ورد في النص؟

الدكتور علاء (يلتقط ورقة ويقرأ منها باهتمام): التعريف الشائع هو: "يركز تعلم الآلة على تصميم النماذج التي تتعلم تلقائياً في منطقةٍ ما بالاعتماد على بيانات تدريبية، وتحسن أداءها حتى تتصرف بشكل مشابه للبشر عند مواجهة بيانات جديدة في نفس المجال". أي أن هناك عملية تدريب ببيانات سابقة، ومن ثم تطبيق هذا النموذج على بيانات جديدة للتنبؤ واتخاذ القرار.

حوراء (تلتقط نفساً وتسجل ملاحظات): إذن يعتمد الأمر بشكل كبير على وجود بيانات سابقة نتعلم منها. هل هناك أمثلة تساعدني على فهم هذه العملية عملياً؟

الدكتور علاء (يعرض الأمثلة على اللوح): نعم، لدينا ثلاثة أمثلة توضح مفهوم المهمة (T)، والأداء (P)، والتجربة (E):

1. تعلم التعرف على خط اليد

- المهمة T: التعرف على الكلمات المكتوبة بخط اليد في الصور وتصنيفها.
- الأداء P: النسبة المئوية للكلمات التي تم تصنيفها بشكل صحيح.
- التجربة E: مجموعة من الكلمات المكتوبة بخط اليد مع تصنيفات معينة مسبقاً.

2. تعلم الروبوت السائق

- المهمة T: قيادة السيارة على الطرق السريعة باستخدام المستشعرات البصرية.
- الأداء P: متوسط المسافة المقطوعة قبل حدوث خطأ.

○ التجربة E: سلسلة من الصور والأوامر المسجلة أثناء قيادة سائق بشري.

3. تعلم الشطرنج

○ المهمة T: لعب الشطرنج.

○ الأداء P: نسبة الفوز بالمباريات ضد الخصوم.

○ التجربة E: ممارسة الألعاب ضد نفسه مرارًا وتكرارًا.

حوراء (وهي تقرأ الأمثلة بتمعن): هذه أمثلة واضحة. إذن كلما كثرت بيانات التدريب (التجربة E)، صار أداء النموذج أفضل في المهمة المحددة، صحيح؟

الدكتور علاء (يبتسم بموافقة): نعم، هذا صحيح. كأنك تعطين الحاسوب خبرةً سابقة مشابهة لخبرتنا نحن. ومن خلال هذه الخبرة، يحاول الحاسوب نمذجة الأنماط التي تساعد على التنبؤ أو اتخاذ القرار بشكل أفضل.

حوراء (تهز رأسها بإعجاب): جميل جدًّا. وما هي أنواع تعلم الآلة الرئيسية التي أشار لها النص؟

الدكتور علاء (يرفع إصبعيه مشيرًا): أشار النص إلى ثلاثة تصنيفات رئيسية:

1. **التعلم الخاضع للإشراف (Supervised Learning):** حيث تكون لدينا بيانات مدخلات ومخرجات (تسميات) جاهزة، ويتعلم النموذج الربط بينها.
2. **التعلم غير الخاضع للإشراف (Unsupervised Learning):** لا نملك مخرجات أو تسميات جاهزة، بل نريد اكتشاف الأنماط في البيانات نفسها.
3. **التعلم المعزز (Reinforcement Learning):** يتعلم الحاسوب من خلال التفاعل مع البيئة المحيطة، فيحصل على مكافآت أو عقوبات حسب أفعاله.

حوراء (بحماسة): يبدو أن كل نوع يتمحور حول إجابة أسئلة مختلفة: في التعلم الخاضع للإشراف نعرف مسبقًا ما هي النتائج الصحيحة، وفي التعلم غير الخاضع نبحت عن أنماط لم نعرفها بعد، وفي التعلم المعزز نجرب ونتلقى تغذية راجعة.

الدكتور علاء (بتقدير لسرعة استيعابها): بالضبط. إن عملية تعلم الآلة عادة تنقسم إلى مرحلتين: مرحلة "التعليم" ومرحلة "التطبيق".

- في مرحلة التعليم، نرّود النموذج ببيانات تدريبية ليتعلم الأنماط.
- وفي مرحلة التطبيق، نستخدم النموذج المدرب لاتخاذ قرارات أو عمل تنبؤات على بيانات جديدة لم يسبق له رؤيتها.

حوراء (تسأل باستفهام): رائع. وماذا عن التعريفات الإضافية التي وردت حول تعلم الآلة في النص؟ سمعت ذكرًا لأسماء مؤلفين عدة.

الدكتور علاء (يفتح كتابًا ويقرأ بعض الاقتباسات): نعم، ذكرت بعض التعريفات:

- **Alpaydin (2004):** يعرف تعلم الآلة بأنه برمجة الحواسيب لتحسين مقاييس الأداء استنادًا لبيانات نموذجية أو خبرة سابقة.
- **Mitchell (1997):** يهتم بكيفية إنشاء برامج تتحسن تلقائيًا من خلال التجربة.
- **Marsland (2015):** يعتبر أن تعلم الآلة هو تعديل إجراءات الحواسيب لجعلها أكثر دقة في التنبؤ أو في التحكم بالروبوتات.

حوراء (تومئ وهي تسجل الاقتباسات): يبدو أن الجميع متفقون على الفكرة الأساسية: أن الحاسوب يتعلم من البيانات أو الخبرة السابقة لتطوير أدائه.

الدكتور علاء (يزفر بارتياح ويعتدل في جلسته): بالضبط، هذا هو الجوهر. وسؤال النص أيضًا كان: "كيف يعرف الحاسوب أنه بحاجة للتحسين؟ وكيف يعرف أنه تحسن؟" فهذان السؤالان يحركان فكرة قياس الأداء وتحديد نوع المهمة.

حواء (تنظر بسعادة وقد بدأت تفهم الصورة الكاملة): أصبحت الأمور أوضح بكثير الآن. تعلم الآلة يعطي الحاسوب القدرة على معالجة البيانات واكتشاف الأنماط وتطوير التنبؤات، مثلما نقوم نحن بذلك اعتمادًا على خبراتنا. لكنني لاحظت في النص أن التعلم البشري ما زال أوسع وأعمق من تعلم الآلة.

الدكتور علاء (يوافقها الرأي بإيماءة): صحيح، فالبشر يمتلكون مرونة ومهارات معرفية وحسية أوسع مما وصلت إليه خوارزميات الحاسوب حتى يومنا هذا. لكن التقدم في مجال الذكاء الاصطناعي وتعلم الآلة مستمر، وهو ينجز الكثير من المهام بطريقةٍ قد تفوق أداء البشر في بعض المجالات المحددة.

حواء (تبتسم بثقة): أشكرك يا دكتور على هذا الشرح الوافي. الآن أصبحت لدي صورة شاملة حول ما هو تعلم الآلة، وأنواعه، وآلية عمله. سأرجع للنص وأعيد قراءته بنظرة أكثر عمقًا.

الدكتور علاء (يبتسم ويجمع أوراقه): سعيد بمساعدتك يا حواء. لا تنسي أن تستفيدي من المراجع التي ذكرناها وتربطي ما قرأته في النص بالتطبيقات العملية. أنا بانتظار أسئلتك في المحاضرة القادمة.

حواء (تجمع دفاترها وتنصرف بحماس): شكرًا جزيلاً لك دكتور، إلى اللقاء.

الحوارية الثانية: ما هو تعلم الآلة (2)

حوراء (تدخل مكتب الدكتور علاء وقد بدت متحمسة للمواصلة): مرحبًا دكتور علاء، أريد اليوم أن أتابع الحديث معك حول أحد أنواع تعلم الآلة، وهو "التعلم الخاضع للإشراف". لقد قرأت النص التالي وأريد أن أفهمه بشكل أعمق، خاصةً ما يتعلق بالفوائد والعيوب.

الدكتور علاء (يرفع رأسه من أوراق أمامه ويبتسم بحفاوة): أهلاً حوراء. رائع أنك تتابعين القراءة. إذًا، أخبريني أولاً ماذا فهمت من النص؟

حوراء (تجلس وتخرج ملاحظاتها): حسنًا، الفكرة الأساسية هي أنه في التعلم الخاضع للإشراف Supervised Learning لدينا بيانات تدريبية تتضمن مدخلات ومخرجات صحيحة (تسمى الأهداف أو التسميات). الهدف هو أن تتعلم الخوارزمية دالة أو علاقة تربط هذه المدخلات بالمخرجات، بحيث عندما تستقبل بيانات جديدة لم ترها من قبل، يمكنها التنبؤ بالمخرج الصحيح.

الدكتور علاء (يشير إلى سبورة قريبة): بالضبط. هذه هي خلاصة "التعلم من الأمثلة"؛ أي أن لدينا معلمًا يعرف الإجابة الصحيحة، ويصوّب الخوارزمية في كل مرة تقوم بتنبؤ خاطئ إلى أن تصل لدقة مقبولة. لذا يُسمى هذا النمط بـ "التعلم الخاضع للإشراف" لأن هناك من يشرف على عملية التعلم ويصوّب الأخطاء.

حوراء (تنظر إلى السبورة باهتمام): وهذا ما ورد في النص: "نحن نعرف الإجابات الصحيحة، تقوم الخوارزمية بشكل متكرر بعمل تنبؤات ويتم تصحيحها من قبل المعلم." وفور أن تصل الخوارزمية لمستوى أداء جيد، تتوقف عملية التعلم. لكن هناك أمرًا آخر ذكره النص حول تصنيف المهام داخل التعلم الخاضع للإشراف...

الدكتور علاء (يومئ برأسه مشجعاً): صحيح. من الأمثلة المهمة لتصنيف مهام التعلم الخاضع للإشراف هي إن كانت المخرجات منفصلة (Discrete) أو مستمرة (Continuous). فلو كانت منفصلة، نسمي المشكلة "تصنيف (Classification)". ولو كانت القيم مستمرة، نسميها "انحدار (Regression)".

حوراء (بحماس): نعم، فهمت ذلك. إذا كان المطلوب معرفة فئة الصورة—هل هي قطة أم كلب—فهذا تصنيف. أما إذا أردنا التنبؤ بسعر المنزل أو درجات الطالب فهذه قيم مستمرة، نسميها انحدار. هل هذا صحيح؟

الدكتور علاء (يبتسم بموافقة): أحسنت، تمامًا. والآن أخبريني عن الفوائد والمساوئ التي قرأتها في النص بخصوص التعلم الخاضع للإشراف.

حوراء (تعاود النظر في ملاحظاتها): حسنًا، بالنسبة للفوائد:

1. يمكنه استخلاص النتائج من الخبرات السابقة.
2. يقدم حلولاً لأنواع مختلفة من المشكلات الحسابية العملية.
3. غالبًا ما يعطينا نتائج أدق مقارنةً بالتعلم غير الخاضع للإشراف.
4. قبل التدريب، تكون الفئات معروفة مسبقًا، مما يجعل تحديد المهمة أكثر وضوحًا.

الدكتور علاء (يكتب على السبورة سريعاً): جيد. وهذه الفوائد مهمة جدًا في مشاريع حقيقية. لأنها تجعلنا قادرين على تحديد أهداف واضحة قبل الشروع في بناء النموذج.

حوراء (تمسك بقلم وتدون): أما المساوئ:

1. يأخذ وقتًا أطول في التدريب؛ بسبب الحاجة إلى بيانات مصنفة.

2. لو كانت بيانات الاختبار مختلفة تمامًا عن بيانات التدريب، يمكن أن يخطئ النموذج في التنبؤ.
3. عملية تصنيف البيانات أو "وسمها" متعبة ومكلفة.
4. لا يناسب أنواعًا معقدة جدًا من مشاكل تعلم الآلة.
5. لا يقدم معلومات غير مكتشفة مثل التعلم غير الخاضع للإشراف.
6. إذا جاءت بيانات جديدة من خارج الفئات التي تعلّمها النموذج، فسيحدث خطأ في التصنيف.

الدكتور علاء (مهدهو وتحليل): ما ذكرته يعطينا نظرة واضحة عن القيود. مثلًا، المثال الأخير؛ لو درّبنا النموذج فقط على صور القطط والكلاب، ثم عرضنا عليه صورة زرافة، فقد يصنّفها كقطعة أو كلب، لأنّه لا يعرف شيئًا عن الزرافات.

حوراء (تبدو متفكّرة): أرى أن هذا يرتبط بموضوع قابلية التعميم. إذا كانت البيانات التدريبية لا تُمثّل جيدًا كل ما قد يُواجهه النموذج في الواقع، فسيجد صعوبة في التنبؤ بالبيانات الجديدة.

الدكتور علاء (يفرك ذقنه وهو يفكر): بالضبط. ولهذا نحتاج إلى عينة تدريب تمثّل مختلف الأوضاع والسيناريوهات التي قد نتوقعها في الواقع. لكن أحيانًا يصعب جمع بيانات متنوّعة أو كافية. وهنا تبدأ التحديات.

حوراء (تبتسم وقد بان عليها التنوّير بالفكرة): فهتم الآن. التعلم الخاضع للإشراف فعّال جدًا إذا توافرت لدينا بيانات مُسمّاة بدقة وكميات كافية. لكنه يكلفنا جهدًا ووقتًا لجمع تلك البيانات وتصنيفها، ولا يستطيع التعامل مع أشياء خارجة عن النطاق الذي تعلّمه من قبل.

الدكتور علاء (باهتمام): أحسنت في الخلاصة. هذه المعلومات مهمة عند اختيار نوع خوارزمية التعلم. وبالمناسبة، لدينا لاحقًا أنواع أخرى مثل التعلم غير الخاضع

للإشراف Unsupervised Learning والتعلم المعزز Reinforcement Learning ، والتي قد تستخدم في حالات لا تتوفر فيها بيانات مصنّفة أو عند الرغبة في اكتشاف أنماط خفية.

حوراء (تدوّن في دفترها بحماسة): سأتمعّق أكثر في قراءة التفاصيل حول كل من أنواع التعلم الأخرى حتى تتبلور الصورة الكاملة في ذهني. شكراً جزيلاً يا دكتور علاء على هذا الإيضاح.

الدكتور علاء (يتكى على كرسيه وينظر إليها بابتسامة تشجيع): على الرحب والسعة يا حوراء. تابعي قراءة المصادر، واطلعي على أمثلة حقيقية لتطبيقات التعلم الخاضع للإشراف، فهي ستساعدك أكثر على الفهم. وأنا جاهز لأي استفسار إضافي في أي وقت.

حوراء (تقف وهي تجمع أغراضها): سأفعل بالتأكيد. أشكرك مرةً أخرى دكتور. إلى اللقاء في المحاضرة القادمة.

الدكتور علاء (مشيراً بيده مودّعاً): إلى اللقاء، بالتوفيق يا حوراء.

الحوارية الثالثة: ما هو تعلم الآلة (3)

حوراء (تعود إلى مكتب الدكتور علاء وقد بدا عليها الفضول): مرحبًا دكتور علاء، عدتُ اليوم لاستكمال حديثنا حول أنواع تعلم الآلة. لقد اطلعت على نصّ جديد يتحدث عن "التعلم غير الخاضع للإشراف" وأريد فهمه بتفاصيله.

الدكتور علاء (يضيق عينيه بابتسامة ترحيب): أهلاً بك مجدداً يا حوراء. أخبريني، ما النقاط التي لفتت انتباهك في هذا النص؟

حوراء (تستعرض ملاحظاتها): يبدو أن الاختلاف الجوهرى عن التعلم الخاضع للإشراف هو عدم وجود مخرجات صحيحة أو تسميات جاهزة للبيانات، وبالتالي تقوم الخوارزمية بحدّ ذاتها بالبحث عن أنماط أو تراكيب خفية في البيانات. مثلاً، قد تحاول الخوارزمية تجميع البيانات المتشابهة معاً أو العثور على ارتباطات بينها.

الدكتور علاء (بإيماءة رضى): هذا صحيح. في التعلم غير الخاضع للإشراف Unsupervised Learning ، لا يوجد "معلم" يزودنا بالإجابات الصحيحة، بل يتعيّن على الخوارزمية أن تكتشف البنية أو الأنماط في البيانات بمفردها. من الأمثلة المعروفة عليه: التجميع (Clustering) حيث تُجمع المدخلات المتشابهة في مجموعات، وقواعد الارتباط (Association Rules) لاكتشاف العلاقات بين العناصر، وتقليل الأبعاد (Dimensionality Reduction) لتبسيط البيانات ذات الأبعاد الكبيرة.

حوراء (تدوّن بعض النقاط): فهمت. والنص يشرح أن الهدف من هذا النوع هو "معرفة المزيد عن البيانات" واستخلاص بُنى أو علاقات خفية. كما ذكر أن الخوارزمية قد تقترح أحياناً طريقة لتجميع البيانات لكن القرار النهائي حول فهم هذه المجموعات والاستفادة منها يبقى للمستخدم.

الدكتور علاء (يعدل جلسته ويتابع الشرح): بالضبط. لأننا لا نعرف مسبقًا ما هي البُنى التي سنكتشفها، قد نحتاج إلى تفسير النتائج بأنفسنا بعد أن يعطينا النموذج تلك المجموعات أو الأنماط. هذه طبيعة التعلم غير الخاضع للإشراف.

حوراء (بحماسة): أعجبنى أيضًا ما جاء في النص عن فوائد هذا النوع من التعلم. ذكروا أنه لا حاجة لبيانات مُسمّاة مسبقًا، مما يوفر جهدًا كبيرًا في وضع الملصقات والتسميات. كما أنه مفيد في العثور على أنماط قد تكون خفية وغير متوقعة، ويمكننا تقليل حجم البيانات بالاعتماد عليه.

الدكتور علاء (يشير إلى شاشة حاسوبه): صحيح جدًا. جُهد وضع العلامات قد يكون مكلفًا في كثير من المجالات، والتعلم غير الخاضع للإشراف يتجاوز هذه المشكلة. أيضًا يُسهّم في كشف العلاقات المعقّدة في البيانات. أما بالنسبة لتقليل الأبعاد، فهو مفيد في تحليل البيانات الكبيرة والمعقّدة، واستخلاص أبرز الميزات منها.

حوراء (تقلب صفحات ملاحظاتها): رغم ذلك، النص لم يغفل مساوئ التعلم غير الخاضع للإشراف، مثل احتمال أن تكون النتائج أقل دقة من التعلم الخاضع للإشراف لعدم امتلاكنا أي إجابات صحيحة لمطابقتها. كما أشار إلى أنه يصبح شديد التعقيد كلما زادت الميزات في البيانات، وقد يستغرق وقتًا طويلًا لمعالجة بيانات ضخمة.

الدكتور علاء (بتعبير جاد): هذه تحدّيات حقيقية. الخوارزمية قد تسفر عن نتائج "منطقية شكليًا" لكنها قد لا تكون مفيدة في سياقٍ معيّن ما لم نُقم بتحليلها وتفسيرها. كما أن عملية البحث عن جميع الاحتمالات والعلاقات في البيانات الكبيرة قد تستهلك الكثير من الموارد والوقت.

حوراء (بتفكير عميق): إذن يمكنني القول إن التعلم غير الخاضع للإشراف أكثر استكشافية من الخاضع للإشراف، لكنه قد يتطلب جهدًا كبيرًا في تفسير النتائج

والتحقق منها. ومع هذا، فهو قويّ جدًّا حين نريد كشف أنماط جديدة أو عندما لا نملك بيانات مُسمّاة.

الدكتور علاء (بتأييد): تمامًا. عليك دائمًا اختيار المنهجية المناسبة بناءً على طبيعة البيانات والهدف من التحليل. إن كان لديك تسميات واضحة وتريد نموذجًا دقيقًا جدًّا للتنبؤ، غالبًا ستختارين التعلم الخاضع للإشراف. أما إذا كنت في وضع استكشافي، لا تعلمين مسبقًا ما قد تجده في البيانات، فالتعلم غير الخاضع للإشراف هو خيار ممتاز.

حوراء (تبتسم وكأنها توصّلت لخلاصة): شكرًا جزيلاً يا دكتور. باتت الصورة أوضح لديّ الآن. سأراجع أمثلة عملية عن خوارزميات التجميع واستخدام تقليل الأبعاد حتى أرى كيف تطبق في الواقع.

الدكتور علاء (ينفض من مكانه مشيرًا بلطف): رائع يا حوراء. تابعي ذلك، وتدكري دائمًا أن السر يكمن في البيانات وكيفية توظيفها. أنا في انتظار أسئلتك في لقائنا القادم.

حوراء (تحمل أوراقها مغادرة وهي تبتسم): على الراحب والسعة دكتور. سأفعل. أشكرك مجددًا، وأراك قريبًا.

الحوارية الرابعة: ما هو تعلم الآلة (4)

حواء (تدخل إلى غرفة الدكتور علاء وعلى وجهها علامات الفضول): مرحبًا دكتور علاء، لقد قرأت النص الأخير الذي يشرح التعلم المعزز ومقارنته بالتعلم الخاضع للإشراف وغير الخاضع للإشراف. لدي بعض الأسئلة والنقاط التي أود مناقشتها معك.

الدكتور علاء (بابتسامة ترحيب): أهلاً بك يا حواء. سعيد برغبتك في التعمق أكثر. إذن، ما الذي جذب انتباهك في هذا النص؟

حواء (تراجع أوراقها): أولاً، فهمت أن التعلم المعزز يختلف عن النوعين الآخرين بعدم اعتماده على بيانات مصنفة أو غير مصنفة. بدلاً من ذلك، لدينا "وكيل" أو "عميل (Agent)" يتفاعل مع البيئة. فما يفعله هو تجربة أفعال مختلفة، ويستقبل مكافآت (Rewards) أو عقوبات (Penalties) من البيئة.

الدكتور علاء (يُومئ برأسه موافقاً): بالضبط. في التعلم المعزز Reinforcement Learning، يمتلك الوكيل هدفًا واضحًا يتمثل في تعظيم تلك "المكافأة" أو "القيمة" على المدى الطويل. ومن خلال التجربة والخطأ، يكتشف مجموعة الإجراءات (Actions) التي يجب اتخاذها في كل حالة (State) من البيئة.

حواء (تدوّن في دفترها): إذن الوكيل لا يتلقى "الأجوبة الصحيحة" مسبقًا كما في التعلم الخاضع للإشراف، ولا يحاول فقط اكتشاف الأنماط بدون تسميات كما في التعلم غير الخاضع للإشراف، بل يعتمد كليًا على الاستجابة الفورية من البيئة. كل إجراء يقوم به الوكيل يؤدي إلى تغيير حالة البيئة أو الإبقاء عليها، والبيئة بدورها تعطيه مكافأة.

الدكتور علاء (بصوت واضح): صحيح جدًا. وهذا ما ذكره النص: أن التعلم المعزز لا يتطلب مجموعة بيانات ثابتة، بل يتعلم الوكيل من التجربة المباشرة. النقطة الأخرى

أنه يركّز على إيجاد "السياسة المثلى (Optimal Policy)" التي تحدد الإجراء الأمثل في كل حالة، بدلاً من تحليل بيانات تاريخية محدّدة كما يحصل في التعلم الخاضع للإشراف.

حوراء (ترفع حاجبها باستغراب): لفت نظري أيضاً قولهم إن التعلم المعزز "ليس إشرافياً تماماً" لأننا لا نزوّده بتسميات، وفي الوقت نفسه "ليس غير إشرافي" لأننا نعرف إنجاز الوكيل من خلال مكافأة واضحة. هل هذا صحيح؟

الدكتور علاء (بيتسم ويشرح): بالضبط. في التعلم الخاضع للإشراف، نكون عادةً على دراية بمخرجات محددة ننشدها؛ وفي غير الخاضع للإشراف، لا نملك مخرجات معلومة بل نبحث في البيانات عن أنماط. في التعلم المعزز، لدينا مقياس واضح للأداء هو "المكافأة"، لكننا لا نعرف الإجراء الصحيح مسبقاً لكل حالة. لذا يمكن القول إنه نمط مستقل بذاته، يعتمد كلياً على التفاعل مع البيئة.

حوراء (تنظر إلى الجدول في النص): نعم، الجدول 1-4 وضّح ذلك:

1. التعلم الخاضع للإشراف:

- يعتمد على بيانات مصنفة ومعرفة مسبقة بالمخرجات الصحيحة.
- المهمة الأساسية: التصنيف أو التنبؤ (الانحدار).
- فيه "مُشرف" خارجي.

2. التعلم غير الخاضع للإشراف:

- يعتمد على بيانات غير مسمّاة.
- المهمة الأساسية: اكتشاف الأنماط أو التجميع.
- بدون مشرف.

3. التعلم المعزز:

- لا يتطلب بيانات بالمفهوم التقليدي؛ يعتمد على تفاعل الوكيل مع بيئته.
- يهدف لتعلم تسلسل من الإجراءات بناء على المكافآت.
- بدون مشرف مباشر، لكن لدينا مكافأة / عقوبة.

الدكتور علاء (مشيرًا إلى الجدول): نعم، تمامًا. لذلك كل نوع من هذه الأنواع يصلح لأغراض محددة. إن كنت تريد عمل نموذج يتنبأ بنتائج بناء على بيانات تاريخية تم وسمها مسبقًا، فالتعلم الخاضع للإشراف هو الأنسب. أما لو أردت اكتشاف مجموعات أو أنماط خفية في بيانات لا تملكين عنها معلومات وسم مسبقًا، فالتعلم غير الخاضع للإشراف هو الحل. أمّا إن كان لديك بيئة تفاعلية (مثل لعبة أو روبوت أو نظام توصيات يتعلّم من أفعال المستخدمين)، فالتعلم المعزز هو الخيارات القوية جدًا.

حوراء (تدوّن ملاحظة جديدة): وبالنسبة للتطبيقات الشهيرة للتعلم المعزز، سمعت عن برامج الألعاب مثل "ألفا جو (AlphaGo)" الذي تعلّم لعب لعبة الـ"جو" وفاز على بطل العالم، وكذلك روبوتات تتعلّم المشي، وبرامج تحكّم ذاتي بالسيارات. أليس كذلك؟

الدكتور علاء (بإيماءة موافقة): نعم، بالفعل. كل هذه الأمثلة تستخدم مبدأ "المكافأة" عند الأداء الناجح، أو "العقوبة" عند الفشل. على المدى البعيد، تكتسب هذه النماذج خبرة كبيرة حول الأفعال التي تؤدي إلى نتائج أفضل.

حوراء (بابتسامة امتنان): فهمت. أشكرك يا دكتور على هذا الشرح. أصبح لدي الآن صورة أوضح حول مفهوم "التعلم المعزز" وفهم أعمق للفرق بينه وبين النوعين الآخرين.

الدكتور علاء (يستند إلى كرسيه ويفرك ذقنه مفكرًا): العفو يا حوراء. أنصحك بأن تطلعي على تطبيقات عملية لهذا النوع من التعلم، خاصة في مجال الألعاب والروبوتات، لأنها توضح آلية التفاعل الحقيقي مع البيئة وخطوات التجربة والخطأ بوضوح شديد.

حوراء (تضع أوراقيها في حقيبتها وهي تستعد للمغادرة): سأفعل بالتأكيد. شكرًا جزيلاً لك دكتور علاء، سأبدأ في البحث عن أمثلة وشروحات تطبيقية لأفهم الخوارزميات الأساسية، مثل Q-Learning وDeep Q-Network.

الدكتور علاء (مشيرًا لها بتشجيع): جيد جدًا، تلك الخوارزميات مهمة للغاية في التعلم المعزز. ابحثي عنها، وإذا احتجت أي توضيح، فأنا في خدمتك. بالتوفيق يا حوراء.

حوراء (ترد بابتسامة واثقة): سأعود بكل الأسئلة التي ستخطر ببالي. إلى اللقاء دكتور.

الدكتور علاء (بصوت ودي): في أمان الله، وإلى اللقاء.

الحوارية الخامسة: ما هو تعلم الآلة (5)

حوراء (تدخل بابتسامة تدل على شغفها بالموضوع): مرحبًا دكتور علاء، لدي اليوم نص عن "التعلم الانتقالي او نقل التعلم" و"التعلم متعدد المهام" أرغب في مناقشته معك. يبدو أنهما مفهومان قريبان ولكن لكل منهما مميزات وطرقه الخاصة.

الدكتور علاء (يضع نظارته وينظر باهتمام): أهلاً بك يا حوراء. نعم، هذان الموضوعان مهمان ويُستخدمان بكثرة في مجالات مختلفة من تعلم الآلة. أخبريني ما أكثر شيء لفت انتباهك في النص؟

حوراء (تتفحص ورقة أمامها): يتحدث النص عن أن التعلم الانتقالي (او نقل التعلم Transfer Learning) يهدف إلى الاستفادة من المعرفة المكتسبة من مجال أو مهمة سابقة (تُسمى المجال المصدر)، لنقلها إلى مجال أو مهمة جديدة (المجال الهدف). ويكون حجم بيانات المجال المصدر عادةً أكبر من حجم بيانات المجال الهدف. الهدف هو تقليل البيانات أو تسهيل التعلم في المهمة الجديدة.

الدكتور علاء (يُومئ برأسه موافقًا): صحيح. على سبيل المثال، لو درّبنا نموذجًا ضخمًا للتعرف على الصور في مجالٍ ما — مثل التعرف على آلاف الفئات المختلفة من الحيوانات والأشياء — يمكننا لاحقًا استخدامه كأساس (Pre-trained Model) لمهمة أخرى شبيهة: كتمييز نوعٍ محدّد من الحيوانات. وبالتالي لا نحتاج إلى تدريب النموذج من الصفر، بل نُكَيِّفه باستخدام عدد أقل من العينات المصنّفة.

حوراء (بحماسة): بالضبط. والنص يوضح التعريف الرسمي للتعلم الانتقالي بالاعتماد على مفاهيم المجال (Domain) والداالة (Function). فالمجال يتكون من فضاء الميزات وتوزيع احتمالي، والداالة تتعلق بالتسميات (y) وداالة النموذج. ثم يُعرّف التعلم الانتقالي رسميًا بأن لدينا مجالًا مصدرًا وداالة تعلم مصدر، ومجالًا هدفًا وداالة تعلم هدف،

ونرغب في تحسين أداء النموذج الهدف باستخدام المعرفة من المجال المصدر، مع العلم أن المجالين غير متطابقين تمامًا.

الدكتور علاء (يُقلِّب بضع صفحات على مكتبه): صحيح جدًا. كثيرًا ما نرى هذا التطبيق في معالجة اللغة الطبيعية أو الرؤية الحاسوبية. مثلًا، عندما نأخذ نموذجًا درّبناه سلفًا على ملايين الصور، ثم نستخدمه في مهمة تصنيف صور طبية ببيانات قليلة. أو في اللغة الطبيعية، حين نأخذ نموذجًا مثل BERT ونعيد تدريبه Fine-Tuning لمهمة تصنيف نصوص طبية أو مالية.

حوراء (تتابع الحديث وقد بدا عليها التركيز): هذا رائع. إذن التعلم الانتقالي مفيد جدًا لتسريع وتحسين أداء النماذج في المهمات الجديدة التي تشبه المهمات الأصلية. لكن كيف يرتبط هذا بمفهوم "التعلم متعدد المهام" المذكور في النص؟

الدكتور علاء (يركز نظره على لوحة بيضاء في الغرفة): التعلم متعدد المهام Multi-task learning يقوم على تعلم عدة مهام في وقت واحد في نموذج واحد، بحيث تشترك هذه المهام في بعض المعلومات أو الميزات. على سبيل المثال، لو كانت لدينا مهام تتعلق بتحليل النصوص: مهمة لتصنيف المشاعر، وأخرى لتحديد أجزاء الكلام (POS Tagging)، وأخرى لتعرّف الكيانات، يمكننا أن ندرب نموذجًا واحدًا يتعلم كل هذه المهام بشكل متزامن. بهذا الشكل، يستفيد النموذج من القواسم المشتركة بينها.

حوراء (بابتسامة تعجب): فهمت، إذا استطاع النموذج تعلّم أشياء مهمة من مهمة معيّنة، فإنه يُطبّقها أو يستفيد منها في مهمة أخرى. مثلما نعمل نحن البشر عندما نتعلّم مهارة في الرياضيات فتساعدنا في حلّ مسائل في الفيزياء مثلًا. أليس كذلك؟

الدكتور علاء (يضحك ويشير بإبهامه موافقًا): بالضبط، هذه هي الفكرة! ومن هنا جاء الإلهام البيولوجي. فبدلًا من تدريب عدة نماذج مستقلة، نحاول إنشاء نموذج واحد يتقاسم المعرفة عبر المهام، ممّا يؤدي أحيانًا لنتائج أفضل وسرعة تعلم أعلى.

حواء (تنظر إلى النص وتقلب أوراقها): ذكر النص أن الاختلاف الأساسي بين التعلم الانتقالي وتعلم تعدد المهام هو في "كيفية" نقل المعرفة:

- في التعلم الانتقالي: نتعلم مهمة أولاً (أو مجالاً)، ثم ننقل المعرفة المتحصلة إلى مهمة أخرى لاحقاً، بشكل متسلسل.
- في التعلم متعدد المهام: نتعلم عدة مهام في الوقت نفسه في نموذج واحد، فتنتقل المعرفة بينها بالتوازي.

الدكتور علاء (يرفع إصبعاً مشيراً إلى نقطة مهمة): نعم، هذا توصيف دقيق. التعلم الانتقالي يُشبه القول: دعني أنتهي من مهمة A، ثم أنقل خبرتي المكتسبة إلى مهمة B. أما التعلم متعدد المهام فهو: سأتعلم مهمة A و B و C... بشكل مشترك وموازي في نموذج واحد.

حواء (بتفكير عميق): صحيح، وأرى أيضاً أن في التعلم الانتقالي نتوقع نوعاً من التشابه بين المهمة القديمة والمهمة الجديدة (كالصور العامة ثم الصور الطيبة)، وإلا لن يكون النقل فعالاً. وفي التعلم متعدد المهام يجب أن تكون المهام متشابهة نوعاً ما أو بينها ارتباط معين كي نضمن استفادة كل مهمة من الأخرى.

الدكتور علاء (يربت على الطاولة مؤكداً): أحسنت يا حواء. في كلتا الحالتين، إذا كانت المهام مختلفة تماماً، فربما يؤدي نقل المعرفة أو تشارك المهام إلى نتائج عكسية تُسمى "النقل السلبي (Negative Transfer)". لذا نحتاج دائماً إلى تقييم مدى قرب المهام من بعضها.

حواء (تسجل ملاحظة جديدة): فهمت. إذن الفرق الجوهرى:

1. التعلم الانتقالي: تدريب متسلسل، نقل خبرة نموذجٍ مدرَّبٍ على مهمة المصدر إلى مهمة الهدف.

2. التعلم متعدد المهام: تدريب متوازٍ، نموذج واحد يتعامل مع مهام متعددة تشترك في المعلومات، فيزداد كفاءتها مجتمعة.

الدكتور علاء (يبتسم وقد بدا عليه الرضا): بالضبط. والاثنان مستخدمان كثيراً في الذكاء الاصطناعي وتعلم الآلة الحديثة. مثلاً، نرى العديد من الأبحاث والتطبيقات حول Fine-Tuning لنماذج ضخمة (تعلم انتقالي)، وكذلك نرى نماذج متعددة الرؤوس لمعالجة مهام مختلفة في الوقت نفسه (تعدد المهام).

حوراء (تنظر إلى الساعة وتلمّ أوراقيها): شكراً جزيلاً لك دكتور علاء. أصبحت لدي الآن رؤية أوضح لكيفية التمييز بين التعلم الانتقالي ومتعدد المهام، وكيف يُستخدم كل منهما. سأحاول الاطلاع على بعض الأمثلة العملية لأتعمق أكثر.

الدكتور علاء (يقف مشيراً بتشجيع): عفواً يا حوراء، أنا سعيد باهتمامك. أنصحك بأن تُلقي نظرة على تطبيقات التعلم الانتقالي في الرؤية الحاسوبية ومعالجة النصوص، وعلى تطبيقات التعلم متعدد المهام في الشبكات العصبية العميقة. ستجدين أمثلة ممتازة توضح مميزاتهما وحدودهما.

حوراء (تضع حقيبتها على كتفها وتستعد للمغادرة): بالتأكيد سأفعل. أشكرك مرة أخرى. أراك في المحاضرة القادمة، دكتور.

الدكتور علاء (بابتسامة ودّية): إلى اللقاء يا حوراء، بالتوفيق في رحلتك العلمية!

الحوارية السادسة: ما هو تعلم الآلة (6)

حوراء (تدخل على الدكتور علاء وعلى ملامحها حماسة واضحة): مرحبًا دكتور علاء، لقد عدتُ ومعي نصُّ جديد يتحدث عن عدة أنواع من أساليب التعلم: التعلم مع عينة واحدة، والتعلم بدون عينات، والتعلم الاستقرائي، والاستنتاجي، والمجازي. أودّ مناقشتها معك لربطها بما سبق أن تناولناه.

الدكتور علاء (يضع نظّارته على عينيه وينظر إليها باهتمام): أهلاً بك يا حوراء، أهلاً بالمناقشات المثمرة. أسردي لي النقاط الأساسية التي وجدتها في هذا النصّ، لنبدأ منها.

حوراء (تقلب صفحاتها): أول ما لفت انتباهي هو التعلم مع عينة واحدة (One-shot Learning). إنه نموذجٌ للتعلم لا يحتاج إلى آلاف العينات التدريبية، بل تكفي عينة واحدة أو عدد قليل من العينات لكل فئة. ومثالهم كان التعرف على وجوه الأشخاص؛ حيث تُعطى صورة أو صورتان لشخصٍ ما فقط، ولكن ينبغي للنموذج أن يتعرف عليه لاحقًا تحت ظروف إضاءة مختلفة أو بملابس مختلفة.

الدكتور علاء (بإيماءة تأييد): نعم، هذا النوع مهم في التطبيقات التي لا تستطيع فيها توفير بيانات كثيرة لكل فئة. مثلاً، في تطبيقات التعرف على الوجوه لفتح الهواتف، نحصل غالبًا على صورة أو اثنتين لوجه المالك. الخوارزميات القائمة على التعرف باستخدام "عينة واحدة" قد تعتمد على تقنيات قياس التشابه بين الصور الجديدة والصورة/الصور المحدودة المتوفرة.

حوراء (تُقلب الورقة إلى قسمٍ آخر): ثم وجدتُ التعلم بدون عينات (Zero-shot Learning). نصّهم يقول إننا أحيانًا نحتاج إلى تصنيف فئات أو عناصر لم نعطِ النموذج أي مثالٍ سابق عنها. بمعنى آخر، النموذج يتعامل مع فئة جديدة تمامًا لم يسبق رؤيتها أثناء التدريب.

الدكتور علاء (يشبك أصابعه أمامه بتفكير عميق): هذا مجالٌ متطور جدًا في تعلم الآلة. الفكرة أن النموذج يستخدم المعلومات المستخلصة من فئات معروفة بالإضافة إلى معرفة أو توصيف عام لمعنى الفئة الجديدة (مثلًا سماتها أو وصفها اللغوي). بهذا يستطيع تعميم ما تعلّمه حتى على فئاتٍ جديدة لم تدخل في مرحلة التدريب. من أمثلة ذلك استخدام تمثيلات نصية في معالجة اللغة الطبيعية، فيكون النموذج قادرًا على فهم مفاهيم جديدة من خلال اللغة دون توفر صور مصنّفة عنها.

حوراء (تقرأ مقتطفًا من النص): أيضًا تناول النص التعلم الاستقرائي Inductive Learning (أو التعلم المفهومي Concept Learning). وصفه بأنه يُنشئ قاعدة عامة من البيانات التي نستخدمها في التدريب، وهو منهجٌ من الأسفل إلى الأعلى (Bottom-up). وقد أعطوا مثالًا مبسطًا:

- (أ) التفاح فاكهة.
- (ب) التفاح طعمه حلو.
- النتيجة: كل الفواكه حلوة المذاق.

وأشاروا إلى أنه مثال بسيط قد لا يكون صحيحًا منطقيًا، ولكنه يُبيّن كيف نعمّم بناءً على أمثلة محدودة.

الدكتور علاء (بابتسامة خفيفة): نعم، الاستقراء يعتمد على احتمالية التعميم. ففي تعلم الآلة الخاضع للإشراف - كالخوارزميات التقليدية للتصنيف أو الانحدار - نقول: "إذا تعلّمنا نمطًا ما من بيانات تدريبية، نُعمّمه على أمثلة لم نرها من قبل". قد يكون التعميم صحيحًا أو غير صحيح، بناءً على جودة البيانات وتشابهها مع واقع الاختبار. لكن بصورة عامة، هذا هو صلب تعلم الآلة: نستنبط قاعدةً عامةً من مجموعة بيانات محدودة ونأمل أن تعمل جيدًا على بقية البيانات.

حوراء (تومئ برأسها متفكرة): أما التعلم الاستنتاجي فهو عكس الاستقرائي، يعتمد نهجًا من الأعلى إلى الأسفل (Top-down). يستخدم الحقائق والقوانين المعروفة سلفًا للتوصل إلى استنتاجات محددة ("نعم" أو "لا"). مثالهم:

- (أ) كل الحيوانات آكلة اللحوم تأكل اللحوم.
- (ب) الأسد حيوانٌ آكلٌ للحوم.
- النتيجة: الأسد يأكل اللحوم.

هنا النتيجة حتمية طالما صحة المقدمات ثابتة.

الدكتور علاء (يشير بيده موضحًا): هذا صحيح. يفكر المنطق الاستنتاجي (Deductive) بصورة أكثر قاطعية. إذا كانت المقدمات صحيحة، فالنتيجة صحيحة بالضرورة. أما الاستقرائي (Inductive) فهو ترجيحي، لأننا نُعمّم من بيانات محدودة وقد نقع في أخطاء التعميم. في مجال تعلم الآلة، غالبًا ما نمارس النهج الاستقرائي، لكن الاستنتاجي له دوره في أنظمة الخوارزميات المنطقية وقواعد المعرفة.

حوراء (تستعرض قسمًا آخر من النص): يتناول النص أيضًا التعلم المجازي (Transductive Learning). وهو يختلف عن الاستقرائي في كونه يتعرّف على بيانات التدريب والاختبار معًا منذ البداية. أي أنه لا يبني نموذجًا تنبؤيًا عامًا صالحًا لأي عينة جديدة، بل يركّز على تصنيف أو وسم نقاط بيانات محددة (غير مسماة) في مجموعة الاختبار الحالية. وعند وصول نقاط بيانات جديدة أخرى، علينا إعادة العملية من جديد.

الدكتور علاء (يوضّح بفكرة مكتملة): نعم، في التعلم الاستقرائي، تدرّب نموذجًا على مجموعة تدريبية، ثم تستخدمه لاحقًا للتنبؤ بأي بيانات جديدة، دون الحاجة لإعادة التدريب من الصفر. أما في التعلم المجازي، فينظر إلى بيانات التدريب والاختبار معًا، فيُحاول الاستفادة من البنية الإجمالية لتلك البيانات، وفي النهاية يصدر التنبؤات لتلك

الحالات المحددة فقط. لو وصلت لاحقًا حالات إضافية، سيحتاج لإعادة بناء التنبؤات من جديد.

حوراء (تكتب بعض الملاحظات): يبدو أن للتعلم المجازي ميزة في استغلال البيانات غير المصنفة الموجودة في مجموعة الاختبار، ما يرفع دقة التنبؤ، لكنه مُكلف حسابيًا. أما في الاستقرار، فننشئ نموذجًا عامًا قد يكون أقل دقة نسبيًا إذا لم يستغل بيانات الاختبار مسبقًا، لكنه أسرع في التعامل مع البيانات الجديدة لاحقًا.

الدكتور علاء (بإعجاب لتلخيصها): أحسنت الخلاصة. على سبيل المثال، لو كان لدينا 2000 صورة مصنفة و98000 صورة غير مصنفة، فالتعلم الاستقرار يبيّن نموذجًا من 2000 صورة فقط. أما التعلم المجازي فقد يقول: "انتظر، لدي 98000 صورة غير مصنفة يُمكن أن تقدّم لي معلومات عن توزيع البيانات، وسأستفيد منها لتحسين دقة تصنيفي." لكن لو جاءت صورة جديدة (بعد الانتهاء)، فلا يمكن توقعها بسهولة إلا بإعادة التشغيل أو بتعديل كبير.

حوراء (تبتسم وقد وضحت لها الصورة): أرى أن النص حاول عرض أكثر من نهج للتعلم، بدءًا من حالات نادرة البيانات (One-shot أو Zero-shot) وصولًا إلى الاستقراء والاستنتاج والتعلم المجازي. كلٌّ منها يعالج مشكلة أو سياقًا محددًا في تعلم الآلة.

الدكتور علاء (ينهض من كرسيه وبتسم مشجعًا): بالفعل، هذه المبادئ مهمة. ففي مشاريع الذكاء الاصطناعي الواقعية، نختار المنهجية المناسبة حسب طبيعة البيانات وتوفرها، وإذا كنا نريد نموذجًا عامًا أو فقط نركّز على مجموعة بيانات بعينها، أو إن كنا نملك عينات كثيرة أم قليلة، إلخ.

حوراء (تجمع أوراها وهي تشكر الدكتور): شكرًا جزيلاً لك دكتور علاء. أشعر الآن أن لدي رؤية شاملة لكيفية اختلاف كل نهج عن الآخر وسبب حاجة كل منها لمجالٍ أو تطبيقٍ معين.

الدكتور علاء (يشير إليها بلطف): العفو يا حوراء. اقرئي بعض الأمثلة التطبيقية للتعلم المجازي مثلاً في التصنيف شبه الخاضع للإشراف (Semi-supervised) أو نماذج One-shot في الرؤية الحاسوبية. ستستفيدين كثيراً.

حوراء (تلوح بيدها مودّعة): سأفعل بالتأكيد. شكرًا مرة أخرى، وإلى اللقاء في المحاضرة القادمة دكتور.

الدكتور علاء (بابتسامة ودّية): إلى اللقاء يا حوراء، حظاً موفقاً في بحثك.

الحوارية السابعة: ما هو تعلم الآلة (7)

حوراء (تدخل على الدكتور علاء وفي يدها بعض الأوراق): مرحبًا دكتور علاء، أود اليوم أن نتحدث حول مفهوم "التعلم النشط" الذي قرأت عنه مؤخرًا. يبدو مثيرًا للاهتمام، خاصةً وأنه يتيح للخوارزمية اختيار العينات التي تريد الحصول على تسميات لها.

الدكتور علاء (يلتفت إليها باهتمام): أهلاً حوراء، سعيدٌ برغبتك في الاطلاع على هذا الموضوع. حدثيني عما فهمته من النص.

حوراء (تتأمل أوراقها): ما استوعبته هو أن التعلم النشط Active learning يُتيح للخوارزمية التفاعل مع "مستخدم بشري" أو "خبير" أثناء عملية التدريب. فبدل أن نزود النموذج بجميع تسميات البيانات دفعةً واحدة، نسمح له بشكل تفاعلي بأن يطلب تسمية عينات محددة لا يعرف تصنيفها على وجه الدقة. والهدف هو رفع أداء النموذج بأقل عدد ممكن من العينات المسماة.

الدكتور علاء (يبتسم مؤكدًا): بالضبط. الفكرة الجوهرية في التعلم النشط هي أن وضع "العلامات" أو "التسميات" قد يكون مكلفًا جدًا، سواءً من حيث الوقت أو المال. إذن، لماذا لا ندع النموذج نفسه يحدد أي عينات هي الأكثر فائدة له حتى يطلب تسميتها من المعلم البشري؟

حوراء (تقلب الصفحة لتقرأ فقرة من النص): النص يقول إن الغرض هو تحسين أداء خوارزمية تعلم الآلة مع الحفاظ على عدد العينات التدريبية المسماة محدودًا. هذا منطقي، خصوصًا في المجالات التي يتعدّر فيها الحصول على عينات كثيرة مصنّفة (مثل المجال الطبي أو الصناعي).

الدكتور علاء (يشير بيده مو أفقًا): صحيح. بدلاً من تصنيف الآلاف أو الملايين من العينات عشوائيًا، يوجّه النموذج "أسئلة" لمجموعة محددة جدًا من العينات التي يحتاجها. وبشكلٍ تفاعلي، يرفع بذلك معرفته بالمجال وبنية البيانات.

حوراء (تنظر إلى أحد العناوين في النص): ذكر النص استراتيجيتين أساسيتين: أخذ عينات غير المؤكدة (Uncertainty Sampling) وأخذ عينات من مساحة العينة (Sampling from the Version Space).

1. أخذ عينات غير المؤكدة:

- يختار المتعلم العينات التي يكون النموذج أقل ثقة فيها.
- يرسلها للمستخدم أو الخبير لطلب التصنيف (الوسم).
- العيب: إذا كان النموذج "واثقًا" في جزء من فضاء الإدخال ولكنه في الحقيقة خاطئ (أي لديه تحيّز أو خطأ في ذلك الجزء)، فلن يختار عينات جديدة منه، مما يؤدي إلى احتمالية فشل النموذج في هذا الجزء.

2. أخذ عينات من مساحة العينة:

- "مساحة العينة (Version Space)" تعني جميع الفرضيات أو النماذج التي تفسر بيانات التدريب الحالية تفسيرًا صحيحًا.
- في كل مرة نضيف عينة جديدة ونطلب تصنيفها، تتقلص مساحة العينة؛ لأن بعض النماذج لن تعود صالحة.
- الهدف هنا هو اختيار العينة التي تقلص مساحة العينة بأكثر قدر ممكن، مما يسرّع تعلم النموذج.

الدكتور علاء (بشيء من التفصيل): جميل. إذن في أخذ العينات غير المؤكدة، نتصيد النقاط التي يشكّ النموذج في كيفية تصنيفها، فنحصل من الخبير على تصنيفها الصحيح، فتزداد ثقة النموذج. وفي أخذ عينات من مساحة العينة، نبحث عن أكثر

نقطة في البيانات تميّز النماذج الممكنة، وتُسهّم في "استبعاد" أكبر عدد من الفرضيات الخاطئة.

حوراء (تهمّ بكتابة بعض الملاحظات): النص أشار إلى أن هذه المنهجية مفيدة جدًّا عندما تكون تكلفة جمع العينات المسماة أو "وسمها" باهظة. وهي تضع "الإنسان في الحلقة (Human in the loop)"؛ أي أن الخوارزمية تطلب منه باستمرار المساعدة عندما تحتاجها فعليًّا.

الدكتور علاء (يؤكد الفكرة): نعم، وهذا ما يجعل التعلم النشط أساسيّاً في العديد من التطبيقات. تخيّلني مثلاً أنك تعملين في مجال التشخيص الطبي بالاعتماد على صور الأشعة، وعملية "تصنيف" كل صورة من قِبل طبيب مختص قد تستغرق وقتاً كبيراً. لذا بدلاً من رسم آلاف الصور، ندع الخوارزمية تشاهد مجموعة غير مسماة كبيرة، ثم تختار عشرات أو مئات الصور التي هي حقًّا بحاجة ماسة إلى تفسيراتها. هذا يُقلص الكلفة والجهد.

حوراء (ترفع حاجبها باستفهام): وهل هناك تحديات تواجه هذا النوع من التعلم؟ أعني قد تبدو الفكرة مثالية جدًّا، لكن لا بدّ من عوائق.

الدكتور علاء (يبسّط الفكرة): بالتأكيد هناك تحديات. منها على سبيل المثال:

1. اختيار الاستراتيجية المثلى للسؤال: كيف نقرر النقاط التي تعكس "عدم اليقين" الأكبر؟ أو كيف نقوم بعملية أخذ عينات من مساحة العينة بفعالية؟
2. ضمان عدم سقوط النموذج في فخ "التحيّز" أو "التعميم الخاطئ". كما ذكرت في عيب أخذ عينات عدم اليقين، قد يتجاهل النموذج مناطق مهمة من فضاء الإدخال.
3. الحاجة إلى استجابة سريعة وموثوقة من الخبير البشري كي لا تتعطل عملية التدريب.

حوراء (تُغلق مفكرتها وهي تستعد للرحيل): أظن أنني اكتسبت صورة أوضح حول ماهية التعلم النشط. إنه باختصار: منهج لجعل النموذج يطلب العينات التي لا يستطيع تصنيفها بثقة، أو التي تُضيق "مساحة العينة" بسرعة، مما يرفع من دقة النموذج رغم محدودية البيانات المسماة.

الدكتور علاء (بانث عليه علامات الرضا): بالضبط. أنصحك أن تلقي نظرة على بعض الأوراق العلمية التي تتحدث عن تطبيقات ناجحة للتعلم النشط في مجالات مثل الرؤية الحاسوبية أو معالجة اللغة الطبيعية. سترين كيف تُستخدم هذه الأفكار عملياً.

حوراء (تحمل أوراقها وتبتسم): سأقوم بذلك بالتأكيد، شكرًا جزيلاً يا دكتور. لقد اتضح لي كيف يُسهم التعلم النشط في معالجة مشكلة شُح البيانات المسماة.

الدكتور علاء (مشيرًا لها بالوداع): عفواً حوراء. بالتوفيق في بحثك، وأنا بانتظار الأسئلة التي ستبادر إلى ذهنك بعد قراءتك.

حوراء (تلوّح بيدها مودعة): إلى اللقاء دكتور، شكرًا على وقتك وتوضيحاتك الثمينة.

الدكتور علاء (يببتسم): في أمان الله يا حوراء، موفقة إن شاء الله.

الحوارية الثامنة: ما هو تعلم الآلة (8)

حوراء (تدخل على الدكتور علاء وهي تحمل ملاحظات عدّة): مرحبًا دكتور علاء، عدتُ اليوم وأريد مناقشتك حول "التعلم الأونلاين" و"التعلم الأوفلاين" في تعلم الآلة. قرأت نصًّا يفرق بينهما، ولكني أريد أن أسمع شرحك وتوضيحاتك لأفهم الصورة كاملة.

الدكتور علاء (يبتسم ويدعوك للجلوس): أهلاً حوراء، سررت بعودتك. أخبريني أولاً ما النقاط التي استوقفتك في النص؟

حوراء (تنظر في ملاحظاتها): أولاً، التعلم الأونلاين Online learning—كما يقول النص—هو أسلوب تتعلم فيه الخوارزميات من البيانات "لحظة بلحظة" أو "تدفقيًا". بمعنى أن كل عينة بيانات جديدة تصل تأخذها الخوارزمية لتحديث نموذجها، ثم تمضي قدمًا دون الحاجة للاحتفاظ بكل البيانات القديمة بالضرورة.

الدكتور علاء (يشير برأسه موافقًا): هذا صحيح. في كثيرٍ من الأحيان تُفضّل الخوارزمية الأونلاين "نسيان" أو "تقليل" أثر العينات القديمة مع الوقت من أجل التأقلم مع تغير التوزيعات الإحصائية للبيانات. وهذا مهم إذا كانت البيانات ليست ثابتة (Non-Stationary)، مثل معلومات تصل على شكل تدفق (Stream) أو بيانات تتغير خصائصها مع الزمن.

حوراء (بابتسامة اهتمام): والنص ذكر مثلاً على ذلك: خوارزمية الانحدار الاشتقاقي للانتشار الخلفي (Stochastic Gradient Descent) في الشبكات العصبية. حيث نحدّث أوزان الشبكة بعد كل عينة أو دفعة صغيرة، وهذا هو جوهر التعلم الأونلاين.

الدكتور علاء (مؤكدًا): بالضبط. يُسمّى أحيانًا Stochastic Gradient Descent، خاصة عندما نعالج عينة أو بضع عينات في الدفعة الواحدة (Mini-Batch).

حواء (تنتقل للنقطة التالية): بالنسبة للتعلم الأوفلاين، الخوارزمية تعمل على مجموعة بيانات كاملة ومخزّنة مسبقًا. ثم تُدرّب النموذج دفعةً واحدة. وإذا تغيّرت البيانات أو أضيفت عينات جديدة، فعادة ما نعيد التدريب من الصفر أو نعيد تشغيل الخوارزمية بطريقة ما.

الدكتور علاء (يضع نظارته ويضبطها قليلاً): صحيح. في التعلم الأوفلاين Offline learning، افتراضياً لدينا بياناتنا مسبقاً (مثلاً ملف CSV يحتوي كل شيء)، ونُشغّل الخوارزمية مرةً واحدة. إذا حصلنا لاحقاً على بيانات جديدة مختلفة، قد لا نستطيع ببساطة "تحديث" النموذج؛ بل نحتاج إلى دمج البيانات الجديدة مع القديمة وإعادة التدريب كلياً أو جزئياً.

حواء (تبتسم وتذكر مثال النص): أعجيني مثال الطالب والكتب. النص أشار بشكلٍ معكوس: اعتبر أن الطالب الذي يمتلك كل الكتب دفعة واحدة ويتعلم منها كلها، ثم لا يكتسب أي معرفة جديدة بعد انتهائه—هذا مثل "التعلم الأوفلاين". أما الطالب الذي يستمر في تلقي الكتب الجديدة وتتوسع معرفته شيئاً فشيئاً—فهو "التعلم الأونلاين". لكن بدا لي أن النص مزج بينهما أو قلهما بطريقة ما.

الدكتور علاء (يضحك قليلاً): حدث بعض الالتباس في صياغة النص، نعم. الصورة المعتادة هي:

- التعلم الأوفلاين: الطالب لديه كل الكتب والمراجع من البداية (لا مستجدّات)، يدرسها جملةً واحدة، ثم يتوقف عن التعلّم لاحقاً.
- التعلم الأونلاين: الطالب يتعلم باستمرار ويحدّث معارفه كلما حصل على كتاب جديد أو أي معلومة جديدة.

على كل حال، المهم هو الفرق في آلية التعامل مع البيانات: دفعة واحدة مسبقاً (أوفلاين) أم تدريجياً مع الوقت (أونلاين).

حوراء (تدوّن ملاحظة جديدة): ذكر النص فائدتين رئيسيتين للتعلم الأونلاين:

1. يمكنه التعامل مع كميات كبيرة جدًّا من البيانات، لأنه لا يحتفظ بالبيانات كلها ويحدّث النموذج باستمرار.
2. يمكنه التكيّف مع التغيّرات التي تطرأ على طبيعة البيانات (مثل رسائل البريد المرعجة التي تتطور مع الزمن).

الدكتور علاء (يشير بإصبعه للسبورة): بالضبط. تخيلي شركات مثل Google أو Facebook تتلقى سيولاً من البيانات كل ثانية. لن يكون منطقيًّا تخزين كل تلك البيانات الضخمة من أجل إعادة التدريب في كل مرة. بدلاً من ذلك، تستخدم خوارزميات أونلاين تُحدّث باستمرار، فتمكن من مواكبة المستجدات بشكلٍ أسرع دون الحاجة لإعادة البناء من نقطة الصفر.

حوراء (بقليل من الفضول): لكن النص قال أيضًا إن هذا لا يجعل الأونلاين متفوقًا دومًا. فقد تكون هناك تنازلات في الدقة أو في كفاءة العينة أو في استهلاك CPU.

الدكتور علاء (بصوت تحليلي): صحيح. أحيانًا، التدريب الأوفلاين بدفعة واحدة من البيانات الشاملة، مع طرق أكثر تعقيدًا، قد يصل إلى نموذج عالي الدقة. في المقابل، التدريب الأونلاين ربما يقدم نتائج أسرع أو أكثر مرونة في التعامل مع البيانات المتغيرة، لكنه قد يدفع ثمنًا في الدقة أو يزيد من التعقيد الحسابي اللحظي.

حوراء (تقرأ آخر سطر في النص تقريبًا): وفي نهاية النص تحدّث عن أن هناك حلًّا وسطًا: الدُفعات الصغيرة (Mini-Batch). بمعنى أن الخوارزمية تتلقى البيانات على شكل دُفعات محدودة، بدلًا من معالجة كل عينة منفردة أو معالجة كل البيانات دفعة واحدة.

الدكتور علاء (يشير موافقًا): نعم، التدريب بالدفعات الصغيرة هو الأسلوب الشائع في كثيرٍ من خوارزميات الشبكات العصبية. فهو يوازن بين استقرار التحديث (كما في الأوفلاين) وسرعة التحديث (كما في الأونلاين). معالجة كل عينة على حدة قد تسبب تذبذبات عالية أثناء التدريب، ومعالجة كل البيانات قد تكون ثقيلة، فالدفعات الصغيرة تقدّم حلاً وسطاً.

حوراء (تجمع أوراها وتبدوراضية عن النقاش): إذن فهمت الآن النقاط الأساسية:

- **التعلم الأونلاين:** تحديث تدريجي للنموذج عند قدوم البيانات الجديدة، مناسب للبيانات المتدفقة أو المتغيرة.
- **التعلم الأوفلاين:** تدريب دفعة واحدة على كل البيانات المخزنة مسبقاً، وقد نحتاج لإعادة التدريب من جديد عند وصول بيانات إضافية.
- **الموازنة:** هناك دوماً مفاضلات بين السرعة والدقة وتغيّر البيانات وحجمها. والدفعات الصغيرة أسلوبٌ وسط.

الدكتور علاء (يبتمس مطمئناً): بالضبط حوراء. هذا ملخص ممتاز. تابعي اطلاعك على تفاصيل الخوارزميات الأونلاين مثل SGD أو خوارزميات التطور التتابعي في SVM إذا أردت معرفة الأمثلة العملية.

حوراء (تلتقط حقيبتها وتهتم بالمغادرة): سأفعل بالتأكيد. شكراً جزيلاً يا دكتور على هذا التوضيح الوافي. أراك في المحاضرة القادمة.

الدكتور علاء (يوحي بالتوديع): إلى اللقاء حوراء، موقفة في دراستك وأبحاثك.

الحوارية التاسعة: ما هو تعلم الآلة (9)

حوراء (تدخل على الدكتور علاء وعلى وجهها علامات الاهتمام): مرحبًا دكتور علاء، أودّ استكمال حواراتنا حول أنواع مختلفة من أساليب تعلم الآلة. فقد قرأت نصًّا جديدًا يتحدث عن "التعلم الجماعي" و"التعلم المتزايد" و"التعلم الذاتي" و"التعلم متعدد الأمثلة". أتمنى أن توضح لي هذه المفاهيم بشكل أعمق.

الدكتور علاء (يومئ برأسه مشجعًا): حسنًا، ابدأي بما لفت انتباهك حول التعلم الجماعي.

حوراء (تنظر إلى ملاحظاتها): حسب النص، في خوارزميات التعلم الجماعي (Batch Learning) تتوفر لدينا كل بيانات التدريب دفعة واحدة منذ البداية. وبعد الانتهاء من مرحلة التدريب، لا يمكننا إضافة عينات جديدة. إذا كانت هذه البيانات ضخمة جدًا، فإن عملية التدريب تصبح طويلة وربما مكلفة في الذاكرة.

الدكتور علاء (بتأكيد): صحيح. نموذج التعلم الجماعي يُسمى أحيانًا التعلم الدفعي (Batch Learning). نستخدم فيه بيانات متجمعة، ثم ندرّب النموذج دفعة واحدة. ولا يستطيع النموذج التعلم من البيانات التي تأتي لاحقًا، إلا بإعادة التدريب من الصفر على كامل البيانات القديمة والجديدة.

حوراء (تنتقل ببصرها إلى فقرة أخرى): وفي المقابل، هناك التعلم المتزايد (Incremental Learning). هنا من الممكن إضافة بيانات تدريب جديدة بعد مرحلة التدريب الأولى، كي نحسن أداء النموذج دون إعادة التدريب من نقطة الصفر.

الدكتور علاء (يوضح أكثر): بالضبط. في التعلم المتزايد، الهدف هو جعل الخوارزمية قابلة للتحديث مع وصول بيانات جديدة، مع الاحتفاظ بالمعرفة السابقة. فلو كان عندنا نموذج مدرّب على مجموعة صور، ثم حصلنا بعد شهر على مجموعة صور

إضافية لفئات جديدة، نستطيع تكييف النموذج وتحديثه بدلاً من محوه وإعادة بناء كل شيء.

حواء (تقرأ من النص): كما يقول النص، هناك ثلاث فئات من خوارزميات التعلم المتزايد وفقاً لقدرتها على تخزين بيانات التدريب السابقة:

1. البيانات الكاملة: تحتفظ بجميع البيانات القديمة، مما يحقق دقة عالية لكنه يستهلك ذاكرة كبيرة.
2. البيانات الجزئية: تحتفظ ببعض البيانات فقط لتحقيق توازن بين الذاكرة والدقة.
3. بدون بيانات: لا تحتفظ إلا ببعض المعلومات الإحصائية، فتقل الدقة لكنها تحتاج ذاكرة قليلة.

الدكتور علاء (يشير بيده موافقاً): هذا صحيح جداً. لكل فئة مزايا وعيوب. إن كان توفير الذاكرة ليس مشكلة، فقد نختار الاحتفاظ بكل شيء لرفع الدقة. أما إذا كانت الذاكرة محدودة أو بياناتنا ضخمة للغاية، فقد نلجأ للطرق الأخرى.

حواء (تقلب صفحة أخرى): النص تطرّق أيضًا إلى التعلم الذاتي (Self-training)، واعتبره شكلاً متقدماً من التعلم غير الخاضع للإشراف. لكن في الواقع، اعتُبر أيضًا شكلاً مستقلاً من التعلم الخاضع للإشراف، والسبب أنه لا يحتاج لمصنّف بشري، بل يحصل النموذج على "تسميات" من البيانات ذاتها باستخدام معلومات تنظيمية ضمنية.

الدكتور علاء (بنغمة تفسيرية): التعلم الذاتي يقع في منطقة بينية. من جهة لا نملك تسميات جاهزة من خبير بشري، لكن لدينا آلية داخلية لاستنتاج التسمية أو وضع علامة للبيانات—ربما اعتماداً على بعض المؤشرات أو البيانات الوصفية. لذا هو نوع من التعلم الخاضع للإشراف بآلية "تسمية ذاتية"، أو نعتبره غير خاضع من زاوية أخرى

لعدم وجود معلم بشري. غالبًا يُستخدم في المراحل الأولى لبناء نموذج يعتمد على معلومات البناء الداخلي للبيانات، ثم يوسّع نطاق التسمية بالتدرج.

حوراء (تستذكر فقرة أخرى في النص): أخيرًا، عندي تساؤل حول التعلم متعدد الأمثلة (Multi-Instance Learning). فهمت أنه فرع من التعلم الخاضع للإشراف، لكن بدلًا من إعطاء تصنيف لكل عينة لوحدها، نعطي تصنيفًا لـ "حقيبة (Bag)" تحتوي عدة عينات. في التصنيف الثنائي، إذا كان في الحقيبة أي عينة واحدة موجبة، فتصبح الحقيبة كلها موجبة، بينما تكون الحقيبة سالبة إذا كانت كل العينات سالبة.

الدكتور علاء (يبتمس علامة الموافقة): صحيح. الفكرة أن هناك عدم يقين جزئي حول تصنيفات العينات الفردية، لكننا نعرف تصنيفًا جماعيًا للحقيبة. مثال شهير: إذا كانت الحقيبة تمثل صورة كاملة، والعينات هي أجزاء أو مناطق داخل الصورة. إذا كانت الصورة تحتوي ورمًا خبيثًا في أي جزء منها، تُصنّف كلها بأنها موجبة. التحدي هنا هو استنتاج أي جزء بالضبط يسبب هذه الإشارة الموجبة، لكن التعلم يتم على مستوى الحقائق.

حوراء (تدون ملاحظة أخيرة): الهدف إذن: تدريب نموذج قادر على التعامل مع حقائق بيانات بدلاً من العينات المفردة، ثم تطبيقه على حقائق جديدة غير مرئية. قد يكون مفيدًا في العديد من المجالات حيث لا تتوفر لدينا معلومات دقيقة عن كل عينة في الداخل، بل عن المجموعة ككل.

الدكتور علاء (ينظر بارتياح): هكذا نكون قد غطينا المفاهيم الجديدة:

1. التعلم الجماعي (Batch) : بيانات متوفرة من البداية، تدريب مرة واحدة.
2. التعلم المتزايد (Incremental) : تحديث النموذج مع البيانات الجديدة دون إعادة كل شيء.

3. **التعلم الذاتي (Self-training)**: يعتمد على آلية وضع العلامات ذاتيًا، من دون تدخل بشري مباشر.
4. **التعلم متعدد الأمثلة (Multi-Instance)**: تصنيف حقائب تحتوي عينات، بدلاً من تصنيف كل عينة منفردة.

حوراء (تبتسم وقد اتضحت لها الرؤية): أشكرك دكتور علاء، أشعر الآن بأن لدي صورة أوضح حول هذه الأنواع. سأقرأ المزيد حول تطبيقاتها العملية.

الدكتور علاء (مشيرًا بلطف): عفواً حوراء. أتمنى لكِ التوفيق في دراسة هذه الأساليب. لا تترددي في طرح مزيدٍ من الأسئلة مستقبلاً.

حوراء (تلوّح بيدها مودّعة): إلى اللقاء دكتور. سأعود قريباً إذا واجهتني أي استفسارات إضافية.

الدكتور علاء (بابتسامة أبوية): في أمان الله يا حوراء. بالتوفيق دائماً.

الحوارية العاشرة: كيف يعمل تعلم الآلة (1)

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

حوراء (تلج القاعة ويدها النص وقد بدا عليها حماس واضح): مرحبًا دكتور علاء، عدتُ اليوم لأواصل حوارنا حول كيفية عمل الآلة في سياق تعلم الآلة الخاضع للإشراف. النص الذي قرأته يشرح مجموعة من المفاهيم، من بينها مشكلة النماذج المتوافقة مع البيانات، ومعايير اختيار النموذج، والتحيز الاستقرائي. أريد أن أناقشها معك وأتأكد من فهمي لها جيدًا.

الدكتور علاء (مبتسمًا ويشير إليها بالجلوس): أهلاً بك يا حوراء. تفضلي، وأخبريني عمّا تتساءلين تحديداً.

حوراء (تتفحص بعض الملاحظات): أول ما فهمته من النص أن تعلم الآلة الخاضع للإشراف يبني نموذجًا تنبؤيًا اعتمادًا على أمثلة سابقة (بيانات تدريب). ولدينا خصائص وصفية (Features) وسمّة هدف (Target). نعلّم الخوارزمية لتتنبأ بقيمة السمّة المستهدفة اعتمادًا على الخصائص الوصفية.

الدكتور علاء (يُومئ برأسه موافقًا): صحيح جدًا. نسمي هذا النهج "الخاضع للإشراف" لأن لدينا بيانات مصنّفة مسبقًا. في مثال الرهن العقاري، كانت الخصائص: المهنة، والعمر، ونسبة القرض إلى الراتب، بينما السمّة المستهدفة هي النتيجة (افتراضي أم استرداد).

حوراء (تعود للنص): نعم، وقد أورد النص مثالًا بسيطًا: إذا كانت نسبة القرض إلى الراتب < 3 ، نتوقع "افتراضي"، وإلا "استرداد". هذا النموذج يبدو أنه يطابق البيانات

الصغيرة في الجدول بالكامل. ولكن عادةً، مع بيانات أكثر تعقيدًا وخصائص أكثر تنوعًا، لا يمكننا بسهولة إيجاد مثل هذه القاعدة يدويًا.

الدكتور علاء (مُضيفًا): صحيح. لذلك نلجأ للخوارزميات، التي تبحث بطريقة ممنهجة في فضاء (Space) من النماذج المحتملة لإيجاد نموذج "جيد" يربط بين الخصائص والهدف.

حوراء (تقرأ ما دُونته): أثار النص نقطة مهمة: مجرد العثور على نموذج يتوافق تمامًا مع بيانات التدريب (أي لا يخطئ في أي عينة تدريبية) قد لا يكون مفيدًا. وقد طرح سببان لذلك:

1. وجود ضوضاء (Noise) في البيانات الكبيرة، فالنموذج الذي يطابق الضوضاء قد يفشل في تعميم ما تعلمه.
2. غالبًا بيانات التدريب لا تمثل كل الحالات المحتملة، فقد يبقى عدد كبير من النماذج التي تتوافق مع بيانات التدريب، لكنها تُعطي تنبؤات مختلفة تمامًا في عينات جديدة.

الدكتور علاء (بتأكيد): هذان السببان يدلان على أن "التوافق فقط" ليس كافيًا. إذا طابقتنا كل نقطة في التدريب 100%، فقد نُفرط في التخصيص (Overfitting)، أو نعجز عن التعامل مع عينات جديدة.

حوراء (بحماسة): نعم، استخدم النص أيضًا مثال "البقالة" أو "البيع بالتجزئة" لتوضيح المشكلة. لدينا 3 خصائص وصفية ثنائية (شراء أغذية الأطفال/مشروب غازي/منتجات نباتية عضوية)، ولدينا سمة مستهدفة: (أعزب/زوج/عائلي). أشار النص إلى أنه يمكن أن توجد $3^8 = 6561$ نموذجًا محتملاً، لأن لدينا 8 مجموعات من القيم الوصفية و3 خيارات للهدف في كل مجموعة، فالمجموع 3^8 .

الدكتور علاء (مؤكدًا): بالضبط. ولكن عند إدخال بيانات تدريبية قليلة (5 عملاء فقط)، سيبقى هناك عدد كبير من النماذج ما يزال متوافقًا مع تلك البيانات القليلة، لكنه يختلف في تنبؤاته للحالات غير الموجودة في التدريب.

حوراء (تستكمل بحزم): وهذا يقود إلى القول بأن تعلم الآلة هو "مشكلة مطروحة بشكل سيئ (ill-posed)"، إذ لا يوجد حلّ فريد يطابق البيانات ويعمّم بشكل صحيح على بيانات المستقبل. لذلك لا بدّ من معيار إضافي أو تحيز استقرائي يساعدنا في اختيار نموذج من بين عدة نماذج محتملة.

الدكتور علاء (يشير بيده للموافقة): صحيح جدًّا. نحتاج ما يُسمّى بالـ"تحيز الاستقرائي (Inductive Bias)" على سبيل المثال، خوارزمية أشجار القرار قد تفضل الأشجار الأقصر أو الأقل تعقيدًا؛ وهذا ما نسميه تحيزًا تفضيليًا (Preference Bias) أو ربما نحد من مساحة الفرضيات (Hypotheses) التي نفحصها من الأساس، وهذا ما نسميه تحيزًا محدودًا (Restriction Bias).

حوراء (تقلّب النص): جاء في التعريف أيضًا:

1. التحيز المحدود (Restriction Bias): نقيّد أو نحد من مساحة النماذج التي نبحث فيها، بحيث تكون أصغر من الفضاء الكلي.
2. التحيز المفضل (Preference Bias): نسمح بالبحث في كامل مساحة النماذج، لكننا نُعيّن "أفضلية" لأشكال معينة من النماذج (كالنموذج الأبسط)، فنجدها أسرع أو نثق فيها أكثر.

الدكتور علاء (موضحًا): بالضبط. كل خوارزمية تأتي معها "افتراضات" أو "تحيزات" ضمنية تُحدّد كيف تختار النموذج وترتبه. مثلاً، خوارزمية الانحدار الخطي تفترض شكلاً خطيًا بين المدخلات والمخرجات، وهذا تحيز محدود. أما خوارزمية أشجار القرار فتسمح بمجموعة واسعة من الأشكال، لكنها تُفضّل الأشجار الأقصر.

حوراء (بنبرة استفهامية): إذن، الهدف النهائي هو الحصول على نموذج لا يحفظ بيانات التدريب فحسب، بل ويعمّم على أمثلة جديدة. ومن دون تحيز استقرائي، لا نستطيع تفضيل نموذج على آخر أو توجيه عملية البحث.

الدكتور علاء (يجيبها بحزم): أحسنت. وهذا جوهر العبارة الشهيرة: "لا يوجد تعلّم دون تحيز". فبدون أي افتراضات، سنجد نماذج عديدة جدًّا ومتوافقة مع بياناتنا، ولن يكون بوسعنا اختيار ما هو أفضل لتنبؤات المستقبل.

حوراء (تضع أوراقيها وهي تبتسم): حسنًا، أظنني فهمت الأمر أكثر الآن:

1. تعلم الآلة الخاضع للإشراف يبني نموذجًا من بيانات تدريب.
2. التوافق مع البيانات وحده لا يكفي لاختيار النموذج، فقد يؤدي للتخصيص الزائد أو يفشل خارج التدريب.
3. التحيز الاستقرائي هو ما يُمكن الخوارزمية من اختيار نموذج يعمّم جيدًا على عينات جديدة.
4. التحيز المحدود يُقلّص فضاء النماذج، والتحيز المفضل يُعطي أولوية لبعض النماذج في البحث.

الدكتور علاء (ينهض من كرسيه بابتسامة رضى): ممتاز يا حوراء! هذا فهمٌ جوهري لتصميم وتقييم خوارزميات تعلم الآلة. أطلعني على أمثلة عملية في خوارزميات مشهورة (كأشجار القرار أو الشبكات العصبية) لترين كيف تُطبّق هذه التحيزات عمليًّا.

حوراء (تحمل حقيبتها): سأفعل بالتأكيد. شكرًا جزيلًا دكتور على هذا الشرح الوافي. أشعر أنني أصبحت أكثر قدرةً على استيعاب مفهوم "التحيز الاستقرائي" ودوره في بناء نماذج تنبؤية جيدة.

الدكتور علاء (بابتسامة وديّة): عفوّاً يا حوراء. سررتُ بمناقشتك. أتمنى لك التوفيق.
إلى اللقاء في المرة القادمة.

حوراء (تلوّح بيدها مغادرة): إلى اللقاء دكتور علاء. شكرًا مجددًا.

الحوارية الحادية عشر: كيف يعمل تعلم الآلة (2)

حوراء (تدخل إلى مكتب الدكتور علاء وعلى ملامحها حماس ورغبة في الاستزادة): مرحبًا دكتور علاء. لقد قرأت نصًّا جديدًا حول التحيز الاستقرائي وضرورته في تعلم الآلة، وتحدّث النصّ أيضًا عن "شفرة أوكام" وأهمية اختيار النماذج الأبسط. أريد أن أناقش معك بعض النقاط التي لفتت نظري.

الدكتور علاء (يبتسم ويدعوك للجلوس): أهلاً بك يا حوراء. يسعدني مواصلة هذا الحوار معك. أخبريني عمّا لديك من تساؤلات.

حوراء (تقلب في صفحاتها): أشار النص إلى أن جميع طرق التعلم تنطوي على شكل من أشكال التحيز الاستقرائي، لأننا نريد تعميم ما تعلمناه من مجموعة محدودة من الأمثلة إلى أمثلة جديدة. بدونها، لا يمكننا اختيار نموذج معيّن من بين عددٍ هائل من النماذج المحتملة، وقد نبقى عند مستوى "التذكر" فقط بدون تعميم.

الدكتور علاء (يهزّ رأسه موافقًا): صحيح تمامًا. الفكرة الأساسية: لا يمكننا تعلّم نموذجٍ قادر على التنبؤ ببياناتٍ جديدة من أمثلة محدودة إلا إذا افترضنا بعض الافتراضات المسبقة عن شكل النموذج أو عن القواعد التي تُحكم سلوك البيانات. هذه الافتراضات تمثّل "التحيز الاستقرائي". من دونها، يكون الأمر أقرب إلى التخمين الأعمى عند مواجهة بياناتٍ جديدة.

حوراء (تتابع بحماس): نعم، وذكر النصُّ أيضًا "شفرة أوكام Occam's Razor" التي تقول إنه من الأفضل اختيار أبسط فرضية لشرح أي ظاهرة. واعتبرها نوعًا من أنواع التحيز الاستقرائي الذي يفضل النماذج الأبسط طالما أدائها مقبول.

الدكتور علاء (يبتسم ويشير إلى سبورة قريبة): بالضبط. "شفرة أوكام" فلسفة قديمة تفضّل التفسيرات الأبسط. وفي سياق تعلم الآلة، هذه الفلسفة يمكن تفسيرها هكذا:

إذا لدينا نموذجين يمتلكان نفس الأداء تقريبًا، نختار النموذج الأبسط، أو الذي يمكن تفسيره وفهمه بسهولة أكبر. وهذا ينعكس على تفضيل خوارزميات أو نماذج أقل تعقيدًا (مثلًا شجرة قرار بسيطة بدلًا من شجرة عملاقة).

حوراء (تدوّن بعض النقاط): وقد أكّد النصّ على أنه لا بد من الموازنة بين البساطة والدقة. فلو أضف نصفًا بالمئة زيادة في الدقة قيمةً بملايين الدولارات - مثلًا في شركةٍ ضخمة - فقد نضطر لقبول نموذج أكثر تعقيدًا وإن كان أصعب في التفسير.

الدكتور علاء (بشيءٍ من الواقعية): صحيح. في المشاريع العمليّة، نتعامل دومًا مع المقايضات (Trade-offs). إن كانت زيادة طفيفة في الدقة تُحدث فرقًا ماليًا أو تشغيليًا كبيرًا، قد نتحمّل تعقيدًا إضافيًا في النموذج. المهم أن نفهم أن "الأبسط هو الأفضل" ليست قاعدة مطلقة؛ بل إننا نلجأ إليها عندما يؤدي النموذجان نفس العمل تقريبًا، فنختار الأنسب للصيانة والتفسير.

حوراء (تراجع النصّ مجددًا): أعجيني ما ذكره النصّ أيضًا عن ضرورة فهم مساحة المشكلة جيدًا لتحديد ما يُقصد بـ"دقيق بما يكفي". لأننا إن بالغنا في تبسيط النموذج دون وعي، قد نضحي بدقة مهمة. وفي حالات أخرى، قد نحتاج أصلًا لسرعة وتفسيرية أكثر من أقصى قدرٍ من الدقة.

الدكتور علاء (بإيماءة تقدير): بالضبط. لذلك يبدأ أغلب علماء البيانات بتحديد الأهداف التجارية أو العملية (مثلًا نسبة الخطأ المقبولة أو معدّل الاكتشاف المطلوب)، ثم يحددون مقياس التقييم الأنسب (Accuracy, F1-score, Precision/Recall... إلخ). بعد ذلك ينظرون إذا كانت النماذج الأبسط تفي بالغرض. إن كانت كذلك، فهي تُعد اختيارًا ممتازًا.

حوراء (تبتسم وهي تسأل): هل لك أن تعطيني مثالًا عمليًا شائعًا على تطبيق "شفرة أوكام" في المشاريع الواقعية؟

الدكتور علاء (يفرك ذقنه مفكرًا): مثال بسيط: عندما نبني نموذج تصنيف في شركة تأمين لتحديد العملاء المعرضين لخطر عدم الدفع، قد نبدأ بنموذج لوجستي بسيط (Logistic Regression)، لأنه قابل للفهم والتفسير: نعرف بالضبط الأوزان (Coefficients) المرتبطة بالميزات، ونفهم العلاقة بينها وبين النتيجة. إذا حقق هذا النموذج دقة أو AUC (مساحة تحت منحنى ROC) جيدة بما يكفي بحاجات الشركة، يُصبح خيارًا ممتازًا. أما لو اكتشفنا أن زيادة 2% في الدقة عبر نموذج معقد مثل شبكة عصبية ضخمة سوف تُوفّر ملايين الدولارات، عندها قد نغامر بتبنيّه رغم صعوبة تفسيره.

حوراء (تجمع أوراقها وتبدوراضية): شكرًا جزيلاً يا دكتور علاء. باتت الصورة أوضح حول ضرورة التحيز الاستقرائي، وكيف نطبّق شفرة أوكام في تعلم الآلة. وسأكون حريصة على فهم الأهداف التجارية قبل تقرير ما يعنيه "النموذج الأبسط" أو "الدقيق بما يكفي".

الدكتور علاء (يستند إلى كرسيه ويبتسم مشجعًا): عفوًا يا حوراء. أرى أنك تتقدّمين بثبات في فهم جوهر تعلم الآلة. تذكّري دائمًا أن الفهم الواضح لمساحة المشكلة والمقاييس المرجوة هو الأساس في اختيار النموذج المناسب. أتمنى لك التوفيق، وأنا بانتظار أسئلتك القادمة.

حوراء (تلوّح مودّعة): شكرًا لك دكتور، أراك قريبًا في المحاضرة القادمة!

الدكتور علاء (بصوت ودّي): إلى اللقاء يا حوراء، بالتوفيق.

الحوارية الثانية عشر: تطبيقات تعلم الآلة

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

حوراء (تدخل وفي يدها بعض الملاحظات): مرحبًا دكتور علاء، عدت اليوم وفي جعبتي أمثلة عديدة لتطبيقات تعلم الآلة في الحياة العملية. قرأت نصًّا مختصرًا حول بعض هذه التطبيقات وأود مناقشتها معك. فقد لاحظت أن تعلم الآلة بدأ يتغلغل في كل جانب من جوانب حياتنا تقريبًا.

الدكتور علاء (يبتسم مشيرًا لها بالجلوس): أهلاً حوراء. بالفعل، تعلم الآلة بات عنصرًا أساسيًا في التقنيات المعاصرة. تفضلي وابدئي بما تريدين مناقشته.

حوراء (تقرأ من ملاحظاتها): أول تطبيق ذكره النص هو التعرف على الصور. فهتمت أنه أحد التطبيقات الأكثر شيوعًا للتعلم الآلي، حيث يتم تدريب النماذج على تحديد الأشياء أو الوجوه أو الأماكن في الصور. كنت أتساءل: هل يدخل في تطبيقات التعرف على الصور أيضًا أمورٌ مثل تحديد الأمراض من صور الأشعة؟

الدكتور علاء (بتأييد): نعم بالتأكيد. فتقنية التعرف على الصور لا تقتصر على تمييز الأشخاص أو الأشياء الشائعة، بل تشمل أيضًا المجال الطبي. على سبيل المثال، في تشخيص الأشعة السينية أو الرنين المغناطيسي، تتعلم الخوارزميات رصد الأورام أو التشوهات عبر مقارنتها بقاعدة بيانات لصورٍ سابقة. كما يُستخدم التعرف على الصور في السيارات ذاتية القيادة لتحديد العوائق والإشارات المرورية وغيرها.

حوراء (تتحول إلى نقطة أخرى): ثاني تطبيق تحدث عنه النص: التعرف على الكلام أو تحويل الكلام المنطوق إلى نص. في هواتفنا الذكية، يمكننا إعطاء أوامر صوتية أو كتابة الرسائل صوتيًا. هل يعتمد هذا التطبيق غالبًا على الشبكات العصبية؟

الدكتور علاء (يفرك ذهنه مفكرًا): صحيح، حوراء. معظم أنظمة التعرف على الكلام الحديثة تستخدم تقنيات الشبكات العصبية العميقة (Deep Neural Networks) أو نماذج تحويل (Transformers) لتحليل الموجات الصوتية وتحديد الكلمات المنطوقة. وتحسنت دقة هذه النماذج كثيرًا في السنوات الأخيرة، خاصة مع توفر بيانات تدريب ضخمة وأجهزة حاسوبية سريعة.

حوراء (تقرأ ما دونته): ثم ذكر النص اقتراح المنتجات كتطبيق مهم للتعلم الآلي. حقا نلاحظه يوميًا في مواقع التسوق الإلكتروني، أو حتى في منصات بث الأفلام والموسيقى التي ترشح لنا ما قد نحب مشاهدته. كيف يتم بناء هذه الأنظمة؟

الدكتور علاء (موضِّحًا): تعتمد أنظمة التوصية Recommendation System على تحليل سلوك المستخدمين السابق وأنماط الشراء أو الاستهلاك لديهم، ثم توفّر توصيات بناءً على تشابه المستخدم أو المنتج مع آخرين. تستعمل خوارزميات شهيرة مثل "عامل التصفية التعاوني (Collaborative Filtering)" أو "نظام التوصية القائم على المحتوى (Content-based Recommender)"، بالإضافة إلى نماذج عميقة (Deep Learning) لتعلم تفضيلات المستخدم بدقة أعلى.

حوراء (تلوح بيدها وهي تتذكر أمرًا ما): أما ترجمة اللغة، فكلنا نستخدمها تقريبًا في تطبيقات كـ Google Translate. النص أشار إلى (GNMT) وهو نموذج تعلم الآلة العصبي من جوجل. هل يعتمد ذلك على شبكة عصبية خاصة بالترجمة مثل Seq2Seq؟

الدكتور علاء (يومئ موافقًا): نعم، "GNMT" هو اختصار لـ Google Neural Machine Translation، وهو نظام يقوم على الشبكات العصبية العميقة، تحديدًا نموذج تسلسل-إلى-تسلسل (Sequence-to-Sequence) مع آليات الانتباه (Attention). يُحطّم الجمل إلى تمثيلات داخلية بلغتها الأصلية، ثم يُعيد تركيبها في اللغة الهدف بجودة عالية نسبيًا.

حوراء (تشير إلى جزء من النص): تطرق النص أيضًا إلى الخدمات المالية واستعمال المصارف للتعلم الآلي في اكتشاف الاحتيال وتحليل المخاطر. هل هذا يعني تحليلات الائتمان مثلًا، أو توقع احتمالية تعثر العملاء في السداد؟

الدكتور علاء (يبتسم): بالضبط. تستخدم المؤسسات المالية النماذج التنبؤية لمعرفة "درجة المخاطرة" لشخصٍ يريد قرضًا مثلًا، فتُقيّم ملفه بناءً على سجلاته المالية والسلوكيات السابقة. كما تُستخدم خوارزميات الكشف عن الاحتيال في متابعة الحركات المالية غير الاعتيادية. إذا لاحظ النظام نمطًا غريبًا لبطاقة ائتمانية، فإنه يُطلق تنبيهًا تحسبًا لكونها عملية احتيال.

حوراء (تتساءل بنبرة فضولية): لم أكن أعلم أن تعلم الآلة يُستخدم في قطاع النفط والغاز بهذا الشكل. النص يقول إنه يُستعمل في البحث عن مصادر الطاقة الجديدة، وتحليل المعادن، والتنبؤ بفشل المستشعرات في مصافي التكرير. كيف يتم ذلك؟

الدكتور علاء (يوضح): تعتمد شركات النفط والغاز على نماذج لتحليل البيانات الجيولوجية، والاستدلال على أماكن وجود الخام بالاستناد إلى أنماط جيولوجية معقدة. كما تُراقب المستشعرات في منصّات الحفر أو المصافي لالتقاط الإشارات المبكرة على احتمالية الفشل أو الأعطال، ثم تتدخل استباقيًا. هذا كله يُزيد من الكفاءة ويُقلل التكاليف.

حوراء (تذكر مثالاً من النص): أيضاً ذكر النص المواصلات واستخدام التحليلات لتبسيط الطرق وتوقع مشكلات الربحية المحتملة لشركات الشحن أو النقل العام. فبالنظرة يتعمدون على بيانات كبيرة حول حركة المركبات والمسارات والزحام؟

الدكتور علاء (مؤكدًا): صحيح، خوارزميات تعلم الآلة تساعد في التنبؤ بأوقات الذروة أو الاختناقات المرورية، وتخطط مسارات أكثر كفاءة لتقليل استهلاك الوقود أو وقت التوصيل. أمّا شركات النقل العام فربما تستعين بالتحليلات لتوزيع الحافلات وتقليل وقت الانتظار ونفقات التشغيل.

حوراء (بإعجاب): الخاتمة كانت الرعاية الصحية. لا شك أنه مجال حيويّ، خاصةً مع توفر أجهزة قابلة للارتداء تجمع بيانات صحية كثيرة. في النص قيل إن أنظمة تعلم الآلة يمكنها التنبؤ بالحالة الصحية وتقديم توصيات لتحسين سلوك الفرد.

الدكتور علاء (يلتفت إلى شاشة عرض بجانبه): نعم. في المجال الصحي، تعلم الآلة لديه تطبيقات واسعة. مثل التشخيص بمساعدة الحاسوب، ودعم الأطباء في اتخاذ قراراتٍ أسرع وأدق، وتخصيص الخطط العلاجية تبعًا لجينات المريض أو تاريخه الطبي. ومع البيانات الضخمة القادمة من أجهزة الاستشعار، تستطيع النماذج مراقبة مؤشرات المريض الحيوية باستمرار، وإطلاق تنبيهات إذا كانت الأرقام تنحرف عن المعدل الطبيعي.

حوراء (تجمع أوراقها وتنظر للدكتور علاء بابتسامة): شكرًا جزيلاً لك دكتور. اكتشفت من هذا النص أن تعلم الآلة في كل مكان من حولنا؛ من هواتفنا وأجهزة ترجمة اللغة إلى القطاعات الضخمة كالنفط والغاز والنقل. يبدو أنه سيزداد انتشارًا في المستقبل أكثر فأكثر.

الدكتور علاء (يبتسم مشجعًا): هذا صحيح، حوراء. تعلم الآلة أصبح أحد المحركات الرئيسية للتطور التكنولوجي في معظم المجالات. اطلّعي دائمًا على الأبحاث والدراسات

الحديثة لتشاهدي كيف تُطبّق هذه التقنيات بطرق أكثر ابتكارًا. وإذا كان لديك أي أسئلة لاحقًا فأنا في خدمتك.

حوراء (تلوّح بيدها مودّعة): شكرًا لك دكتور علاء. سأفعل بالتأكيد. إلى اللقاء في المحاضرة القادمة.

الدكتور علاء (بصوت ودّي): إلى اللقاء يا حوراء، بالتوفيق في دراستك وأبحاثك.

الحوارية الثالثة عشر: علاقة تعلم الآلة بالتخصصات الآخري

(مكتب الدكتور علاء طعيمة في الجامعة. تجلس حوراء أمامه ويدها دفتر ملاحظات. قررت حوراء هذا اليوم مناقشة علاقة تعلم الآلة بالتخصصات الآخري بالتفصيل مع الدكتور علاء طعيمة)

حوراء (تدخل على الدكتور علاء وعلى ملامحها علامات التأمل): مرحبًا دكتور علاء، قرأت نصًا حول العلاقة بين تعلم الآلة ومجالات أخرى مثل الذكاء الاصطناعي والتنقيب في البيانات والإحصاء. أود أن أواصل حوار معك اليوم لمناقشة هذه الروابط والتداخلات.

الدكتور علاء (يستقبلها بابتسامة): أهلاً بك يا حوراء. نعم، تعلم الآلة حقل متعدد التخصصات يرتبط بمجالات عدة، وهو ما يجعل فهم العلاقات بينه وبين الذكاء الاصطناعي والتنقيب في البيانات والإحصاء مهمًا جدًا. تفضّلي، اطرحي ما لديك من أسئلة.

حوراء (تنظر في ملاحظاتها): في النص، تم تعريف الذكاء الاصطناعي بأنه "محاكاة السلوك البشري أو التفكير البشري بواسطة برنامج حاسوبي"، واعتبره مجالًا أوسع من تعلم الآلة. بل وقيل إن تعلم الآلة هو مجموعة فرعية رئيسية منه. ما السبب في أن تعلم الآلة أصبح أحد اللبنة الأساسية للذكاء الاصطناعي؟

الدكتور علاء (يُومئ بالإيجاب): لأن تعلم الآلة يوفّر الآلية العملية لجعل الآلة "ذكية"؛ بمعنى أنها تستطيع تعديل سلوكها أو قراراتها بالاعتماد على البيانات والتجربة، بدلاً من مجرد اتباع قواعد مبرمجة ثابتة. لذا يُعدُّ تعلم الآلة الداعم الأساسي للكثير من تقنيات

الذكاء الاصطناعي الحديثة، مثل فهم اللغة الطبيعية أو التعرف على الصور أو حتى قيادة السيارات ذاتياً.

حوراء (متفكرة): إذًا تعلم الآلة يجعل الذكاء الاصطناعي يخرج من مفهوم "كود يشبه الذكاء" إلى قدرة فعلية على التحسين الذاتي بناءً على بيانات وخبرة. جميل.

حوراء (تنتقل للنقطة التالية): أما عن التنقيب في البيانات، فالنصّ ذكر أنه يستخدم تقنياتٍ شبيهة بتعلم الآلة لاستخراج المعرفة من قواعد البيانات الكبيرة. كما أشار إلى فروق بينهما، أبرزها أن التنقيب في البيانات يحتاج تدخلًا بشريًا لاكتشاف الأنماط، بينما تعلم الآلة يعتمد على النماذج التي تتعلم وتتنبأ تلقائيًا. هل يمكنك إيضاح هذه النقطة؟

الدكتور علاء (بشرح وافٍ): بالتأكيد. في التنقيب في البيانات (Data Mining)، نميل إلى التركيز على اكتشاف المعلومات المخفية أو الأنماط الجديدة في مجموعة بيانات ضخمة، ويظلّ الخبير البشري مشرفًا على العملية لفهم نتائج التنقيب وتفسيرها. أما في تعلم الآلة، فنركّز على بناء نماذج تتنبأ وتتعلّم تلقائيًا—وغالبًا ما تكون هذه النماذج قادرة على تحسين أدائها مع الوقت عند وصول بيانات جديدة (إن كان ذلك ضمن سيناريو أونلاين). لذا العنصر البشري حاضر أكثر في التنقيب في البيانات، بينما في تعلم الآلة، نسعى لتقليل التدخل البشري إلى أدنى حدّ ممكن بعد مرحلة بناء النموذج.

حوراء (بابتسامة تعجب): فهمت. ومع ذلك، هناك تدخل كبير؛ قد يستخدم التنقيب في البيانات خوارزميات تعلمٍ خاضع للإشراف أو غير خاضع للإشراف للبحث عن تلك الأنماط في البيانات.

حوراء (تراجع النصّ لتلخص): ذكر النصّ بعض الفروق الأساسية بين التنقيب في البيانات وتعلم الآلة:

1. التطبيق: يحتاج تعلم الآلة عادةً بياناتٍ منظمةٍ كثيرًا وكبيرة الحجم، بينما التنقيب في البيانات قد يتعامل مع بيانات أقل أو أقل تنظيمًا.
2. المفاهيم: تعلم الآلة مبني على فكرة تحسين النموذج تلقائيًا من خلال البيانات (التجربة)، أما التنقيب في البيانات فيكتشف الأنماط من خلال عمليّة استكشاف.
3. التنفيذ: تعلم الآلة يستخدم خوارزميات ذكية (كالانحدار الخطي والشبكات العصبية) لتركيز الجهد على التنبؤ، بينما التنقيب في البيانات قد يستخدم أدوات تشمل قواعد بيانات وتقنيات تقييم الأنماط.
4. القدرة على التعلّم: تعلم الآلة مؤتمت أكثر، يتعلم ويستجيب ويتكيّف. التنقيب في البيانات يعتمد على التحليل البشري لاستخلاص الرؤى.
5. العامل البشري: في التنقيب في البيانات، التدخل البشري واضح (إعداد البيانات، تحديد الهدف، تفسير النتائج). أما في تعلم الآلة، نحاول جعل العملية أكثر اعتمادًا على الآلة وأقل على التدخل البشري المباشر.

الدكتور علاء (موافقًا): صحيح جدًا. رغم هذا التمييز، ففي مشروع بياناتٍ عمليّ كبير، قد يندمج كلا النهجين: قد نستخدم التنقيب في البيانات لاستخلاص ميزات أو أنماط معيّنّة، ثم نُطعمها لنموذج تعلم آلي للحصول على نظام تنبؤي أكثر دقة.

حوراء (تحولّ الحديث إلى الجزء الأخير): النصّ أوضح العلاقة بين تعلم الآلة والإحصاء. وذكر أنهما مرتبطان، لكن هدف الإحصاء هو تعميم استنتاجات من عيّنة تمثيلية، بينما تعلم الآلة يهدف للتنبؤ المستمر بالاعتماد على العثور على أنماط في البيانات، وغالبًا يتطلب بيانات أكبر لتدريب النماذج. هل هذا هو الاختلاف الجوهرى؟

الدكتور علاء (يرفع إصبعه موضحًا): نعم. في الإحصاء الكلاسيكية، نستخدم أساليب كالاستدلال (Inference) لبناء نموذج يشرح أو يفهم العلاقة السببية أو الارتباطية بين متغيرات قليلة، مع الحرص على قوة التعميم من عيّنة تمثيلية. أما في

تعلم الآلة، فنحن أكثر تركيزاً على دقة التنبؤ (Accuracy) بدلاً من التفسير، وغالباً ما نتعامل مع عدد ضخم من الميزات (Features) والبيانات. هذا لا يعني انعدام التفسير في تعلم الآلة، لكنه أقل أولويةً مقارنةً بالنتيجة التنبؤية.

حوراء (تدوّن بعض الأفكار): وبالتالي، يمكن القول إن الإحصاء وتعلم الآلة يتشاركان المفاهيم الرياضية (مثل الانحدار والاحتمالات والتوزيعات) لكن أهدافهما في البحوث والمشاريع التطبيقية قد تختلف.

حوراء (تبتسم راضية): ممتاز، أشكرك دكتور علاء. أصبحت لدي صورة أعمق حول العلاقات والتداخلات بين تعلم الآلة والذكاء الاصطناعي والتنقيب في البيانات، بالإضافة إلى اختلافه عن الإحصاء. سأطلع أكثر على أمثلة عملية تجمع بين هذه المجالات، فقد فهمت الآن أن الخطوط بينها ليست حادة تمامًا.

الدكتور علاء (يبتسم مشجعاً): بالضبط يا حوراء، ستجدين الكثير من المشاريع التي تدمج الذكاء الاصطناعي وتعلم الآلة والتنقيب في البيانات والإحصاء معاً. دراسة هذه الروابط يساعدك على فهم أوسع وإيجاد أفضل الحلول في المشاريع الواقعية.

حوراء (تلوّح مودّعة): شكراً لك دكتور، سأعود إذا طرأت لي أي استفسارات جديدة. إلى اللقاء.

الدكتور علاء (مودّعاً بابتسامة): إلى اللقاء حوراء، موفّقة دائماً.

الحوارية الرابعة عشر: أدوات وبيئة العمل لتعلم الآلة (1)

(مكتب الدكتور علاء طعيمة في الجامعة، تجلس حوراء أمامه ويدها دفتر ملاحظات. ترغب حوراء هذا اليوم في فهم أدوات وبيئة العمل لتعلم الآلة بعناية).

حوراء (تدخل على الدكتور علاء وفي يدها ملاحظات جديدة): مرحبًا دكتور علاء، لدينا نص يتحدث عن أدوات وبيئات العمل الخاصة بتعلم الآلة، وأريد أن أناقشه معك كي أفهم كيفية اختيار البيئة المناسبة ومدى أهميتها في تبسيط عملية بناء النماذج ونشرها.

الدكتور علاء (يبتسم ويرحب بها): مرحبًا بك يا حوراء. بالفعل، بيئات وأدوات تعلم الآلة تلعب دورًا مهمًا في تسهيل حياة المبرمجين وعلماء البيانات. فما النقاط التي أثارت انتباهك في النص؟

حوراء (تتفحص ملاحظاتها): أولاً، يتحدث النص عن أن بيئة تعلم الآلة هي واجهة أو أداة تسمح ببناء ونشر النماذج بسهولة وسرعة، دون الحاجة إلى الخوض في تفاصيل البنية التحتية أو الخوارزميات منخفضة المستوى. ما الذي يجعل هذه البيئة "فعالة" بالضبط؟

الدكتور علاء (شارحًا): من وجهة نظري، البيئة الفعالة للتعلم الآلي يجب أن تُوفّر عدة جوانب:

1. سهولة الاستخدام: واجهة أو مكتبات بسيطة للمبرمجين تسرع عملية التطوير.
2. قابلية التوسع: إمكانية التعامل مع كميات كبيرة من البيانات، وربما المعالجة الموزعة أو دعم وحدات معالجة الرسوم GPU.
3. الأداء العالي: الاستفادة من أحدث الخوارزميات والمكتبات المحسّنة.

4. المرونة: تسهيل العمل بلغات برمجة مختلفة أو منصّات عدّة.
5. الدعم المجتمعي: وجود مجتمع قوي، وأدلة توثيق، ومصادر تعليمية.

إذا توفرت هذه الجوانب في بيئة العمل، أصبح بناء النماذج الآلية وصيانتها أكثر سهولة.

حوارة (تشير للنص): كما أشار النص إلى "انفجار" في عدد الأدوات والنظم الأساسية التي تدعم الذكاء الاصطناعي وتعلم الآلة. فلدينا حاليًا عدد كبير من المكتبات مثل TensorFlow و PyTorch و scikit-learn وغيرها. ما الذي يجب أخذه بالاعتبار عند اختيار أداة محددة من بينها؟

الدكتور علاء (يفكر لبرهة): هناك عدة اعتبارات، منها:

1. نوع المهمة: هل أنت مهتمة بالتعلّم العميق (Deep Learning) أم تعلم الآلة التقليدي (مثل أشجار القرار، والانحدار، وغيرها)؟ أدوات مثل TensorFlow و PyTorch تميل لتكون ممتازة في التعلّم العميق، بينما scikit-learn قوية في خوارزميات التعلّم التقليدي.
2. لغة البرمجة المفضلة: بايثون هي اللغة الأكثر انتشارًا حاليًا في علم البيانات، لكن قد يحتاج البعض إلى Java أو Scala في مشاريع Big Data، أو R في بعض التطبيقات الإحصائية.
3. أهداف المشروع: إذا كنت تهتمين بسرعة النمذجة وبساطة الأكواد، فقد تختارين أداة توفر واجهات برمجة سهلة (مثل Keras فوق TensorFlow). أما إذا كنت بحاجة لتحسينات شاملة في المعاملات أو ترغب في تحكّم أدقّ، فقد تتجهين لـ PyTorch أو أطر عمل أخرى.

4. الدعم السحابي والتوزيع: بعض المنصات أو الأدوات تتكامل بسلاسة مع خدمات سحابية مثل AWS أو GCP أو Azure ، فتسهّل عمليات النشر والتدريب الموزّع.

حوراء (تقرأ فقرة من النص): النص ذكر نقاطاً أساسية للاعتبار:

1. إن كان المشروع يركّز على التعلم العميق أم الخوارزميات التقليدية.
2. لغة البرمجة المفضلة.
3. البنية التحتية والأجهزة المستخدمة في القياس.
4. طرق تحسين المعاملات الفائقة (Hyperparameters) بين ما هو تلقائي وما هو يدوي.
5. قابلية التوسع في مرحلتي التدريب والتطوير.

الدكتور علاء (يرفع إصبعه مؤكداً): بالضبط. هذه النقاط تُلخّص معظم العوامل العملية. مثلاً، إذا كنا نطوّر تطبيقاً للتعرف على الصور بدقة عالية جداً باستخدام شبكات عصبية عميقة، قد نتجه إلى TensorFlow أو PyTorch لدعمهما القوي في هذا المجال. أمّا لو كنا نطوّر نموذجاً بسيطاً (كتصنيف نصي باستخدام Logistic Regression)؛ فمن الممكن أن نجد في scikit-learn كل ما نحتاجه بسرعة.

حوراء (تنظر إلى إحدى الفقرات في النص): أيضاً أوضح النص أن بايثون أخذت الصدارة في السنوات الأخيرة، بينما R ، رغم أنها كانت مفضّلة عند الإحصائيين، ليست مريحة بنفس القدر لمعظم المطورين. هذا صحيح؟ ولماذا هذا التحوّل نحو بايثون؟

الدكتور علاء (يجيب بسلاسة): بايثون لغة عامة أكثر سلاسة وذات بناء نحوي بسيط. كما أنها تمتلك مكتبات هائلة للتعلم الآلي وتحليل البيانات (مثل NumPy و pandas و scikit-learn و TensorFlow) مجتمعها كبير جداً، ويقدم دعماً مكثفًا عبر الإنترنت. لهذا باتت اللغة الافتراضية في مشاريع الذكاء الاصطناعي. على الجانب الآخر،

R ما زالت ممتازة للأعمال الإحصائية والأكاديمية، لكنّ بايثون تفوق عليها في سهولة التطوير والدمج مع أنظمة الإنتاج.

حوراء (تسأل بلهفة): النص أكد على أهمية ضبط المعاملات الفائقة (Hyperparameter Tuning). كيف يؤثر ذلك في اختيار بيئة تعلم الآلة؟

الدكتور علاء (بوضوح): تختلف الأدوات في مدى سهولة أو تلقائية عمليات البحث في المعاملات الفائقة. بعض البيئات توفر AutoML أو وظائف مدمجة للبحث الشبكي (Grid Search) أو البحث العشوائي (Random Search) أو تحسين بايزي Bayesian Optimization. فإذا كان المشروع يتطلب الكثير من تجارب الضبط للمعاملات، ستحتاجين بيئة عمل تدعم ذلك بسلاسة—أو على الأقل تكامل سهل مع مكتبات خارجية مخصصة للغرض.

حوراء (بفضول): ماذا عن "قابلية التوسّع (Scalability)"؟ كيف نختار بيئة عمل ملائمة للتدريب على بيانات ضخمة، ثم نشر النموذج لخدمة آلاف أو ملايين المستخدمين؟

الدكتور علاء (بلهجة خبيرة): الحاجة للتوسّع تأتي في مرحلتين:

1. مرحلة التدريب: قد تحتاجين أجهزة متعددة أو معالجات رسوم GPU أو منصّة سحابية تدعم توازي العمليات. بعض الأدوات تسمح بتدريب موزّع Distributed Training تلقائيًا.
2. مرحلة النشر: هل البيئة تدعم نشر النموذج بسهولة على سحابة AWS أو Google Cloud أو Azure؟ هل لديها قدرات API؟ هل يمكنها التعامل مع آلاف الطلبات في الثانية؟ كل هذا يدخل في اختيارك. أحيانًا ندرّب النموذج في بيئة (مثلًا notebook بايثون) ثم ننقله لنشره في بيئة أخرى (مثلًا Kubernetes مع

منصة سحابية)، لذا من المهم أن نعرف إن كانت الأداة تدعم كلا السيناريوهين بسلاسة.

حواء (تجمع أوراها): شكرًا لك دكتور علاء على هذه المعلومات. لقد اتضح لي أن اختيار بيئة العمل لا يتوقف على "اسم مشهور" أو "أداة واحدة تناسب الجميع". بل يجب النظر إلى متطلبات المشروع—نوع الخوارزميات، لغة البرمجة، قابلية التوسع، والكثير من التفاصيل الأخرى.

الدكتور علاء (بابتسامة تشجيع): بالضبط، هذا هو المغزى. دائمًا أسأل نفسي: ما احتياجات مشروعك؟ ما نوع النماذج؟ ما الموارد المتاحة؟ أجيب عن هذه الأسئلة بدقة قبل اختيار البيئة. هكذا تضمنين أن تكون أداة تعلم الآلة عونًا لك لا عبئًا إضافيًا.

حواء (تلوّح مودّعة): أشكرك مرة أخرى دكتور. سأطبّق هذه المعايير في مشروعك القادم بإذن الله. إلى اللقاء في المحاضرة التالية.

الدكتور علاء (بصوت ودي): في أمان الله، حواء. بالتوفيق في مشروعك، وأنا بانتظار نتائجك.

الحوارية الخامسة عشر: أدوات وبيئة العمل لتعلم الآلة (2)

حوراء (تدخل وفي يدها أوراق عليها أسماء عدة أدوات للتعلم الآلي): مرحبًا دكتور علاء، عدتُ اليوم ومعني نصّ يتحدث عن أشهر أدوات تعلم الآلة المستخدمة حاليًا، مثل SciKit-Learn و PyTorch و TensorFlow و Keras و Google Colab. أريد أن أسمع رأيك حول متى قد نستخدم كل أداة، وما يميزها عن غيرها.

الدكتور علاء (يستقبلها بابتسامة): أهلاً بك يا حوراء. رائع أنك تسعين للتعرف على هذه الأدوات. كلُّ منها يلبي احتياجات محددة في بناء نماذج تعلم الآلة، وسأحاول أن أوضح لك نقاط القوة لكل واحدة منها.

حوراء (تنظر في ملاحظاتها عن SciKit-Learn): تقول الملاحظات إن SciKit-Learn مكتبة قديمة نسبيًا، ظهرت عام 2007، وهي خيار ممتاز لتطبيق خوارزميات تعلم الآلة التقليدية مثل الانحدار والشجرة العشوائية ودعم المتجهات وغيرها. لا يحتاج عادةً إلى وحدات معالجة الرسوم (GPU)، لأنه لا يدعم التعلم العميق بشكل مباشر.

الدكتور علاء (مؤكدًا): صحيح SciKit-Learn. ممتازة للمهام الكلاسيكية في التصنيف أو الانحدار أو التجميع. توفر دوال معالجات مسبقة للبيانات (Preprocessing) وتشفير الميزات واختبار النماذج والتحقق المتبادل (Cross Validation) وضبط المعاملات الفائقة (Hyperparameters) بسهولة. غالبًا ما يبدأ المبتدئون بخوارزميات تعلم الآلة التقليدية من خلال هذه المكتبة.

حوراء (تقلب الصفحة): أما PyTorch فهو إطار قوي للبناء السريع للشبكات العصبية. طُوّر في مختبر أبحاث الذكاء الاصطناعي في فيسبوك عام 2016. مميزاته في

التعلم العميق وفي تطبيقات مثل رؤية الكمبيوتر (Computer Vision) ومعالجة اللغة الطبيعية (NLP). هل هو سهل الاستخدام حقاً؟

الدكتور علاء (يومي برأسه): نعم، أحد أسباب شعبية PyTorch هو سهولة بناء الشبكات العصبية باستخدام نمط برمجي أقرب إلى بايثون النقي (Pythonic). كما أنه يوفر مرونة كبيرة في تحديد بنية الشبكة وتحديثها أثناء التشغيل. بالإضافة لدعم وحدة المعالجة المركزية (CPU) ووحدة معالجة الرسوم (GPU) بكفاءة. يستخدمه الباحثون بكثرة في مجال الرؤية الحاسوبية وNLP.

حوراء (تقرأ ما كُتب عن TensorFlow): تقول الملاحظات إن TensorFlow أحد أشهر أطر التعلم العميق، طوره فريق Google Brain. يتميز بأنه يعمل على وحدات CPU وGPU وحتى TPU، كما يمكن نشر النماذج المدربة على أجهزة مختلفة، من الحواسيب إلى الهواتف وحتى المتصفحات. لكن البعض يشتكي أن تعلمه قد يكون صعباً.

الدكتور علاء (بتأييد): صحيح، TensorFlow منصة ضخمة ومتطورة جداً، تدعم التوزيع الواسع للتدريب (Distributed Training) وتشغيل نماذج متوازية. لكن واجهته البرمجية منخفضة المستوى (خاصة في الإصدارات الأولى) كانت صعبة بعض الشيء على المبتدئين. ومع ذلك، الإصدار 2 وما تلاه جعل الأمور أوضح باستخدام واجهة Keras المدمجة. يظل TensorFlow خياراً ممتازاً للمشاريع الكبيرة التي تتطلب تدريب موزع.

حوراء (بتحمس): إذن Keras هي واجهة عالية المستوى تعمل فوق TensorFlow. النص يقول إنها أسهل كثيراً في الكتابة والقراءة، مناسبة لتجارب النماذج السريعة أو النماذج الأولية (Prototyping). ومع ذلك، قد تكون أبطأ من PyTorch أو من TensorFlow المباشر، لكنها مناسبة للمبتدئين وللمشاريع الصغيرة أو المتوسطة.

الدكتور علاء (مشيرًا بيده مو أفقًا): تمامًا Keras مصممة لتبسيط بناء الشبكات العصبية العميقة وتقليل كمية الأكواد اللازمة. لذلك إذا أردت التركيز على الفكرة أو النموذج سريعًا دون الانشغال بالتفاصيل منخفضة المستوى، فإن Keras خيار رائع. أما إذا كانت مشاريعك معقدة جدًا أو تحتاج تحكّمًا أعمق في المعمارية أو الأداء، فيمكنك استخدام المزايا المضمّنة في TensorFlow أو PyTorch مباشرة.

حوراء (تقرأ القسم الأخير): أخيرًا، الملاحظات تتحدث عن Google Colab باعتباره خدمة سحابية من جوجل تتيح تشغيل دفاتر Jupyter عبر المتصفح، مع إمكانية الوصول إلى GPU و TPU مجانًا. كما أنه يأتي بمكتبات مثبتة مسبقًا. يعد خيارًا ممتازًا لمن ليس لديهم أجهزة قوية. صحيح؟

الدكتور علاء (يبتسم): بلا شك Colab. يُعد حلًا مثاليًا للتعلم والتجريب، خاصة لمن لا يتوفر لديهم حاسوب مزوّد بوحدة GPU. يمكنك التعاون مع الآخرين في ذات النوتبوك، تمامًا مثل مستندات جوجل. الميزة الأساسية فيه هي سهولة البداية وعدم الحاجة لتنصيب أي شيء محلي. لكن إن كنت بحاجة لمواصفات خصوصية عالية، أو تملك جهازًا فائقًا بمعالجة قوية، فقد تفضّل استخدام Jupyter Notebook محليًا.

حوراء (تحمل أوراها وهي تبتسم): شكرًا جزيلاً، دكتور علاء. الآن لدي تصور أوضح:

- أستخدم SciKit-Learn للمهام الكلاسيكية البسيطة والمتوسطة.
- TensorFlow و PyTorch للتعلم العميق بمشاريع متقدمة، مع تفضيل PyTorch للمرونة و TensorFlow للتوزيع الواسع ودعم TPU.
- Keras واجهة بسيطة فوق TensorFlow لاختصار بناء الشبكات العصبية.
- Google Colab لتجربة النماذج فورًا أونلاين بمزايا مجانية من GPU/TPU دون تعقيد.

الدكتور علاء (بصوت مشجّع): أحسنتِ يا حوراء، هذا ملخّص ممتاز. أتمنى لكِ التوفيق في استخدام كل أداة فيما يناسب حاجاتك. لا تترددي في السؤال إذا احتجتِ تفاصيل أخرى حول أيِّ منها.

حوراء (تلوّح مودّعة): شكراً دكتور. سأبدأ باستكشاف بعضها عملياً في مشاريعي. إلى اللقاء في المرة القادمة!

الدكتور علاء (بابتسامة ودّية): إلى اللقاء يا حوراء، بالتوفيق دائماً.

الحوارية السادسة عشر: قيود تعلم الآلة (1)

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

حوراء (تدخل على الدكتور علاء وعلى ملاحظها علامات الاهتمام): مرحبًا دكتور علاء، لقد قرأت نصًا حول قيود تعلم الآلة، وخاصةً ما يتعلق بالجانب الأخلاقي وقضية جودة البيانات. أودّ أن أستعرض معك أهم ما فهمته لأعرف وجهة نظرك.

الدكتور علاء (يرحّب بابتسامة): أهلاً حوراء. يسعدني دائمًا أن نستكمل حواراتنا حول جوانب الذكاء الاصطناعي وتعلم الآلة، بما فيها الجوانب الأخلاقية والتحديات التي نواجهها. تفضّلي.

حوراء (تقلب صفحاتها): أشار النص إلى مصطلح "اعتقاد البيانات (Dataism)" الذي ذكره ديفيد بروكس أولًا، وانتشر عن طريق المؤرخ يوفال نوح هراري. هذه الفكرة تفيد أننا أصبحنا نعتمد كثيرًا على الخوارزميات في اتخاذ قراراتنا. سؤالي: هل هذا الاعتماد على الخوارزميات يثير مخاوف أخلاقية معينة؟

الدكتور علاء (يفكر قبل الإجابة): بالتأكيد. الخوارزميات قد تُساعدنا في اتخاذ قرارات دقيقة وسريعة، لكنها في الوقت ذاته تطرح تساؤلات مثل: من يتحمّل المسؤولية إذا تعرّضنا لخطأ؟ من يضمن العدالة والشفافية في قرارات الخوارزمية؟ هذه كلها أمور أخلاقية حرجة. فعلى سبيل المثال، في مجال السيارات ذاتية القيادة، ثمة سيناريوهات "أخلاقية" حول من يُنقذ إذا كان هناك حادث لا مفر منه؟ وما المعايير التي يجب برمجة السيارة عليها؟ هذه الأسئلة ليست تقنية بحتة بل تتعلق بمنظومتنا الأخلاقية والقانونية.

حوراء (تتابع حديثها): أكد النص على أن البيانات هي قيد أساسي: إن لم تكن لدينا بيانات كافية أو كانت البيانات سيئة، سيقدم النموذج نتائج ضعيفة. وينطبق ذلك بصورة خاصة على الشبكات العصبية التي تحتاج كمًا هائلًا من بيانات التدريب. هل فعلاً الحل البسيط هنا هو "جمع المزيد من البيانات"؟

الدكتور علاء (بشيء من التحليل): غالبًا ما يكون الحل الأول في التعلم العميق هو زيادة عدد العينات التدريبية أو تحسين تنوع وجودة البيانات. لكن هناك حدود واقعية: فقد لا يتوفر المزيد من البيانات بسهولة، أو قد يكون جمعها مكلفًا. أحيانًا نلجأ لأساليب مثل **Augmentation** (توليد بيانات جديدة من البيانات المتاحة) لكن يظل ذلك محدودًا إذا كانت البيانات الأصلية ليست مناسبة أو متحيّزة (كما في المثال الذي ذكره النص حول سرطان الثدي وقلة بيانات النساء ذوات البشرة السوداء).

حوراء (بتعاطف): أعجبنى المثال الذي ضربه النصّ حول التنبؤ بسرطان الثدي عند النساء. قاعدة البيانات تحتوي غالبًا على صور أشعة سينية لنساء بيض، ما قد يؤدي إلى نموذج منحاز ضد النساء ذوات البشرة السوداء. كيف يمكننا معالجة هذه المشكلة؟

الدكتور علاء (شارحًا): الطريقة الأكثر مباشرة هي تحسين تمثيل البيانات في المجموعة التدريبية. وذلك يعني إضافة صور أشعة لمختلف الأعراق والفئات العمرية، وضمان أن تعكس البيانات الواقع المتنوع. كذلك قد نحتاج إلى ميزات (Features) إضافية توضح الفروق الصحية أو الجسدية بين الأعراق أو الفئات المختلفة. وفتيًا، يمكن للباحثين استخدام تقنيات تخفيف التحيز (Bias Mitigation) وأخذ العدل والإنصاف بعين الاعتبار عند بناء النموذج.

حواء (بصوت فيه حيرة): المقال ذكر سؤالاً جوهرياً: إذا حدث خطأ في قرارات الخوارزمية أو في نموذج تعلم آلي، فمن نلوم؟ هل نلوم المبرمج، أم صاحب الشركة، أم الخوارزمية نفسها؟

الدكتور علاء (بو اقعبة): هذا من أعقد التساؤلات. المسؤولية غالباً ما ترجع في النهاية للبشر الذين صمموا أو نشروا النظام. فالقانون لم يتعامل بعد بوضوح مع "شخصية اعتبارية" للخوارزميات. ما يحدث في المحاكمات الحالية (إذا حدثت أخطاء جسيمة) هو التحقيق في مدى اتباع الشركة أو المطور لإجراءات السلامة والأخلاقيات في تصميم الخوارزمية. وفي الوقت نفسه، هناك دعوات لإيجاد أطر قانونية جديدة تحدد المسؤولية بشكلٍ أدقّ في عصر الذكاء الاصطناعي.

حواء (تطرح تساؤلاً فلسفياً): النصّ قال بوضوح إن تعلم الآلة لا يستطيع إخبارنا بالقيم المعيارية التي يجب أن نتبناها في مواقف معينة. معنى ذلك أنه ما زال دور الإنسان ضرورياً؟

الدكتور علاء (يومئ برأسه مو افقاً): نعم. الآلة تتعلم نماذج إحصائية من البيانات، لكنها لا تستطيع أن تحدد قيمنا الأخلاقية أو تحدد متى يجب أن نضحي بجزء لصالح آخر مثلاً. هذه قرارات نابعة من الفلسفة والأخلاق والقانون، وليس من أنماط البيانات. بمعنى آخر، الخوارزمية "تتنبأ"، أمّا "ينبغي" أو "يجب" في المواقف الأخلاقية فهي أسئلة تخص الإنسان أولاً وأخيراً.

حواء (تجمع أوراقتها وهي تبتسم): شكراً دكتور علاء، أصبحت لديّ صورة أوضح حول قيود تعلم الآلة:

1. المسائل الأخلاقية في الاعتماد على الخوارزميات والمسؤولية عمّا تفعله.
2. الحاجة للبيانات الوفيرة والجيدة لضمان نتائج صحيحة وغير متحيزة.
3. تعلم الآلة لا يغني عن الأحكام الأخلاقية التي تقع في النهاية على عاتق البشر.

الدكتور علاء (يبتسم مشجعاً): رائع يا حوراء، هذا ملخص ممتاز. أمل أن يساعدك هذا النقاش على فهم الجانب الأخلاقي والتحديات العملية أمام تعلم الآلة، لا سيما عندما نتعامل مع بيانات ضئيلة أو متحيّزة. أتمنى لك التوفيق، وأنا بانتظار أسئلتك في المستقبل.

حوراء (تلوّح مودعة): سأعود قريباً بأسئلة أخرى. إلى اللقاء، دكتور.

الدكتور علاء (بصوت ودّي): في أمان الله يا حوراء. بالتوفيق!

الحوارية السابعة عشر: قيود تعلم الآلة (2)

حوراء (تدخل وعلى وجهها علامات التفكير): مرحبًا دكتور علاء، عدت ومعني نص جديد حول "قابلية التفسير" في تعلم الآلة والفرق بين النموذج القابل للتفسير والقابل للشرح. إضافةً إلى مفهوم "الصندوق الأسود" و"الصندوق الشفاف". أرغب في مناقشة هذه الأفكار معك لنضعها في سياق عملي.

الدكتور علاء (بيتسم مرحبًا): أهلاً حوراء. نعم، قابلية التفسير Expandability وقابلية الشرح Interpretability تعدّان من أهم التحديات في الذكاء الاصطناعي، خاصةً عندما نتحدث عن تطبيقات عالية الخطورة مثل الرعاية الصحية أو المالية. تفضلي، ما الأمور التي تودين التركيز عليها؟

حوراء (تقلب صفحات ملاحظاتها): يقول النص إن "النموذج القابل للتفسير" (Interpretability) هو الذي يمكن للإنسان فهمه دون أي مساعدة إضافية. أما "النموذج القابل للشرح" (Explainability) فهو أكثر تعقيدًا، ويحتاج وسائل أو خوارزميات أخرى لاستخلاص الكيفية التي توصل بها لقراره. هل يمكنك توضيح هذا التمييز بمثال؟

الدكتور علاء (يشير بيده مشيرًا إلى سبورة): طبعًا. مثلًا، خذي شجرة القرار: إنها نموذج قد نقول إنه "قابل للتفسير": فبوسعنا متابعة الفروع حتى نصل للورقة التي تُصدر القرار، وبذلك نستوعب تمامًا منطق التنبؤ. في المقابل، الغابة العشوائية (Random Forest) أو الشبكة العصبية تُعدّ نموذجًا "قابلًا للشرح" أكثر من كونه قابلًا للتفسير. لماذا؟ لأن حتى لو كانت الغابة العشوائية مجموعةً من أشجار القرار، إلا أن عدد الأشجار كبير، ومن الصعب فحص كل شجرة وفهم كيفية مزج أصواتها. فهنا نلجأ إلى طرق مثل Feature Importance أو SHAP أو LIME لنستخلص تفسيرًا عن كيفية عملها.

حوراء (تسأل باستفهام): وهذا يربطنا بمفهوم "الصندوق الأسود" مقابل "الصندوق الشفاف" (أو الأبيض). النص أوضح أن نموذج الصندوق الشفاف هو البسيط ذو عدد معاملات (Parameters) قليل جدًا، ونستطيع فهمه مباشرة (كالانحدار الخطي البسيط). أما الصندوق الأسود فهو الأكثر تعقيدًا كالشبكات العميقة أو الغابات العشوائية. لماذا صعوبة كهذه في فهم الصندوق الأسود؟

الدكتور علاء (بهدهوء): لأن الصندوق الأسود قد يمتلك أعدادًا هائلة من المعاملات أو يأخذ قراراته بناء على تفاعلات معقدة بين الميزات. مثلًا، شبكة عصبية عميقة (Deep Neural Network) قد تحوي ملايين من الأوزان. النظر إلى قائمة هذه الأوزان لا يكشف بسهولة المنطق الكامن وراء كل تنبؤ. ذلك سبب وصفه بـ "الصندوق الأسود": ندري ما المدخلات، ونعرف النتيجة، لكن المسار الداخلي شبه غامض للبشر ما لم نستخدم تقنيات شرح خاصة.

حوراء (تقرأ بصوت واضح): يذكر النص عدة أسباب لأهمية قابلية التفسير والشرح، منها الثقة، والشفافية، والتحيّز، والالتزام بالقوانين مثل قانون حماية البيانات الأوروبي GDPR في أوروبا. أيضًا في المجالات الحرجة كالرعاية الصحية، يريد الطبيب فهم مبررات قرار النظام قبل اعتماده. صحيح؟

الدكتور علاء (يومئ مو أفقًا): صحيح جدًا. لو أعطى نظامٌ طبي توصية بعلاج معيّن دون تفسيرٍ واضح، قد يتردد الطبيب في اتباعه بالكامل. يحتاج الطبيب معرفة العوامل التي أوصلت النموذج لتقريره. كذلك في عالم التمويل أو إقراض البنوك، لا بد من تفسير سبب رفض منح قرضٍ لمتقدم ما، خاصة إذا كانت هناك أسئلة قانونية بشأن التمييز والتحيّز.

حواء (تنظر إلى فقرة في النص): أشار النص إلى أن هناك نوعين من التفسير: تفسير عام (Global) يوضح سلوك النموذج ككل، وتفسير محلي (Local) يشرح كيف وصل النموذج إلى قرارٍ محدد لعيّنة بعينها. هل لديك أمثلة لتقنيات تخص كل منهما؟

الدكتور علاء (يفكر قبل أن يجيب): بالنسبة للتفسير العام، هناك أساليب مثل **Feature Importance** العامة (في الغابة العشوائية أو الأشجار). يمكنها إخبارنا بأي الميزات أكثر تأثيرًا في نموذجنا. كذلك هناك طرق تحليل الحساسية (Sensitivity Analysis) مثل **Partial Dependence Plots** أما التفسير المحلي فمثاله خوارزميات مثل **LIME** (Local Interpretable Model-agnostic Explanations) أو **SHAP** (SHapley Additive exPlanations) التي تحاول بناء نموذج تفسيري مبسّط حول نقطة واحدة أو مجموعة صغيرة من النقاط لمعرفة كيف أثر كل عنصر فيها على التنبؤ النهائي.

حواء (تبتسم وهي تقرأ هذه العبارة من النص): النص يقول إننا "نعالج التعقيد بمزيد من التعقيد" حين نستخدم خوارزميات إضافية لشرح النماذج المعقدة. هل هذا أمرٌ واقعي؟ ألا يزيد من صعوبة اعتماد هذه النماذج؟

الدكتور علاء (بشيء من الواقعية): نعم، نوعًا ما. بإضافة مرحلة "تفسير" للنموذج المعقد، نضيف خطوة أخرى قد تولد أخطاء أو تقديرات تقريبية فقط. لكن في الكثير من الحالات، هذا هو الثمن الواجب دفعه للاستفادة من قوة النماذج "الصندوق الأسود" مع الحفاظ على درجة مقبولة من التفسير. الحقيقة أن مجال "تعلم الآلة القابل للتفسير (Explainable AI)" ينمو سريعًا ويقدم أدوات أفضل يومًا بعد يوم.

حواء (تجمع ملاحظاتها مع ابتسامة تقدير): شكرًا جزيلاً دكتور علاء. إذا الخلاصة:

- النماذج القابلة للتفسير هي تلك التي يستطيع الإنسان فهمها مباشرةً (مثل الأشجار البسيطة والانحدار الخطي).

- النماذج القابلة للشرح أشد تعقيدًا، ونستخدم أدوات تفسير خارجية (مثل (LIME, SHAP).
- تزداد الحاجة للتفسير في المجالات الحرجة، وللإستجابة للقوانين واللوائح (كـGDPR).
- التفسيرات قد تكون عامة أو محلية بحسب مستوى الفهم المطلوب.
- ورغم زيادة التعقيد، يعدّ التفسير حجر زاوية لبناء الثقة في الأنظمة الذكية.

الدكتور علاء (بسرور): عرض ممتاز يا حوراء. أتمنى لكِ التوفيق في بحثك وعملك مع النماذج القابلة للتفسير. تذكّري دائمًا أنه في كثيرٍ من الأحيان، يبدأ العلماء والمهندسون بنموذج بسيط مُفسّر، ثم إذا احتاجوا لأداء أعلى، قد ينتقلون إلى نماذج أعقد ويستخدمون أساليب التفسير المساندة. وأي سؤال عندك في المستقبل، لا تترددي في طرحه.

حوراء (تلوّح مودّعة): سأفعل بالتأكيد. شكرًا دكتور علاء، إلى اللقاء في المحاضرة القادمة!

الدكتور علاء (يبتهسم مودّعًا): إلى اللقاء يا حوراء، بالتوفيق دائمًا.

الحوارية الثامنة عشر: مناهج تعلم الآلة

(مكتب الدكتور علاء طعيمة في الجامعة، حيث تجلس حوراء، الطالبة المهتمة
بمجال مناهج تعلم الآلة، ويدها دفتر ملاحظات)

حوراء (تدخل إلى مكتب الدكتور علاء وعلى وجهها تساؤلات واضحة): مرحبًا دكتور علاء، أتمنى أن تكون بخير. لدي سؤال مهم اليوم: ما هو نهج تعلم الآلة الذي يجب أن أستخدمه لمشكلتي؟ قرأت نصًا يوضح أن هناك استراتيجيات مختلفة، وأنه لا ينبغي تجربة كل الخوارزميات عشوائيًا، بل يجب فهم طبيعة المشكلة والهدف منها. أرغب في سماع رأيك ومناقشتك في هذا الموضوع.

الدكتور علاء (ينظر إليها بابتسامة ترحيب): مرحبًا بك يا حوراء. بالفعل، اختيار نهج تعلم الآلة المناسب يعتمد بشكل أساسي على طبيعة المشكلة التي تواجهينها وعلى الهدف النهائي الذي ترغبين بتحقيقه. هل توّدين البدء بما فهمته من النص؟

حوراء (تمسك مفكرتها وتقلب صفحاتها):

أشار النصّ إلى أننا نحتاج أولاً لفهم المشكلة بالكامل وتحديد ما نريده بالضبط. وأعطى إطار عمل مفيد:

1. إن كنا نريد تقسيم البيانات غير المصنّفة إلى مجموعات تتشارك خصائص متشابهة (مثل تصنيف العملاء)، فنستخدم خوارزميات التجميع (التعلم غير الخاضع للإشراف).
2. إن كنا نريد التنبؤ بقيمة مستمرة (مثل أسعار المنازل)، فنلجأ إلى خوارزميات الانحدار (التعلم الخاضع للإشراف).
3. إن كنا نريد التنبؤ بفئة/صنف (ولدينا بيانات مصنّفة مسبقًا)، فإننا نستخدم خوارزميات التصنيف (التعلم الخاضع للإشراف).

4. إذا أردنا تقليل عدد الميزات إلى عدد أقل، نستخدم خوارزميات تقليل الأبعاد مثل PCA.

5. إن كنا بحاجة لخوارزمية تتفاعل مع بيئتها وتتعلم باستمرار من التجربة، فتلك حالة التعلم المعزز.

الدكتور علاء (يشير برأسه موافقاً): جيّد جدًّا، هذا ملخص ممتاز. إذن قبل الدخول في تجربة الخوارزميات من دون هدف محدد، يُستحسن أن نطرح الأسئلة المحورية: هل هدفنا تقسيم البيانات؟ أم التنبؤ بقيمة مستمرة؟ أم تصنيف فئات؟ أم تعلم مستمر من البيئة كما في الألعاب والروبوتات؟ بعدها نضيق نطاقنا ونختار النوع المناسب من خوارزميات تعلم الآلة.

حوراء (تشير إلى نقطة في النص): كما لفت النص الانتباه إلى عدة أسئلة عملية ينبغي طرحها بعد تحديد نوع المهمة. مثلاً:

- هل يجب بناء النموذج وتدريبه واختباره بسرعة؟
- هل نحتاج نموذجًا يقدم تنبؤات بسرعة؟
- ما مدى الدقة المطلوبة؟
- هل عدد الميزات أكبر من عدد العينات؟
- هل نحتاج نموذجًا يسهل تفسيره؟
- ما هي معايير التقييم الأساسية لاحتياجات العمل؟
- ما مقدار معالجة البيانات التي نريد القيام بها؟

كيف نستخدم هذه الأسئلة عمليًّا؟

الدكتور علاء (موضحًا): هذه الأسئلة تساعدك على تضيق نطاق الخوارزميات أكثر. مثلاً، إذا كنت بحاجة لسرعة التنبؤ بدرجة كبيرة على جهاز محدود الموارد، فقد تفضّلين خوارزمية بسيطة نسبيًّا على شبكة عصبية كبيرة. إذا كانت قابلية التفسير

مهمة جدًا (مثلًا في المجال الطبي) ستُفضّلين خوارزميات بسيطة كأشجار القرار أو الانحدار الخطي على نماذج "الصندوق الأسود" كالشبكات العصبية العميقة. وإذا كانت الدقة أو الأداء التنبؤي هو الأهم وليس سهولة التفسير، فقد تختارين النماذج الأكثر تعقيدًا.

حوراء (تستعيد جزءًا من النص): ذكر النص أن محاولة تجربة "كل الخوارزميات" دون استراتيجية قد يستغرق وقتًا طويلًا، وأيضًا قد نستخدم خوارزمية لا تناسب أصلًا نوع المشكلة. شبهوها بضرب المسمار بمطرقة بدلاً من مفك البراغي. هل تكرار تجربة كل شيء دائمًا مرفوض؟

الدكتور علاء (بشيء من الموازنة): ليس مرفوضًا بالكامل، إذ هناك حالات نريد فيها البحث الشامل (مثلًا في بعض مشاريع البحث العلمي) إذا كنا نريد إجراء دراسة واسعة. ولكن غالبًا ما يكون هذا مكلفًا ويفتقر للتركيز. أما في المشاريع العملية، فنودّ استثمار وقتنا ومواردنا بحكمة. لذا نبدأ بتحديد نوع المشكلة، ثم نختار أكثر الخوارزميات ملاءمة لهذا النوع. بعدها قد نجرب بضع خوارزميات (أو نتبع AutoML) لنرى أيها يعطي أداءً أفضل، بدلًا من تجربة كل شيء عشوائيًا.

حوراء (تبتسم وهي تسأل): ما رأيك لو نعطي مثالًا عمليًا؟ لنفترض أنني أعمل على "توقع مبيعات منتج" في شركة تجارية. في هذه الحالة، أي نهج يبدو ملائمًا؟

الدكتور علاء (يفرك ذقنه مفكرًا): توقع المبيعات يعتبر مشكلة انحدار (Regression) لأنها قيمة مستمرة. إذن نتجه مبدئيًا لتعلم خاضع للإشراف (Supervised Learning) باستخدام خوارزميات الانحدار. قد نبدأ بانحدار خطي بسيط أو خطي متعدد، أو حتى خوارزمية شبيهة بالغابة العشوائية للانحدار (Random Forest Regressor) أو الشبكات العصبية الموجهة للانحدار، حسب حجم البيانات وتعقيد العلاقات فيها.

نسأل أنفسنا الأسئلة الإضافية: هل تهمننا التفسيرات أم الأداء البحث؟ ما حجم البيانات؟ هل نريد النموذج سريعاً جداً؟ ونختار بناءً على ذلك.

حوراء (تكمل بنبرة حماسية): ماذا إذا أردت أن أقوم بتجميع العملاء في فئات بناءً على سلوكهم الشرائي، مثلاً لإرسال حملات تسويقية مخصصة؟

الدكتور علاء (يشير بإصبعه): هذه حالة تجميع (Clustering)، وهو نوع من التعلم غير الخاضع للإشراف. لا نملك تسميات مسبقة أو فئات معدة، بل نريد كشف مجموعات ذات سمات متشابهة. من أشهر الخوارزميات K-means، التجميع الهرمي (Hierarchical Clustering)، أو DBSCAN في بعض الحالات. نختار من بينها بناءً على أسئلة مثل: كم نتوقع عدد المجموعات؟ هل لدينا فكرة مسبقة عن شكل التوزيع؟ هل يمكن أن تكون المجموعات ذات أشكال معقدة؟ ... إلخ.

حوراء (تجمع أوراها وهي تبتسم ابتسامة امتنان): شكراً جزيلاً، دكتور علاء. يبدو الأمر واضحاً: لن أضيع وقتي في تجربة كل خوارزمية أجدها، بل سأتبع منهجاً منطقياً يبدأ من طبيعة المشكلة وأهدافي، ثم أطرح مجموعة أسئلة عملية حول السرعة والدقة والتفسير، وغيرها، لأضيّق نطاق الاختيار. وبعدها أجري التجارب على عدد محدود من الخوارزميات الملائمة.

الدكتور علاء (بابتسامة تشجيع): بالضبط، هذا هو الأسلوب السليم. وهكذا تقللين الوقت والتعقيد، وتضمنين أنك تستخدمين الأدوات الملائمة للمشكلة المناسبة. أتمنى لك التوفيق، وأنا بانتظار أسئلتك في المستقبل.

حوراء (تلوّح مودعة): سأعود بكل تأكيد عند أي استفسار جديد. شكراً مرة أخرى، دكتور علاء. إلى اللقاء.

الدكتور علاء (مشيراً بعفوية): إلى اللقاء يا حوراء، أطيب التمنيات لنجاحك!