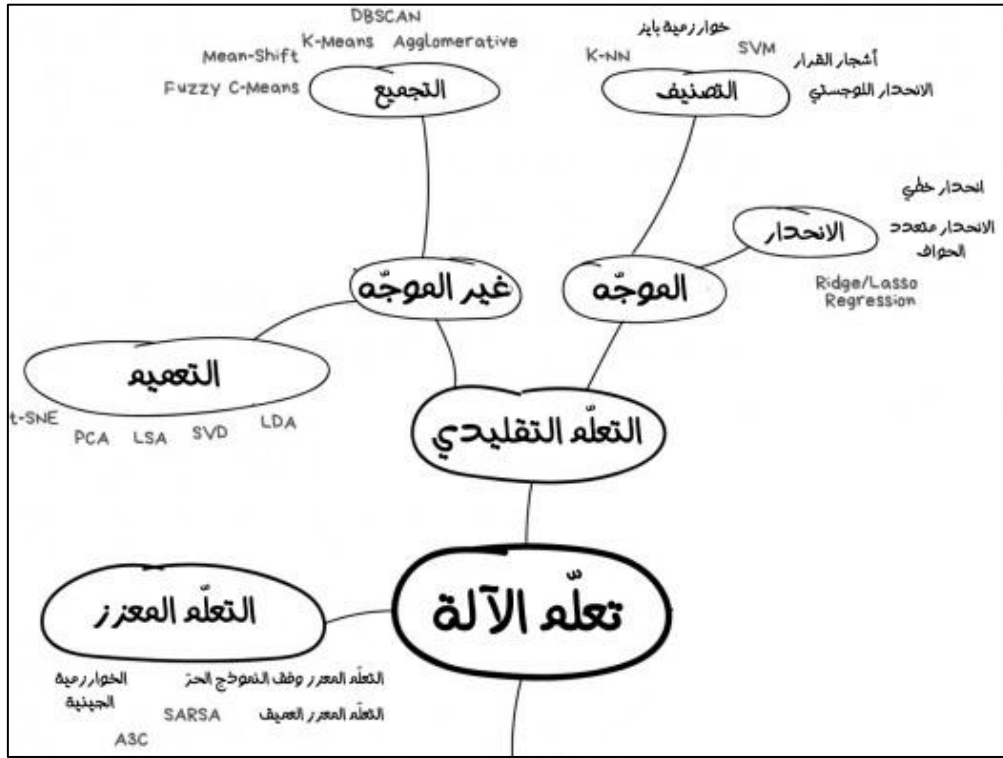


الدرس 02: أساسيات التعلم الآلي (Machine learning)

مقدمة

هناك نوعان رئيسيان من طرق التعلم الآلي: بإشراف وبدون إشراف. الفرق الرئيسي بين المنهجين هو أن التعلم تحت الإشراف يكتسب التعلم باستخدام حقيقة، أو بعبارة أخرى، لدينا معرفة مسبقة بمخرجات عيناتنا. عادة ما يتم التعلم الخاضع للإشراف في مجال التصنيف، عندما نريد تعيين المدخلات إلى تسميات الإخراج، أو الانحدار، عندما نريد تعيين الإدخال إلى إخراج مستمر.

من ناحية أخرى، التعلم غير الخاضع للإشراف، لا توجد مخرجات معنونة، وبالتالي فإن الهدف هو استنتاج البنية الطبيعية لمجموعة من نقاط البيانات واكتشاف الأنماط دون أي توجيه.



رسم تخطيطي يوضح أنواع التعلم الآلي

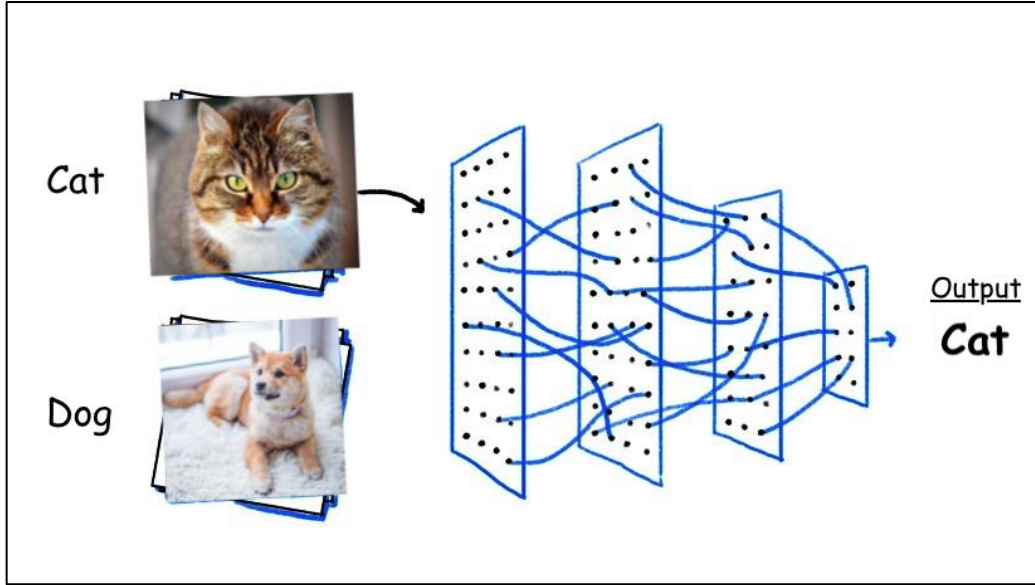
1. التعلم الموجه (بإشراف)

يعد التعلم الخاضع للإشراف أحد أكثر فروع التعلم الآلي استخدامًا، والذي يستخدم بيانات التدريب المصنفة لمساعدة النماذج على إجراء تنبؤات دقيقة. تعمل بيانات التدريب هنا كمسرف ومعلم للآلات، ومن هنا جاء الاسم. يعتمد التعلم الخاضع للإشراف على توليد مخرجات من التجارب السابقة (البيانات المسماة). في التعلم الخاضع للإشراف

1.1. التصنيف (Classification)


التصنيف هو عملية تعلم بأشراف، مما يعني أن خوارزمية التعلم تحاول إيجاد اتصال بين البيانات والعلامات بناءً على بيانات التدريب الموسومة مسبقاً.

في التصنيف، يتم تحديد الفئات مسبقاً وغالباً ما يشار إليها على أنها أهداف أو علامات أو فئات



1.1. التوقع أو الانحدار (Regression)

يتمثل الاختلاف الرئيسي بين نماذج التوقع والتصنيف في استخدام خوارزميات الانحدار للتنبؤ بالقيم المستمرة (درجات الامتحان)، بينما تتنبأ خوارزميات التصنيف بقيم منفصلة (ذكر / أنثى، صواب / خطأ). الانحدار هو عملية إحصائية تجد علاقة ذات دلالة إحصائية بين المتغيرات التابعة والمستقلة. كخوارزمية، فإنه يتنبأ بعدد مستمر. على سبيل المثال، يمكنك استخدام خوارزمية الانحدار لتحديد درجات اختبار الطلاب بناءً على عدد الساعات التي يدرسونها في الأسبوع. في هذه الحالة، تصبح الساعات المدروسة متغيراً مستقلاً والنتيجة النهائية لاختبار الطالب هي متغير تابع. يمكنك رسم خط الأنسب Fitting Line من خلال نقاط بيانات مختلفة لإظهار تنبؤات النموذج عند إدخال مدخلات جديدة. يمكن استخدام نفس الخط للتنبؤ بدرجات الامتحان بناءً على أداء طالب آخر

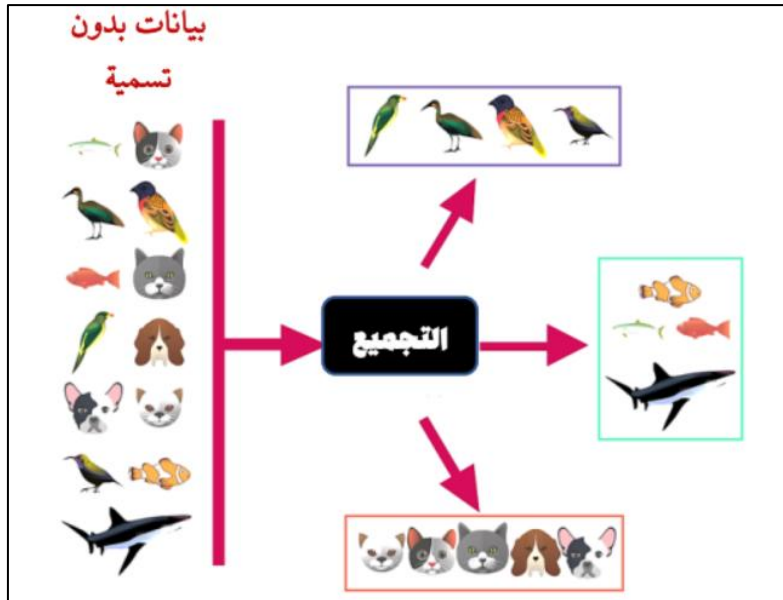


2. التعلم الغير الموجه (بدون إشراف)

يحدث التعلم بدون اشراف في التعلم الآلي عندما لا يكون هناك تسمية للبيانات أو تصنيف لها. تتمثل المهمة في فرز المعلومات غير المجمعة بناءً على بعض أوجه التشابه والاختلاف دون أي توجيه

1.2 التجميع (Clustering)

التجميع هو عملية تعيين عينات البيانات لعدد معين من المجموعات بحيث يكون لنقاط البيانات التي تنتمي إلى المجموعة خصائص متشابهة




3. التعلم المعزز:

يتجذر التعلم المعزز في سيكولوجية تعلم الحيوانات وهو يدور حول تعلم السلوك الأمثل في البيئة. للحصول على أقصى قدر من المكافأة، يتم تعلم هذا السلوك الأمثل من خلال التفاعل مع البيئة وملاحظات كيفية تفاعلها. يكافأ المتعلم (الوكيل) على الأعمال الصالحة ويعاقب على الإثم.

في حالة عدم وجود مراقب، يسعى المتعلم إلى سياسة فعالة لحل مهمة صنع القرار. تحدد مثل هذه السياسة كيفية تصرف الوكيل في أي موقف قد يواجهه من أجل تكبير (أو تقليل إجمالي المكافأة) المتوقعة عن طريق التجربة والخطأ في التفاعل مع بيئة ديناميكية. يعد التعلم المعزز خوارزمية قوية للغاية لأنه يمكن أن يتعلم الإجراءات التي تؤدي إلى النجاح النهائي في بيئة غير مرئية دون مساعدة مراقب.

Genetic Algorithms



تجزئة البيانات:

على الرغم من أن خوارزميات التعلم الآلي تعتبر أدوات مذهلة وقوية في التنبؤ والتصنيف، فإن السؤال الذي يطرح نفسه هو مدى دقة هذه التنبؤات وهل هناك طريقة لقياس أداء النموذج؟ نظرا لأن هذه الخوارزميات تحتوي على علامات مميزة للعينات.

يمكن الإجابة على هذا السؤال بتقسيم عينات التدريب إلى عدة أقسام، من خلال تقسيم البيانات، نقوم أولاً بإجراء التدريب على جزء من البيانات، ثم نستخدم البيانات التجريبية لقياس كفاءة النموذج وإمكانية تعميمه.

- **مجموعة التدريب:** عادة ما تكون أكبر مجموعات البيانات وتستخدم للعثور على معاملات النموذج، تحدد بيانات مجموعة التدريب العلاقة الأساسية بين البيانات وعلاماتها بأفضل طريقة ممكنة.
- **مجموعة الاختبار:** لقياس أداء النموذج بناءً على قدرة النموذج على التنبؤ بالبيانات التي لا تلعب دوراً في عملية التعلم.

معايير تقييم الأداء:

لحساب معايير التقييم لنموذج التصنيف، نحتاج إلى أربع مجموعات من الفئة الحقيقية وفئة التنبؤ مع العناوين، الموجبة الحقيقية، الموجبة الخاطئة، السلبية الحقيقية والسلبية الخاطئة، والتي يمكن تمثيلها في مصفوفة الارتباك (Confusion Matrix) (جدول 2-1):

- **موجب حقيقي (TP):** على سبيل المثال، عندما كانت القيمة الفعلية للفئة "نعم"، توقع النموذج أيضاً "نعم" (أي توقع صحيح).
- **موجب خاطئ (FP):** على سبيل المثال، عندما كانت القيمة الفعلية للفئة "لا" لكن النموذج توقع "نعم" (أي توقع خاطئ).
- **منفى خاطئ (FN):** على سبيل المثال، عندما تكون القيمة الفعلية للفئة "Yes"، لكن النموذج توقع "لا" (أي توقع خاطئ).
- **منفى حقيقي (TN):** على سبيل المثال، عندما تكون القيمة الفعلية للفئة "لا" وتوقع النموذج "لا" (أي، كان التوقع صحيحاً).

		الفئة المتوقعة	
		مبني	منفي
الفئة الحقيقية	مبني	موجب حقيقي (TP)	منفي خاطئ (FN)
	منفي	موجب خاطئ (FP)	منفي حقيقي (TN)

المعيار الأكثر شيوعاً الذي يتم الحصول عليه من مصفوفة الارتباك هو دقتها (accuracy) أو عكسها: خطأ التنبؤ (prediction error):

$$\text{الدقة} = \frac{TP + TN}{TP + FN + FP + TN}$$

$$\text{الدقة} = 1 - \text{خطأ التنبؤ}$$

الدقة هي نسبة عدد التنبؤات الصحيحة إلى العدد الإجمالي لعينات الإدخال. عندما يتعين علينا تقييم نموذج ما، فإننا غالباً ما نستخدم معدلات الخطأ والدقة، ولكن ما نركز عليه بشكل أساسي هو مدى موثوقية نموذجنا، وكيف يعمل على مجموعة بيانات مختلفة (قابلية التعميم) ومدى مرونته. لا شك أن الدقة معيار مهم للغاية يجب أخذه في الاعتبار، لكنها لا تقدم دائماً صورة كاملة لأداء النموذج.

عندما نقول إن النموذج موثوق، فإننا نعني أن النموذج قد حصل على البيانات بشكل صحيح ووفقاً لطلب التعلم. لذلك، فإن التنبؤات التي قدمتها قريبة من القيم الفعلية. في بعض الحالات، قد يؤدي النموذج إلى دقة أفضل، لكنه قد لا يفهم البيانات بشكل صحيح وبالتالي يؤدي بشكل سيئ عندما تكون البيانات مختلفة. هذا يعني أن النموذج ليس موثقاً وقوياً بدرجة كافية وبالتالي يحد من استخدامه.

على سبيل المثال، لدينا 980 تفاحة و20 برتقالة ولدينا نموذج يصنف كل فاكهة على أنها تفاحة. لذلك، دقة النموذج $98/980 = 10\%$ ، وبناءً على معيار الدقة لدينا نموذج دقيق للغاية. ومع ذلك، إذا استخدمنا هذا النموذج للتنبؤ بالثمار المستقبلية، فسوف نفشل. لأن هذا النموذج يمكن أن يتنبأ بفئة واحدة فقط.

الحصول على صورة كاملة للنموذج، على سبيل المثال كيف يدرك البيانات وكيف يمكن التنبؤ بها، يساهم في فهمنا العميق للنموذج ويساعد على تحسينه. لذا، افترض أن لديك نموذجاً يحقق دقة 90٪، فكيف يمكنك تحسينه؟ لتصحيح الخطأ، يجب أن ندركه أولاً. وبالمثل، لتحسين النموذج، نحتاج إلى النظر في كيفية عمل النموذج على مستوى أعمق. ومع ذلك، لا يتم تحقيق ذلك بمجرد النظر إلى معيار الدقة، وبالتالي يتم النظر في معايير أخرى. معايير مثل الدقة (precision) والاستدعاء (recall) و F1-Score هي أمثلة على هذه المعايير.

يشير الاستدعاء إلى قدرة النموذج على التنبؤ بالحالات الإيجابية من بين جميع الإيجابيات الحقيقية. من ناحية أخرى، تقيس الدقة جزء الإيجابيات الحقيقية بين العينات التي يُتوقع أن تكون إيجابية. قد لا تكون الدقة والاستدعاء وحدهما مناسبين لتقييم النموذج، لذلك يتم استخدام درجة F1، والتي تتضمن الدقة والاستدعاء، وتشير إلى مدى دقة المصنف. كلما زادت درجة F1، كان أداء نموذجنا أفضل. طريقة حساب هذه المعايير على النحو التالي:

$$\text{الاستدعاء} = \frac{TP}{FN + TP}$$

$$\text{الدقة} = \frac{TP}{FP + TP}$$

$$\text{درجة F1} = 2 \times \frac{\text{الاستدعاء} * \text{الدقة}}{\text{الاستدعاء} + \text{الدقة}}$$