

## طرق تعلم الآلة

يوجد نوعان رئيسيان من طرق التعلم الآلي:

- **التعلم بإشراف (Supervised Learning):** يعتمد على بيانات ذات مخرجات معروفة مسبقاً (Labels) ، والهدف هو بناء دالة تتبعاً بالمخرجات انطلاقاً من المدخلات. يطبق أساساً في التصنيف (Classification) لتحديد الفئات، والانحدار (Regression) للتنبؤ بقيم مستمرة.

### **(Classification): التصنيف**

- **منح القروض البنكية:**

التنبؤ بما إذا كان العميل سيحدد القرض أو سيعذر (فتنان: "سيحدد" / "لن يحدد").

- **تحليل الجدارة الائتمانية (Credit Scoring):**

تصنيف العملاء إلى "جيد" أو "سيء" من حيث المخاطر.

- **التسويق الموجه:**

تحديد ما إذا كان الزبون سيستجيب لحملة تسويقية معينة (نعم / لا).

### **(Regression): الانحدار**

- **التنبؤ بالناتج المحلي الإجمالي (GDP):**

اعتماداً على متغيرات مثل الاستثمار، الاستهلاك، الإنفاق الحكومي.

- **توقع أسعار الأسهم أو السلع:**

مثل التنبؤ بسعر النفط أو الذهب بناءً على بيانات العرض والطلب والعوامل الجيوسياسية.

- **تقدير الطلب على منتج:**

مثلاً: تقدير حجم المبيعات الشهرية لشركة وفقاً للإنفاق الإعلاني والدخل الفردي.

### ◆ الخلاصة:

- إذا كان الهدف التنبؤ بفئة/قرار → نستخدم التصنيف.

- إذا كان الهدف التنبؤ بقيمة عددية → نستخدم الانحدار.

- **التعلم بدون إشراف (Unsupervised Learning):** لا يتتوفر على مخرجات معروفة، بل يسعى لاكتشاف الأنماط والهيكل الخفي في البيانات. من أبرز تطبيقاته التجميع (Clustering) وتقليل الأبعاد (Dimensionality Reduction).

### **1. التجميع (Clustering):**

- **تقسيم العملاء إلى شرائح (Customer Segmentation):**

تجميع العملاء وفقاً لسلوك الشراء أو القدرة الشرائية (مثلاً: عملاء ذوي إنفاق مرتفع، متوسط، منخفض).  
• **تصنيف الأسواق:**

تجميع الأسواق العالمية أو المحلية حسب خصائصها الاقتصادية (مستقرة / ناشئة / متقلبة).

- **تحليل سلوك المستهلك:**

تقسيم المستهلكين حسب أنماط الشراء (شراء موسمي، شراء متكرر، شراء عشوائي).

## 2. تقليل الأبعاد (Dimensionality Reduction):

- **تحليل المخاطر المالية:**

تبسيط مجموعة ضخمة من المؤشرات المالية (أسعار الفائدة، التضخم، سعر الصرف، إلخ) إلى أبعاد أقل لفهم الاتجاهات الرئيسية.

- **تصور البيانات الاقتصادية:**

عرض بيانات اقتصادية عالية التعقيد (مثل بيانات التجارة الدولية) في بعدين أو ثلاثة لتسهيل التقسيم.

## 3. اكتشاف الأنماط والتطرفات (Pattern & Anomaly Detection):

- **كشف الغش العالمي أو المحاسبي:**

اكتشاف العمليات المشبوهة في المعاملات البنكية أو البيانات المالية.

- **تحليل الاستهلاك الطاقي:**

رصد أنماط غير طبيعية في استهلاك الكهرباء أو الوقود التي قد تشير إلى تهريب أو سوء استخدام.

الخلاصة: ◆

- **التجمیع مفید لتقسیم العملاء أو الأسواق.**

- **تقلیل الأبعاد لتبسیط البيانات الاقتصادية المعقدة.**

- **کشف الأنماط لاكتشاف الغش أو السلوكيات غير المعتادة.**

### أولاً: التعلم بإشراف:

التعلم الخاضع للإشراف (Supervised Learning) يعتمد على بيانات مصنفة (مدخلات  $x$  مع مخرجات  $y$ ، حيث يتعلم النموذج دالة  $y = f(x)$  ليربط بينهما، مما يمكنه من التنبؤ بمخرجات دقيقة لمدخلات جديدة استناداً إلى تجارب سابقة).

#### 1. التصنيف:

التصنيف (Classification) هو نوع من التعلم الخاضع للإشراف، يهدف إلى إيجاد علاقة بين البيانات المدخلة والتسميات (Labels) استناداً إلى بيانات تدريب مصنفة، بحيث يمكن للنموذج التنبؤ بالفئة الصحيحة لبيانات جديدة.

ينقسم التصنيف إلى:

#### 1. حسب عدد التسميات:

##### أ. التصنيف أحادي العلامة (Single-Label Classification):

كل عينة ترتبط بفئة واحدة فقط.

♦ مثال اقتصادي: تصنیف شركة إلى قطاع اقتصادي واحد (زراعي، صناعي، خدمي).

##### ب. التصنيف الثنائي (Binary Classification):

الحالتان فقط (نعم/لا، إيجابي/سلبي).

♦ مثال اقتصادي: التنبؤ بما إذا كان العميل سيوافق على قرض أم سيرفض طلبه البنك (قبول / رفض).

## ج. التصنيف متعدد الفئات (Multi-Class Classification):

أكثر من فئتين.

♦ مثال اقتصادي: تصنيف المشاريع الاستثمارية إلى منخفضة، متوسطة، عالية المخاطر.

## د. التصنيف متعدد العلامات (Multi-Label Classification):

العينة قد تتنمي لأكثر من فئة في نفس الوقت.

♦ مثال اقتصادي: مقال اقتصادي قد يدرج تحت أكثر من تصنيف في آن واحد مثل:

- "تجارة دولية"
- "مالية"
- "استثمار"

أو مثال آخر: شركة ناشئة يمكن أن تُصنف في وقت واحد ضمن "التكنولوجيا المالية" (FinTech) و"التجارة الإلكترونية".

### 1. حسب عدد التسميات:

- تصنيف أحادي العلامة (Single-Label): كل عينة مرتبطة بتسمية واحدة.
- تصنيف متعدد العلامات (Multi-Label): العينة قد تتنمي لعدة تسميات في نفس الوقت.

#### (Single-Label Classification):

- كل عينة بيانات يمكن أن تأخذ تسمية واحدة فقط من مجموعة الفئات.
- النموذج يتبع بفئة وحيدة لكل حالة.

#### مثلاً اقتصادي:

عميل بنك يتم تصنفيه إما "جيد" أو "سيء" من حيث السداد. (لا يمكن أن يكون الاثنين معًا).

#### (Multi-Label Classification):

- كل عينة بيانات يمكن أن تتنمي إلى عدة فئات في نفس الوقت.
- النموذج يتبع بمجموعة تسميات للعينة.

#### مثلاً اقتصادي:

مقال اقتصادي قد ينتمي في الوقت نفسه إلى أكثر من مجال: "مالية"، "تجارة دولية"، و"استثمار".

أو شركة ناشئة تُصنف في آن واحد ضمن "التكنولوجيا المالية" (FinTech) و"التجارة الإلكترونية".

#### الفرق الأساسي:

- كل عينة → تسمية واحدة فقط.  
Single-Label: •  
كل عينة → قد تحتوي عدة تسميات معًا.  
Multi-Label: •

- التصنيف أحادي العلامة (Single-Label)
- التصنيف متعدد العلامات (Multi-Label)

♦ تخيل لدينا نفس العينة (عميل بنك):  
 أحادي العلامة: (Single-Label)  
 كل عميل يعطى فئة واحدة فقط:  
 • العميل "A" → جيد  
 • العميل "B" → سيء  
 → النتيجة دائمًا تصنيف واحد لكل عينة.

متعدد العلامات: (Multi-Label)  
 العميل نفسه قد ينتمي إلى أكثر من فئة في نفس الوقت:  
 • العميل "A" → جيد في السداد + مستثمر نشط  
 • العميل "B" → سيء في السداد + مستهلك كثيف  
 → النتيجة عدة تسميات للعينة الواحدة.

## 2. حسب عدد الفئات:

- تصنیف ثنائی (Binary): فئتان فقط (نعم/لا، ذكر/أنثى).
- تصنیف متعدد الفئات (Multi-Class): أكثر من فئتين (تصنیف أنواع الزهور أو المنتجات)

### أ. التصنیف أحادي العلامة:

التصنیف أحادي العلامة (Single-Label Classification) يعني أن كل عينة ترتبط بتسمية واحدة فقط، ويتبع النموذج بعلامة واحدة لكل حالة. وينقسم إلى:

- ✓ تصنیف ثنائی (Binary): حالتان فقط.
- ✓ تصنیف متعدد الفئات (Multi-Class): أكثر من فئتين.

ب. التصنیف الثنائي (Binary Classification): هو أبسط أنواع التصنیف، حيث تنتمي كل عينة إلى إحدى فئتين فقط (إيجابية أو سلبية). مثال: اختبار الانتخابات (انتخاب/امتنع).

### ت. التصنیف متعدد الفئات:

التصنیف متعدد الفئات (Multi-Class Classification) يسمح بتمیز العینات إلى أكثر من فئتين دون حد محدد، مثل: تصنیف الأخبار حسب الموضوع، أو الكتب حسب التخصص، أو الحيوانات في الصور.

### ث. التصنیف متعدد العلامات:

التصنیف متعدد العلامات (Multi-Label Classification) يعني أن العينة الواحدة قد ترتبط بعدة تسمیات في آن واحد، مثل خبر تقني عن iPhone يرتبط بفئة "تكنولوجيا" و "علامة تجارية". يستخدم بكثرة في معالجة اللغة الطبيعية (تصنیف النصوص)، وكذلك في استرجاع المعلومات، تشخیص الأمراض، والمعلوماتية الحیوية. وهو تعمیم للتصنیف أحادي العلامة، حيث يمكن ربط كل حالة بمجموعة من العلامات بدلاً من واحدة فقط.

أ. التصنیف أحادي العلامة: (Single-Label Classification)  
 كل عينة لها تسمیة واحدة فقط.

♦ مثال اقتصادي: تصنیف مؤسسة إلى قطاع واحد فقط (زراعي، صناعي، خدمي).

## ب. التصنيف الثنائي: (Binary Classification)

أبسط أنواع التصنيف: حالتان فقط (نعم/لا أو إيجابي/سلبي).

- ♦ مثال اقتصادي: التنبؤ إذا كان العميل سيرافق على قرض أم سيرفض طلبه البنك (قبول / رفض).
- ♦ مثال آخر: التنبؤ إذا كان سهم شركة سيرتفع أو ينخفض غداً.

## ج. التصنيف متعدد الفئات: (Multi-Class Classification)

أكثر من فئتين، لكن العينة تأخذ فئة واحدة فقط.

- ♦ مثال اقتصادي: تصنيف المشاريع الاستثمارية حسب درجة المخاطرة: منخفضة - متوسطة - عالية.

## 2. الانحدار - regression

الانحدار (Regression) يختلف عن التصنيف في كونه يتبع بقيم عدديّة مستمرة، بينما التصنيف يتعامل مع فئات منفصلة. هو أسلوب إحصائي يحدد العلاقة بين المتغير المستقلة و المتغير التابع. أمثلة تطبيقية:

- التنبؤ بدرجات الطلاب بناءً على عدد ساعات الدراسة.
- تقدير سعر سيارة مستعملة اعتماداً على خصائصها (العلامة التجارية، السنة، المسافة المقطوعة).
- في السيارات ذاتية القيادة: التنبؤ بالزاوية المناسبة لعجلة القيادة استناداً إلى بيانات أجهزة الاستشعار.

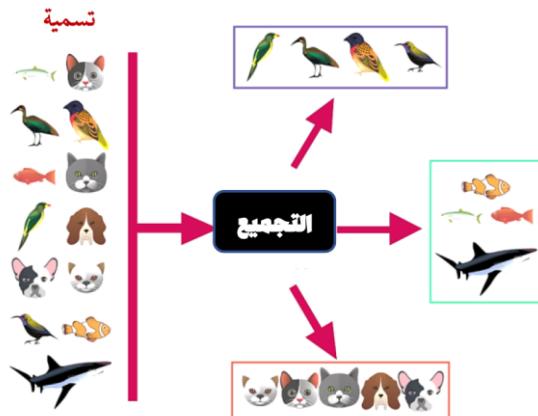
ثانياً/ التعلم بإشراف:

التعلم بدون إشراف (Unsupervised Learning) يستخدم عند غياب البيانات المصنفة، حيث تقوم الخوارزمية بالبحث ذاتياً عن أنماط وهياكل خفية داخل البيانات.

- ✓ لا يعرف النموذج مسبقاً ما هو "الصواب أو الخطأ".
- ✓ يعتمد على تشابه البيانات واختلافها لتجمِعها أو تبسيطها.
- ✓ مفيد في التحليل الاستكشافي، مثل تقسيم المستهلكين إلى شرائح دون وجود تسميات سابقة

## 1. التجميع: Clustering

التجمِع (Clustering) هو تقسيم البيانات إلى مجموعات (عناقيد) بحيث تتشابه العناصر داخل كل مجموعة وتختلف عن المجموعات الأخرى، مع تقليل المسافة بين نقاط البيانات داخل نفس المجموعة قدر الإمكان.



شكل 2-1. التجمِع.

نظرًا لأن التجميع يتم بواسطة خوارزمية، فمن المحتمل أنك ستكون قادرًا على اكتشاف الارتباطات غير المعروفة سابقًا في البيانات التي يمكن أن تساعدك في مواجهة تحدي الأعمال من منظور جديد.

2. تقليل الأبعاد:

**تقليل الأبعاد (Dimensionality Reduction)** هو تبسيط البيانات عبر خفض عدد المتغيرات (السمات) مع الحفاظ قدر الإمكان على المعلومات الأساسية، وذلك بتحويلها من فضاء عالي الأبعاد إلى فضاء أصغر دون فقدان الخصائص المهمة.

3. المقارنة بين التعلم بإشراف مع التعلم بدون إشراف

المقارنة بين التعلم بإشراف والتعلم بدون إشراف يمكن تبسيطها عبر مثال تعلم لغة جديدة:

A. التعلم بإشراف: يشبه إعطاء الطفل قاموساً يتترجم الكلمات مباشرة، فيتعلم بسرعة لكنه يظل محدودًا في الفهم العميق (يعتمد على بيانات مصنفة جاهزة).

B. التعلم بدون إشراف: يشبه إعطاء الطفل كتاباً باللغة الأجنبية ليكتشف القواعد والأنمط بنفسه. العملية أصعب وستغرق وقتاً أطول، لكنها تمنحه فهماً أعمق وبنية لغوية أوسع (يستخرج الأنماط خفية من البيانات غير المصنفة).

#### التعلم بإشراف (Supervised Learning)

الفكرة: لدينا بيانات مُسماة (Labels) نعرف فيها النتيجة مسبقاً، ونعلم النموذج كيف يتباين بها.

أمثلة اقتصادية وإدارية:

الاقتصاد: التنبؤ بالناتج المحلي الإجمالي (GDP) لدولة اعتماداً على بيانات مثل: الاستثمار، الصادرات، والاستهلاك (انحدار). Regression).

التسيير المالي: التنبؤ بمدى احتمال إفلاس الشركات بالاعتماد على نسب مالية (ديون، سيولة، ربحية)). تصنيف ثنائي Binary).

إدارة الموارد البشرية: التنبؤ بما إذا كان موظف ما سيترك الشركة أم لا (Yes/No) بالاعتماد على بيانات مثل: الراتب، عدد ساعات العمل، الرضا الوظيفي.

التسويق: التنبؤ بقيمة مبيعات منتج معين اعتماداً على ميزانية الإعلانات والموسمية (انحدار).  
ثانياً: التعلم بدون إشراف (Unsupervised Learning)

الفكرة: لا نملك بيانات مُسماة مسبقاً، النموذج يكتشف الأنماط والعلاقات المخفية بنفسه.

أمثلة اقتصادية وإدارية:

الاقتصاد: تجميع الدول إلى مجموعات (Clusters) بناءً على مؤشرات اقتصادية مثل التضخم، البطالة، والنمو، دون تحديد الفئات مسبقاً.

التسيير المالي: تجميع العملاء في البنوك حسب سلوكهم المالي (مدخرون، مقترضون، مستثمرون) دون وجود تسميات جاهزة.

إدارة الموارد البشرية: تحليل بيانات الموظفين لاكتشاف أنماط غير مرئية، مثل تقسيمهم إلى مجموعات حسب الأداء والتحفيز، من غير أن نحدد الفئات مسبقاً.

**التسويق: تقسيم السوق (Market Segmentation)** إلى مجموعات من المستهلكين (حسب الدخل، التفضيلات الشرائية، العمر) دون تسميات جاهزة مسبقاً.

◆ الفرق الأساسي:

بإشراف: عندما نتائجة معروفة مسبقاً (مثل: ربح/خسارة، قبول/رفض.)

بدون إشراف: نحاول اكتشاف أنماط وعلاقات جديدة في البيانات (مثل: تقسيم العملاء، تجميع الدول).

#### 4. لماذا التعلم بدون إشراف؟

[فعال جداً عند توفر بيانات مصنفة، حيث يقيس النموذج أداؤه بمقارنة المخرجات المتوقعة بالحقيقية، ويسعى لتقليل الخطأ. لكنه يواجه قيوداً:]

- تكلفة عالية لوضع العلامات يدوياً.

• محدودية التعلم، إذ يتعلم فقط من البيانات التي تم تدريبه عليها (مناسب للذكاء الاصطناعي الضيق *Narrow AI*).

#### [التعلم غير الخاضع للإشراف: (Unsupervised Learning)]

لا يعتمد على بيانات معروفة، بل يتعلم البنية الأساسية للبيانات ويكشف أنماطاً خفية.

- مثل: تجميع الصور المشابهة (كراسي معًا، قطط معًا).

- يقلل عباءة وضع العلامات يدوياً.

- أكثر مرنة للتعامل مع بيانات غير معروفة أو متغيرة باستمرار.

- أقل كفاءة أحياناً من التعلم بإشراف، لكنه مناسب للمشكلات المفتوحة ولتعلم المعرفة بشكل أوسع.

#### ثالثاً: التعليم المعزز

التعلم المعزز (**Reinforcement Learning**) مستوحى من طريقة تعلم الحيوانات، حيث يتعلم "الوكيل" السلوك الأمثل من خلال التفاعل مع البيئة عبر التجربة والخطأ، فيكافأ على الأفعال الصحيحة ويعاقب على الخاطئة. الهدف هو تطوير سياسة (**Policy**) لاتخاذ قرارات تزيد من إجمالي المكافآت المتوقعة. يتميز بقدرته على التعلم في بيئات ديناميكية غير معروفة مسبقاً دون إشراف مباشر.

#### اختيار النموذج وتقييمه:

اختيار النموذج وتقييمه في التعلم الآلي يتم عبر خطوتين أساسيتين:

##### 1. اختيار النموذج: (Model Selection)

- يشمل تحديد المعاملات الفائقة (**Hyperparameters**) مثل عدد الطبقات في الشبكة العصبية أو عدد

الأشجار في *Random Forest*.

- أو اختيار الخوارزمية الأنسب من بين عدة خوارزميات.

##### 2. تقييم النموذج: (Model Evaluation)

- الهدف هو تقدير خطأ النموذج على بيانات جديدة غير مرئية (خطأ التعلم).

- لا يكفي قياس الأداء على بيانات التدريب فقط لتفادي مشكلة الحفظ. (*Overfitting*).

#### طرق التقييم:

- عند توفر بيانات كافية: تقسيمها إلى تدريب / تحقق / **Validation** اختبار.

- عند قلة البيانات: تقسيمها إلى تدريب / اختبار مع استخدام التحقق المتقاطع (Cross-Validation).  
القاعدة الأساسية: يجب أن تكون بيانات التدريب والتحقق والاختبار مأخوذة من نفس التوزيع لضمان دقة التقدير.

#### طرق التقييم:

في حين أن تدريب النموذج هو خطوة أساسية، فإن كيفية تعليم النموذج على البيانات غير المرئية هي جانب مهم بنفس القدر يجب مراعاته بعد تصميم أي نموذج للتعلم الآلي. يجب التأكد من أن النموذج فعال حقاً وأن نتائج تنبؤاته يمكن الوثوق بها.

يمكن تدريب خوارزمية التصنيف على مجموعة بيانات محددة مع مجموعة فريدة من المعاملات التي يمكن أن تخلق حدود قرار تتناسب مع البيانات. نتيجة تلك الخوارزمية المعينة لا تعتمد فقط على المعاملات المتوفرة لتدريب النموذج، ولكن أيضاً على نوع بيانات التدريب. إذا كانت بيانات التدريب تحتوي على تباين بسيط أو كانت البيانات موحدة، فقد يؤدي النموذج إلى overfitting وإنتاج نتائج متحيزة على البيانات غير المرئية. لذلك، يتم استخدام طرق مثل التحقق المتبادل لتقليل overfitting في التحقق من الصحة. التحقق من الصحة المتبادل هو أسلوب يقسم مجموعة التدريب الرئيسية إلى مجموعتين من التدريب والبيانات التجريبية (التحقق من الصحة). الطريقة الأكثر شيوعاً للتتحقق المتبادل هي التتحقق متعدد الأجزاء - K-fold Validation، والذي يقسم مجموعة البيانات الرئيسية إلى أجزاء k متساوية الحجم. k هو رقم يحدده المستخدم ، وعادة ما يتم تحديد 5 أو 10. في هذه الطريقة، في كل مرة يتم استخدام واحدة من المجموعات الفرعية k كمجموعة تحقق (اختبار) ويتم تجميع المجموعة الفرعية k-1 معًا لتشكيل مجموعة تدريبية. للحصول على الكفاءة الكلية للنموذج، يتم حساب متوسط تقدير الخطأ في جميع التجارب.

#### معايير التقييم:

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

• 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).

• منفي خاطئ : FN ( على سبيل المثال ، عندما تكون القيمة الفعلية للفئة "Yes" ، لكن النموذج توقع "لا" (أي توقع خاطئ).

• منفي حقيقي : TN ( على سبيل المثال ، عندما تكون القيمة الفعلية للفئة "لا" وتوقع النموذج "لا" (أي ، كان التوقع صحيحاً).

جدول 2-1. مصفوفة الارتباط

		الفئة المترقبة	
		منفي	مثبت
مثبت	مثبت	موجب حقيقي (TP)	منفي خاطئ (FN)
	منفي	منفي خاطئ (FP)	منفي حقيقي (TN)

المعيار الأكثر شيوعاً الذي يتم الحصول عليه من مصفوفة الارتباط 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 يتبعنا 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 أخذها الاعتبار، لكنها لا تقدم دائمة صورة كاملة لأداء النموذج.