

## الذكاء الاصطناعي أو السباق المحموم نحو المجهول (2): التعلم الآلي: الروبوتات والبرامج المدربة تقتحم عالم الإنسان

سعيد قادري

أستاذ بقسم الإعلام الآلي، كلية الرياضيات والإعلام الآلي، جامعة محمد بوضياف، المسيلة

[said.kadri@univ-msila.dz](mailto:said.kadri@univ-msila.dz)

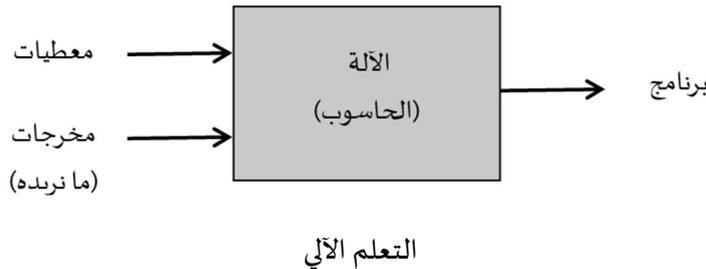
### 1. توطئة

لم يكن أحدٌ - حتى أشدّ الناس تفاؤلاً - يتصوّر أنه بإمكان الروبوتات والبرامج الذكية أن تقتحم عالم الإنسان وتنتهك خصوصيته، وتتمكن من محاكاته في كثير من سلوكياته ووظائفه، بل وحتى طريقة تفكيره وحله للمشكلات التي تُعرض له، بل وتتفوق عليه أحياناً، حتى ظهر مجال جديد في علم الحاسب الآلي يُسمى التعلّم الآلي الذي يعطي الروبوتات والبرامج الذكية قدرات فائقة في محاكاة الإنسان والقيام بالكثير من الوظائف والمهام التي كانت إلى وقت قريب حكراً عليه لا ينازعه فيها أحد.

### 2. تعريف التعلّم الآلي (Machine Learning)

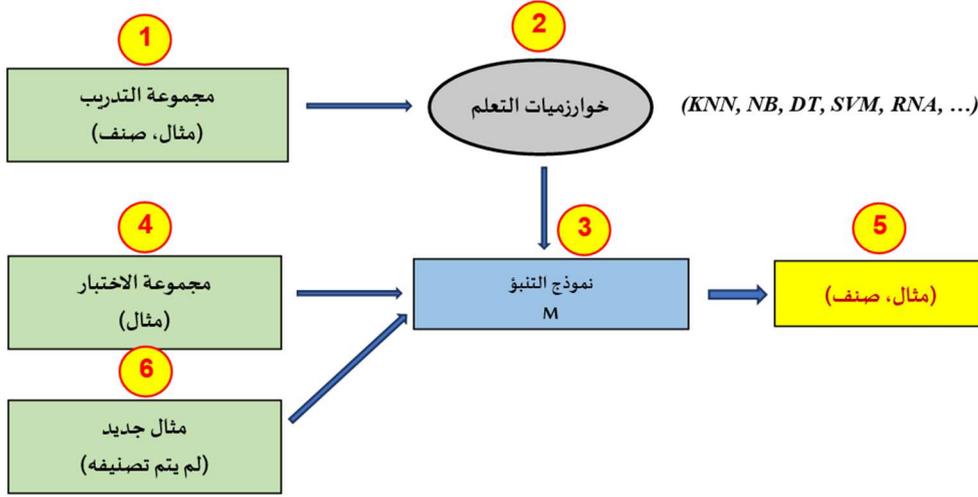
يُعدّ التعلّم الآلي أحد أهم الفروع الناشئة عن الذكاء الاصطناعي في السنوات الأخيرة، وقد وُضع له عددٌ من التعريفات، منها:

- مجال فرعي من الذكاء الاصطناعي يهدف إلى محاكاة الإنسان في طريقة تفكيره وتحليله وحلّه للمشكلات.
- الهدف الرئيسي من التعلّم الآلي هو إعادة إنتاج سلوك الإنسان.
- الفكرة الرئيسية للتعلّم الآلي هي التنبؤ بالمستقبل استناداً إلى الماضي (التجارب والمعطيات السابقة).
- تقوم فكرة التعلّم الآلي على تدريب الآلة على إنجاز مهام مختلفة دون تدخل الإنسان، أي منح الآلة استقلالية شبه كلية في التنفيذ واتخاذ القرار.



مثال: يمكن التنبؤ بكيفية اختيار عمر لفيلم لم يشاهده من قبل، استنادًا إلى تعليقاته وإعجاباته بالأفلام التي شاهدها سابقًا (بالاعتماد على تجاربه الماضية). أي التنبؤ بالمستقبل بناءً على الماضي.

### 3. خطوات التعلم الآلي (مثال: مشكلات التصنيف)



#### الخطوات الرئيسية

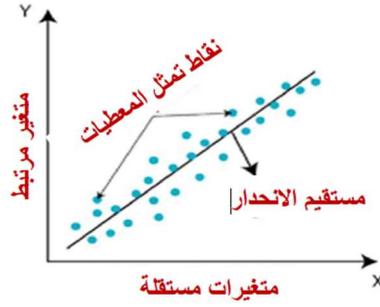
- 1) أخذ نسبة كبيرة من البيانات واستعمالها في التدريب (مجموعة التدريب) واستخدامها في بناء نموذج التنبؤ (نموذج Model/دالة Function).
- 2) تطبيق خوارزميات التعلم الآلي على مجموعة البيانات التدريبية لبناء نموذج تنبؤي.
- 3) بناء نموذج تنبؤي.
- 4) تقييم أداء هذا النموذج باستخدام مجموعة بيانات الاختبار (مجموعة الاختبار).
- 5) تُعدّ خوارزمية التعلم المستعملة صالحة وفعالة إذا كان أداؤها في مجموعة الاختبار مرتفعًا.
- 6) بعد التحقق من صحة النموذج وكفاءته، يُستخدم لتصنيف مثال جديد لم يسبق له التعرف عليه.

### 4. أمثلة عن مشكلات التنبؤ النمذجية

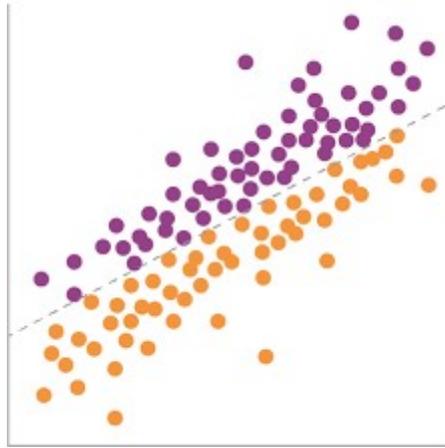
- أ- الانحدار (Regression): محاولة التنبؤ بقيمة حقيقية مجهولة.
- مثال 1: التنبؤ بقيمة المخزون لليوم الموالي بناءً على قيمه في الماضي (باستخدام الإحصائيات).

X	5	10	12	17	24	45
Y	12	22	26	36	?	?

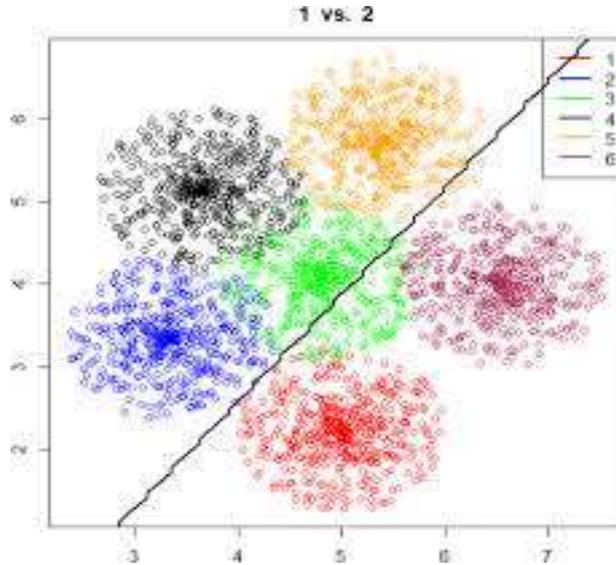
- مثال 2: البحث عن مستقيم يمر بأغلب نقاط المعطيات (تقريب خطي للمعطيات).



- ب- التصنيف الثنائي: محاولة التنبؤ بإجابة ثنائية بسيطة (نعم/لا - صح/خطأ).  
 مثال: التنبؤ بما إذا كان الطالب مراد يُفضّل وحدة تعليمية معينة أم لا.  
 من تطبيقات هذا النوع من التصنيف: فلترة البريد الإلكتروني، الكشف عن البريد المزيف.



- ج- التصنيف متعدد الفئات (الأصناف): تصنيف كائن معين ضمن فئة واحدة من بين عدة فئات.  
 مثال 1: تصنيف موضوع مقال إلى إحدى الفئات التالية: سياسة، رياضة، اقتصاد، دين، سينما، هوايات، وغيرها.  
 مثال 2: تصنيف حيوان ضمن إحدى الفئات التالية: قط، دب، ذئب، كلب، ثعلب، إلخ.



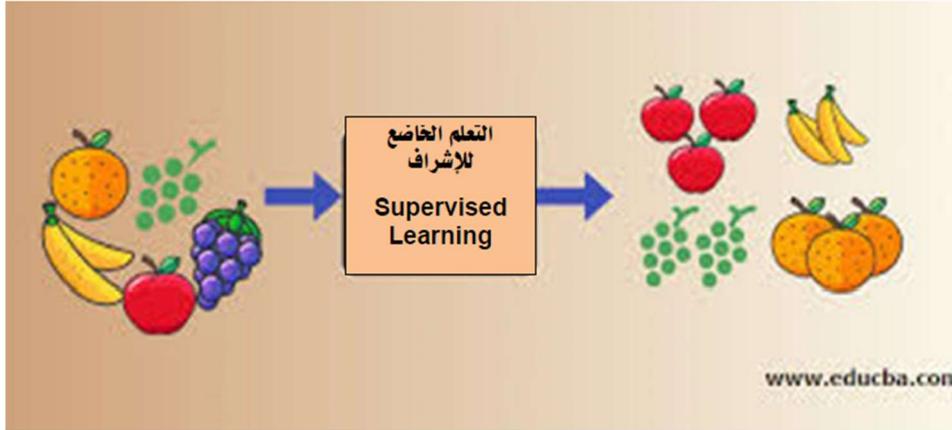
د- تصنيف متعدد العلامات: تصنيف كائن ما ضمن عدة فئات في الوقت ذاته.  
مثال: تصنيف كتاب تحت فئتين معًا، مثل "السياسة" و"التاريخ" في آن واحد، إذا كان يتناول تاريخ النظم السياسية في بلدٍ ما.

ثلاثة أنواع من مهام التصنيف

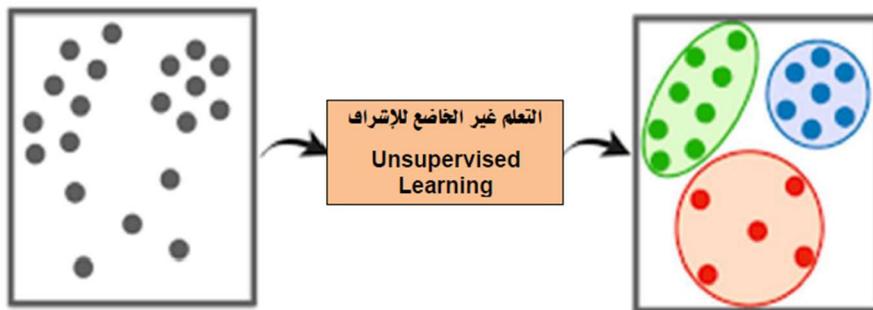


#### 4. أنواع التعلّم الآلي

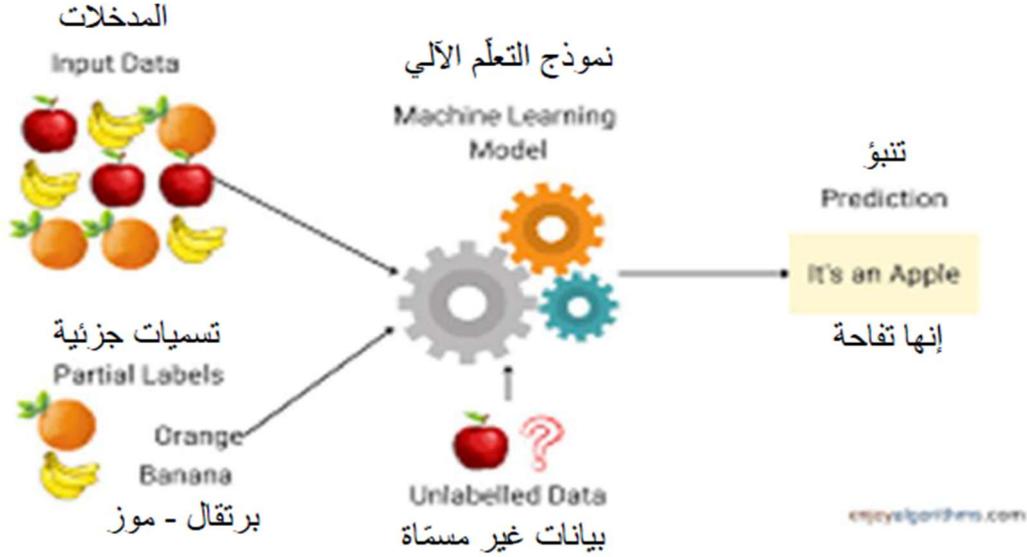
أ- التعلم الخاضع للإشراف (Supervised learning): يتم إجراء التصنيف إلى فئات محددة ومعروفة مسبقًا



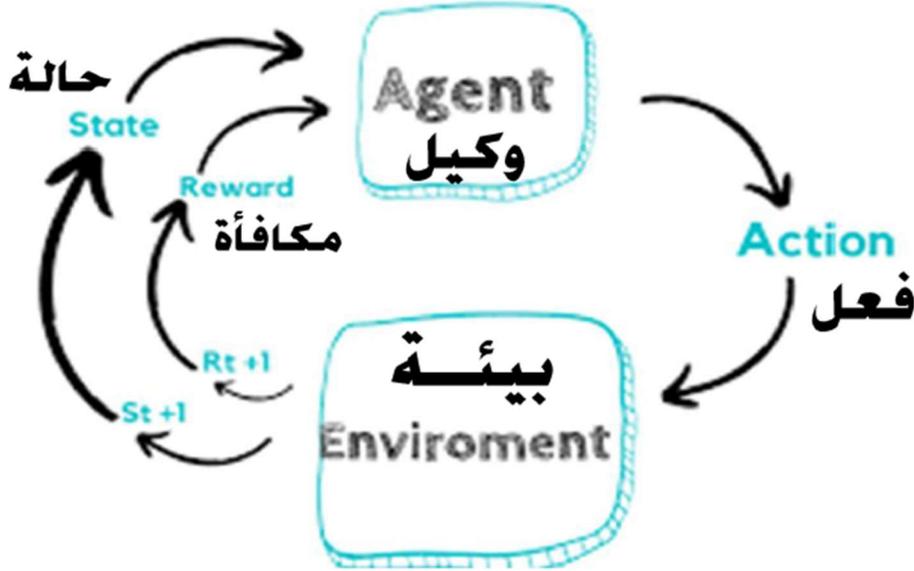
ب- التعلم غير الخاضع للإشراف (Unsupervised learning): يتم التصنيف على أساس فئات غير محددة مسبقًا.



- ج- التعلم الخاضع لشبه إشراف (مختلط): يتم التصنيف على البيانات ذات الفئات المعروفة مسبقاً، ولكن أيضاً على البيانات التي لم تُعرف فئاتها مسبقاً. ويهدف هذا الأسلوب إلى الاستفادة من مزايا كل من التعلم الخاضع للإشراف والتعلم غير الخاضع للإشراف، وذلك لتحقيق أداء أكثر كفاءة وفعالية.



- د- التعلم التعزيزي: يُعدّ التعلم التعزيزي نمطاً من أنماط التعلم يعتمد على التفاعل المتكرر مع البيئة المحيطة من أجل الوصول إلى الحلّ الأفضل (نوع من التعلم الموجه بردود أفعال المحيط).



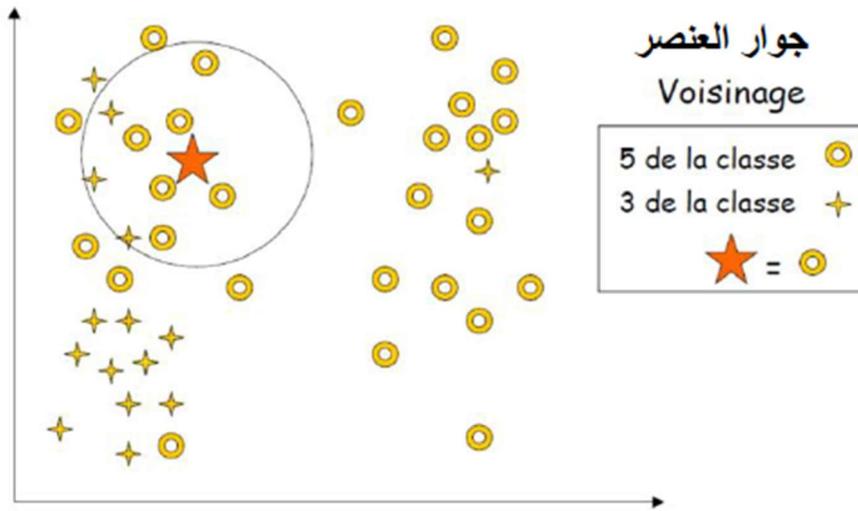
مثال: يستطيع الروبوت أن يكتسب خبرة ومعارف جديدة من المحيط (البيئة) الذي يتحرك فيه، مما يمكنه من تحسين أدائه في القيام بالوظائف المكلف بها.

## 5. خوارزميات التعلم الآلي

يعتمد التعلم الآلي على مجموعة من الخوارزميات التي طوّرت خصيصًا لتمكين الآلة من امتلاك قدرات تقترب من قدرات الإنسان في التعامل مع مختلف المشكلات المطروحة في شتى المجالات والبحث عن الحلول الأمثل والأسرع لها. من بين هذه الخوارزميات نذكر ما يأتي:

### أ- خوارزمية k-NN (k-nearest neighbors / العدد k من الجيران الأقرب)

تُعدّ هذه الخوارزمية من أبسط خوارزميات التصنيف، وتعتمد فكرتها الأساسية على تصنيف العنصر الجديد في نفس صنف العدد k من الجيران الأقرب إليه. فإن كان العدد الأكبر من الجيران ينتمي إلى الفئة (o) مثلاً، يتم تصنيفه ضمن هذه الفئة، وإن كان العدد الأكبر ينتمي إلى الفئة (+) يتمّ تصنيفه ضمنها، كما يظهر في المثال الموالي حيث نقوم بتصنيف النجمة ضمن فئة الدوائر لغلبة عدد الجيران من هذه الفئة.



تعتمد هذه الخوارزمية بشكل أساسي على مبدأ حساب المسافة بين العنصر المراد تصنيفه وباقي العناصر. وفي هذا الصدد يمكن الاعتماد على طرق كثيرة لحساب المسافة من أهمها: الجداء الداخلي (Inner Product)، المسافة الأفليدية (Euclidean distance)، تشابه جيب التمام (Cosine Similarity)، معامل دايس (Dice coefficient)، تشابه جاكارد (Jaccard Similarity)، مسافة مينكوفسكي (Minkowski distance)، إلى جانب طرق أخرى.

#### إيجابيات الخوارزمية:

- تتميز ببساطة في البرمجة وسهولة التنفيذ.
- توفر نتائج واضحة.
- إضافة بيانات جديدة لقاعدة البيانات لا تتطلب إعادة بناء النموذج من جديد.

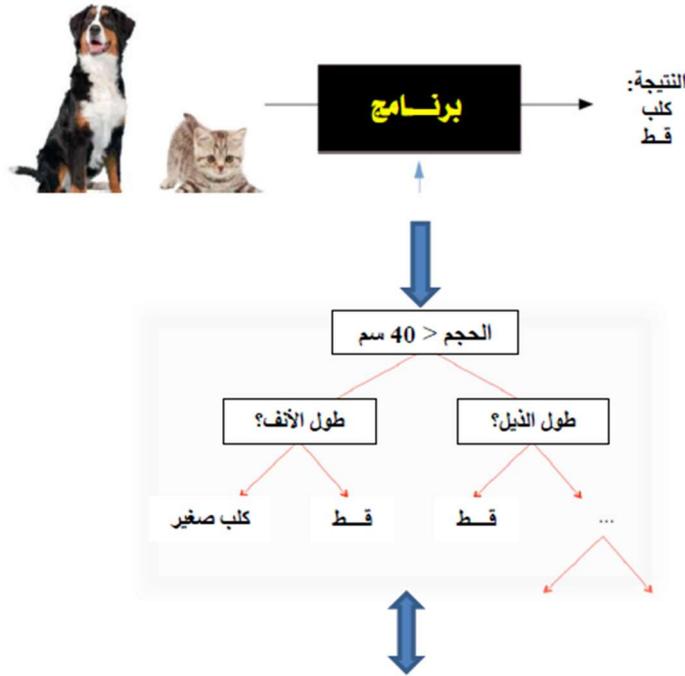
#### سلبات الخوارزمية:

- لا تعتمد على تعلم (تدريب) مسبق ولكن تقوم أساسًا على حساب مسافات.

- تتطلب عددًا معتبرًا من السمات (أمثلة، عينات، متغيرات).
- صالحة لجميع أنواع البيانات.
- ذات كلفة عالية من ناحية وقت المعالجة وسعة التخزين في الذاكرة المركزية (تخزين النموذج وحساب المسافات).

### ب- خوارزمية شجرة القرار (Decision Tree DT)

تُعدّ شجرة القرار من أقدم خوارزميات التعلم الآلي، وتعتمد على المبدأ الشهير "فرّق تَسُد"، بمعنى كلما قسّمت المسألة الرئيسية إلى مسائل فرعية أمكن التحكم فيها وحلّها بسهولة. وقد أثبتت هذه الخوارزمية فعاليتها ونجاحتها بشكل خاص في التصنيف الثنائي، أي عند تصنيف عناصر إلى واحدة من فئتين، ويتم ذلك من خلال تحديد متغير أو خاصية في كل مستوى من الشجرة يتمّ على أساسها التصنيف. فعلى سبيل المثال، إذا أردنا تصنيف مجموعة من الصور التي تمثل نوعين مختلفين من الحيوانات، فإن شجرة القرار تبدأ بتطبيق خاصية الحجم في المستوى الأول، ثم تنتقل إلى خصائص أخرى مثل طول الأنف أو الذيل في المستويات التالية، إلى أن يتم تحديد الفئة المناسبة لكل صورة بناءً على هذه المعايير.



**R1:** إذا كان (الحجم > 40 سم) و (الأنف الطويل = صحيح) فإن الكلب صغير

**R2:** إذا كان (الحجم > 40 سم) و (الأنف الطويل = خطأ) فإن القطّة

**R3:** إذا كان (الحجم < 40 سم) و (الذيل الطويل = صحيح) فإن الكلب

**R4:** إذا كان (الحجم < 40 سم) و (الذيل الطويل = خطأ) فإن القطّة صغيرة

ويمكن تحويل شجرة القرار إلى مجموعة من القواعد كل قاعدة تمثل فرعاً في الشجرة. ويلجأ إلى هذه الطريقة في الغالب من أجل تسهيل قراءة الشجرة إن كانت معقدة بعض الشيء، ومن ثمّ يتمّ التصنيف بالاستناد إلى هذه القواعد بدل الشجرة نفسها.

### بعض خوارزميات شجرة القرار الشهيرة

تمّ تطوير العديد من خوارزميات شجرة القرار التي تشارك في المبدأ والفكرة، غير أنها تختلف فيما بينها من حيث الكفاءة والقدرة على التصنيف وطريقة اختيار السمة أو المتغير الذي يتمّ على أساسه التصنيف. ومن أبرز هذه الخوارزميات: ID3، C4.5، C5 CART، CHAID.

### إيجابيات الخوارزمية:

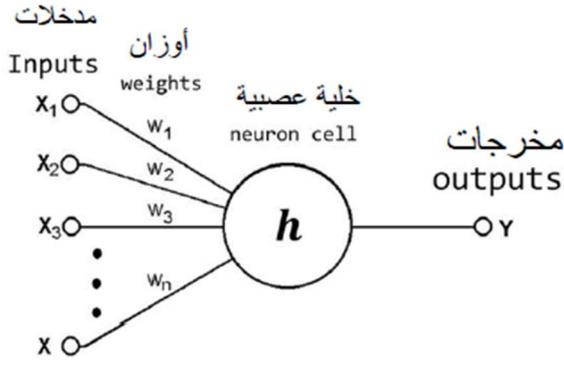
- مفهومة بالنسبة لأي مستخدم (سهولة قراءة النتيجة <قواعد - شجرة>).
- تبرير تصنيف العناصر (باستخدام المسار الموجه: الجذر ← الورقة).
- صالحة لأي نوع من البيانات.
- مقاومة لكل تشويش أو قيم مفقودة على مستوى قاعدة البيانات.
- تظهر السمات حسب ترتيب أهميتها ← وهي مهمة المعالجة المسبقة (طريقة اختيار السمات).
- تصنيف سريع (الوصول إلى مسار في الشجرة).
- أداة متوفرة في معظم بيئات استخراج ومعالجة البيانات (مثل برنامج ويكا الشهير Weka).

### سلبيات الخوارزمية:

- حساسة تجاه عدد الفئات، إذ يتراجع أداؤها تدريجيًا كلما زاد عدد الفئات المراد التصنيف ضمنها.
- لا تُعدّ الخيار الأمثل في مهام التصنيف متعدّد الفئات، وإن كان بالإمكان استخدامها في هذا السياق مع بعض التحفظات.
- على الرغم من قابليتها للتوسّع مع تطور البيانات، إلا أنّ أي تعديل جوهري في قاعدة البيانات يستلزم إعادة تنفيذ مرحلة التدريب وبناء نموذج التصنيف من جديد، كما لو أننا نتعامل مع قاعدة بيانات جديدة.

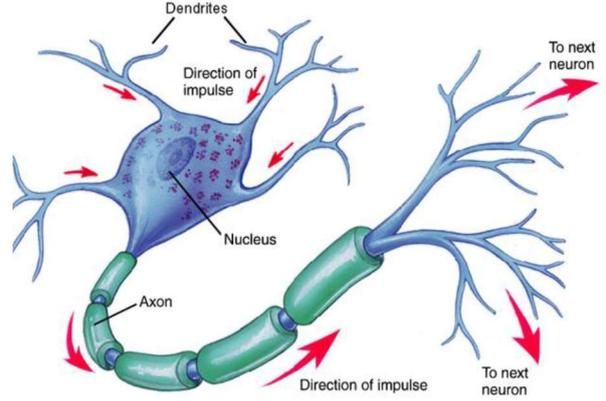
### ج- الشبكات العصبية الاصطناعية

تمّ اقتراح الشبكات العصبية الاصطناعية لأول مرة سنة 1943 من قبل و. ماكولوتش (W. McCulloch) و و. بيتس (W. Pitts)، حيث استلهمت فكرتها من الشبكات العصبية البيولوجية في دماغ الإنسان. أما في عام 1948، فقد قدّم د. هيب (D. Hebb) قاعدة التعلم للشبكات العصبية. وفي 1958، طوّر ف. روزنبلات (F. Rosenblatt) نموذج البيروسيبترون (Perceptron model). وشهد عام 1985 ظهور التعلم بالانتشار الخلفي للشبكات متعددة الطبقات (MultiLayer Perceptron MLP).

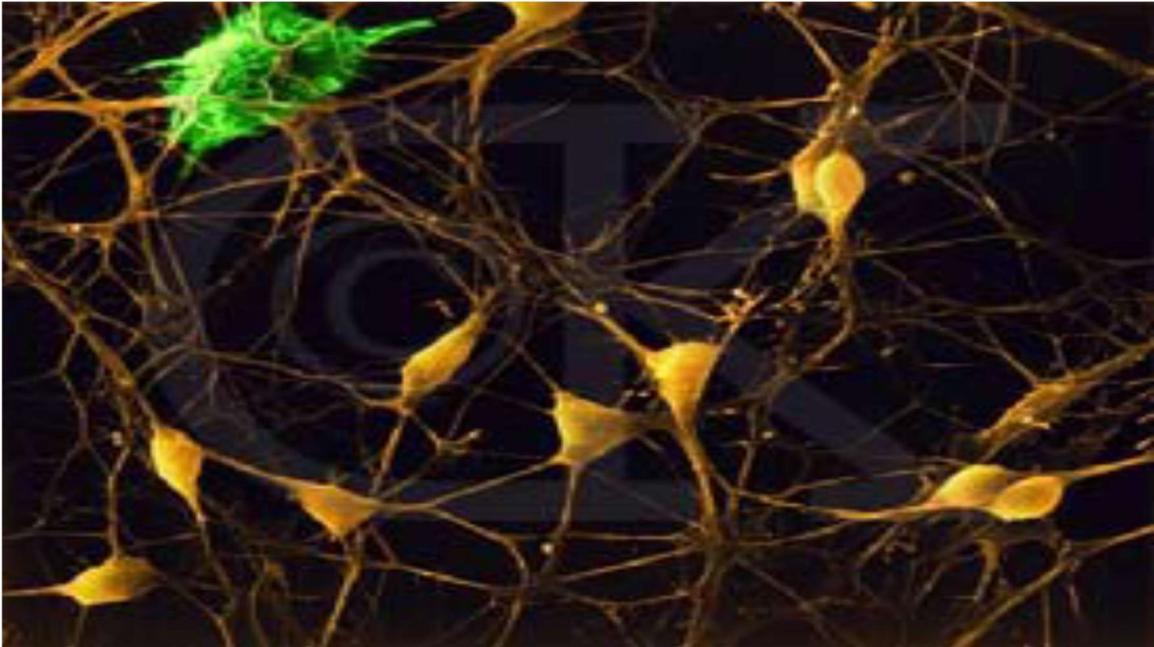


$$h = \sum_i x_i * w_i \quad y = f(h)$$

الخلايا العصبية الرسمية



الخلايا العصبية البيولوجية

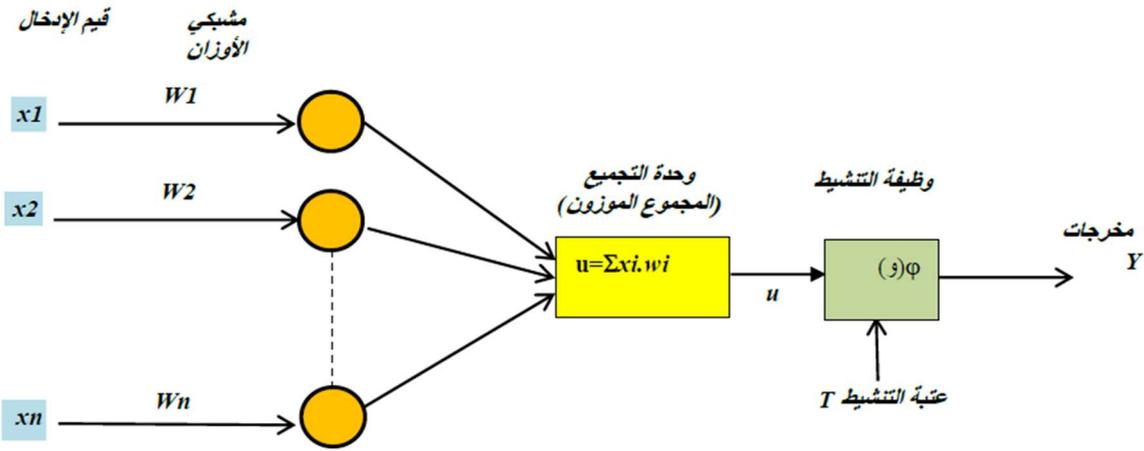


بنية الجهاز العصبي لدى الإنسان

## أرقام مهمة:

- يُقدّر عدد الخلايا العصبية في دماغ الإنسان بحوالي 100 مليار خلية عصبية ( $10^{11}$ ~)، وهو رقم يعكس التعقيد البنيوي الكبير للجهاز العصبي.
- ترتبط كل خلية عصبية بما يقارب 10,000 إلى 100,000 وصلة عصبية (Synapses)، ما يتيح شبكة اتصالات واسعة بين الخلايا.
- وبهذا، يُقدّر إجمالي عدد الروابط العصبية في الدماغ بنحو 100 تريليون وصلة، وهي روابط ديناميكية تتغير باستمرار مع النشاط العقلي والتعلم.

## الشبكات العصبية الاصطناعية (نموذج ماكولوتش-بيتس)



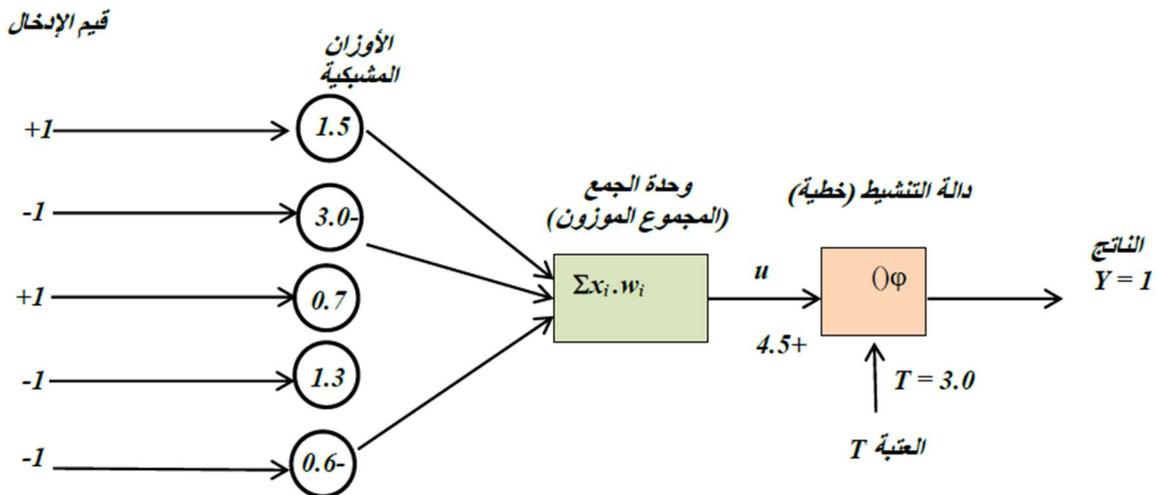
بنية الشبكات العصبية الاصطناعية (نموذج ماكولوتش-بيتس)

كيف يعمل؟ (حساب قيمة المخرج)

- تحسب الخلية العصبية الاصطناعية مجموع المدخلات  $x_1, x_2, \dots, x_n$  الموزونة بالأوزان المشبكية  $w_1, w_2, \dots, w_n$ .
- تقارنها مع العتبة  $T$ .
- إذا كانت النتيجة أكبر من الحد الأدنى  $T$ ، فإن القيمة التي يتم إرجاعها كمخرج هي  $+1$  (تنشيط الخلايا العصبية)، وإلا فإن القيمة التي يتم إرجاعها هي  $0$ .

$$y = \begin{cases} +1, & \text{if } \sum x_i \cdot w_i > T \\ 0, & \text{otherwise.} \end{cases}$$

مثال: كيف تعمل الشبكات العصبية الاصطناعية (نموذج ماكولوتش-بيتس)



ملاحظة: توجد عدة أنواع من وظائف التنشيط، مثل: Linear Function، sigmoid، tanh، ReLU، وELU، Softsign، Softplus، وSoftmax.

## إيجابيات الخوارزمية:

- تُعطي على العموم دقة تصنيف عالية جدًا.
- متوفرة ضمن أشهر بيئات معالجة البيانات واستخراج المعلومات الشهيرة، مثل Weka.
- تُعدّ مقاومة لكل تشويش أو قيم مفقودة على مستوى قاعدة البيانات.
- توفّر تصنيفًا سريعًا إذا كان النموذج الذي تمّ بناؤه فعالاً.
- يمكن المزاوجة بينها وبين خوارزميات أخرى مثل شجرة القرار أو خوارزمية بايز.

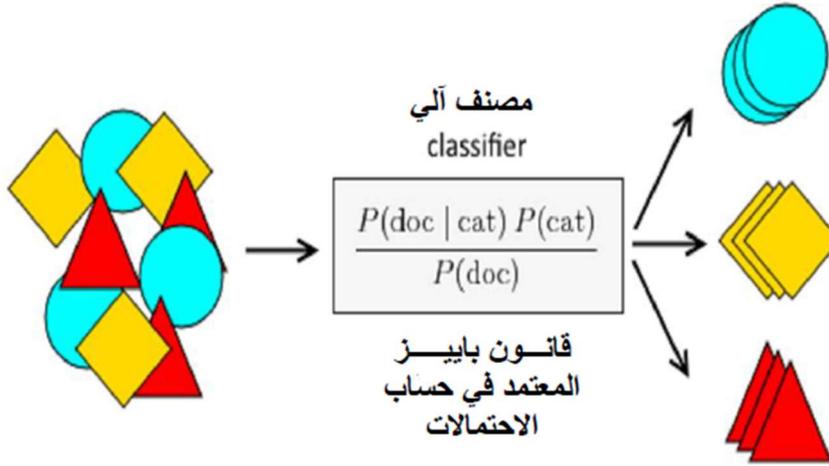
## سلبيات الخوارزمية:

- تتطلب مرحلة التدريب وقتًا طويلًا جدًا وكمًا هائلًا من البيانات من أجل بناء نموذج فعال للتصنيف.
- تتطلب التعامل مع وسائط متعددة خلال مرحلة بناء النموذج، مثل البنية العامة، المعاملات المشبكية، عدد الطبقات، عدد الخلايا العصبية في كل طبقة.
- تفتقر إلى القدرة التفسيرية، فهي مثل الصندوق الأسود لا نرى ما يحدث بداخله.
- صعوبة دمج معارف إضافية تتعلق بالمجال.
- قابلة للتوسيع مع الوقت، خاصة مرحلة التدريب.

## د- خوارزمية بايز (Bayesian Algorithm)

كيف تعمل؟ (الفكرة الرئيسية)

التنبؤ بفرضيات متعددة محدّدة مسبقًا، بناءً على احتمالاتها.



كيف يتم إسناد عنصر إلى فئة؟ (التصنيف الآلي لعنصر ما)

لتصنيف عنصر ما ضمن مجموعة فئات نتبع الخطوات التالية:

- نقوم بحساب الاحتمال  $P(C_i|X)$  وهو احتمال انتساب العنصر  $X$  إلى الفئة  $C_i$ ، حيث:
- $X = \langle x_1, x_2, \dots, x_n \rangle$ ,  $C_i = C_1, C_2, \dots$
- يتم حساب الاحتمالات وفق قانون بايز التالي:

$$P(C_i|X) = \frac{P(X|C_i) \cdot P(C_i)}{P(X)}$$

- $P(X)$ : هو احتمال ثابت بالنسبة لجميع الفئات (احتمال ظهور العنصر  $X$  في قاعدة البيانات).
- $P(C_i)$ : التردد النسبي للفئة  $C_i$  ضمن مجموعة البيانات (عدد تكرارات الفئة  $C_i$  في مجموعة البيانات).
- $P(C_i|X)$ : احتمال انتساب العنصر  $X$  إلى الفئة  $C_i$ ، وتكون قيمته قصوى إذا كانت القيمة  $P(X|C_i) \cdot P(C_i)$  قصوى.
- مع مراعاة فرضية بايز التالية:

$$P(X|C_i) = P(x_1, \dots, x_k|C_i) = P(x_1|C_i) \cdot \dots \cdot P(x_k|C_i).$$

- يُسند العنصر  $X$  إلى الفئة  $C_i$  التي تحقق أعلى قيمة للاحتمال الشرطي  $P(C_i|X)$ .
- مثال: لو افترضنا وجود ثلاث فئات هي:  $C_1, C_2, C_3$ ، ونرغب في تصنيف العنصر  $X$ ، وبعد حساب الاحتمال  $P(C_i|X)$  حصلنا على القيم التالية:

$$P(C_3|X) = 0.75, P(C_2|X) = 0.60, P(C_1|X) = 0.45,$$

فإن العنصر  $X$  يُصنّف ضمن الفئة الموافقة لأعلى احتمال وهي الفئة  $C_3$ .

#### إيجابيات الخوارزمية:

- تتميز بسرعة الأداء، مما يُساهم في تقليص الزمن المستغرق في عملية التصنيف.
- تُعدّ الأفضل في حالة التصنيف متعدد الفئات.
- لا تتطلب حجماً كبيراً من بيانات التدريب، ومع ذلك توفر دقة تصنيف عالية.
- أكثر ملاءمة للتعامل مع المتغيرات الفئوية مقارنة بالمتغيرات الرقمية.

#### سلبيات الخوارزمية:

- تفترض هذه الخوارزمية استقلالية السمات (المتغيرات) عن بعضها البعض، وهو افتراض غالباً ما لا يتحقق في الواقع العملي، مما يجعل استخدامها محدوداً في بعض الحالات.
- تواجه مشكلة ما يُعرف بـ "التردد الصفري"، والتي تحدث عندما يُعطى لمتغير فئوي احتمال صفري.
- قد تُفضي إلى تقديرات خاطئة في بعض الأحيان، لذا ينبغي التعامل مع مخرجاتها بحذر.

#### هـ- بعض الخوارزميات الأخرى:

- خوارزمية آلة الدعم المتجهي (Support Vector Machine)،
- الخوارزمية الجينية (Genetic Algorithm)،
- خوارزمية AdaBoost

رابط الجزء الأول من المقال: <https://www.ens-kouba.dz/magazine/pdf/n10/article10-9.pdf>