

## إمكانية تطبيق بعض تقنيات التعلم العميق في ضبط جودة المنتجات / دراسة حالة

### The Possibility of Applying Deep Learning Techniques in Product Quality Control / Case Study

أ.م. د. علي عبد الكريم الصفار  
 Asst. Prof. Dr. Ali  
 Abdul Kareem Al-  
 Saffar  
 مركز التعليم المستمر/ الجامعة  
 التقنية الوسطى/ بغداد/ العراق  
 dr.ali.abdulla@mtu.edu.

أ.د. نشأت جاسم محمد  
 Prof. Dr. Nashaat Jasim  
 Mohammed  
 قسم تقنيات إدارة الأعمال/الكلية التقنية  
 الإدارية - بغداد / الجامعة التقنية الوسطى/  
 بغداد/ العراق  
 Dr.nashaat@mtu.edu.iq

جاسم راضي منصور  
 Jasim Radhi Mansoor  
 قسم تقنيات إدارة الأعمال/الكلية  
 التقنية الإدارية - بغداد / الجامعة  
 التقنية الوسطى/  
 بغداد/ العراق  
 dcc2023@mtu.edu.iq

#### المستخلص.

تناولت الدراسة حالة الإنتاج وحل مشاكل العيوب وضبط الجودة في قسم الصوابين بمصنع المأمون التابع للشركة العامة للمنتجات الغذائية باستخدام خوارزميات وتقنيات التعلم العميق. تم تحديد مشكلة البحث في إنتاج معيب وضعف أداء قسم ضبط الجودة واقتقاره للتقنيات الحديثة. لاختيار معايير ضبط جودة الصابون السائل، تم التركيز على: المادة الفعالة (NaCl)، واللزوجة (viscosity)، الدالة الحامضية (pH)، والأملاح (AD). وتم استخدام برنامج MATLAB - Ver 2024 لتطبيق خمس خوارزميات، وهي خوارزمية أشجار القرار، وخوارزمية مصنف بيز، وخوارزمية الشبكة العصبية الالتفافية، وخوارزمية الشبكة العصبية الاصطناعية، والنموذج اللوجستي فضلاً عن استخدام برنامج SPSS-Ver.28. وأظهرت النتائج أن من بين 206 قنينة صابون سائل تم اختيارها عشوائياً، كانت 155 قنينة مطابقة للمواصفات و51 غير مطابقة، مما يشكل نسبة 25% من العينة. وبينت الدراسة أن خوارزمية أشجار القرار هي الأفضل في تحديد مسببات العيوب ودقة التصنيف لها. وتتضمن أهداف هذه الدراسة تحسين جودة الإنتاج باستخدام تقنيات التعلم العميق، وتحديد أسباب العيوب بدقة، وتقليل الهدر والتكاليف، وبناء نظام خبير لضبط الجودة بشكل آلي، وزيادة وعي المسؤولين بالتقنيات الحديثة. تكتسب الدراسة أهمية كبيرة من خلال إثراء المعرفة العلمية في هذا المجال، وإدراك أهمية تقنيات التعلم العميق في تقليل العيوب واعتماد تقنيات حديثة لتقليل الوقت والجهد في الفحص.

الكلمات المفتاحية: التعلم العميق، خوارزمية شجرة القرار، خوارزمية مصنف بيز، خوارزمية الشبكة العصبية الالتفافية، خوارزمية الشبكة العصبية الاصطناعية، النموذج اللوجستي

#### Abstract:

This study addresses the production status, defect resolution, and quality control issues in the soap department of Al-Maamoun Factory, part of the General Company for Food Products, using deep learning algorithms and techniques. The research problem was identified as defective production and the poor performance of the quality control department, which lacks modern technologies. To select the quality control criteria for liquid soap, the focus was on active ingredient (NaCl), viscosity, pH, and salts (AD). MATLAB - Ver 2024 was used to apply five algorithms: decision tree, Naive Bayes classifier, convolutional neural network, artificial neural network, and logistic model, along with SPSS-Ver.28. The results showed that out of 206 randomly selected bottles of liquid soap, 155 were compliant with specifications and 51 were non-compliant, constituting 25% of the sample. The study revealed that the decision tree algorithm is the best in identifying defect causes and classification accuracy. The objectives of this study include improving production quality using deep learning techniques, accurately identifying defect causes, reducing waste and costs, building an expert system for automated quality control, and raising awareness among officials about modern technologies. The study is significant for enriching scientific knowledge in this field, recognizing the importance of deep learning techniques in reducing defects, and adopting modern techniques to reduce inspection time and effort.

**Keywords:** Deep Learning, Decision Tree Algorithm, Bayes Classifier Algorithm, Convolutional Neural Network Algorithm, Artificial Neural Network Algorithm

## 1. مقدمة

تواجه المنظمات عقبات تؤثر سلباً على منتجاتها، مثل الاعتماد على الفحص لضبط الجودة، وهو أسلوب قديم غير ملائم لعصر تكنولوجيا المعلومات الحديثة. لذلك، تتجه المنظمات لاستخدام تقنيات مؤتمنة عالية الدقة والسرعة لحل مشكلات تعجز الأنظمة التقليدية عن حلها. ومع تطور أجهزة الحاسوب وتسجيل البيانات، تراكمت كميات كبيرة من البيانات، وأصبح تحليلها وتنظيمها تحدياً. لذا، أصبح تحليل البيانات وتحولها إلى معلومات محور اهتمام تكنولوجيا المعلومات، وتم تطوير تقنيات تنقيب البيانات (Data Mining)، تعلم الآلة (Machine Learning)، والتعلم العميق (Deep Learning) لتحويل البيانات إلى معلومات دقيقة بسرعة وتوظيفها في جميع مجالات العمل. وتعد مرحلة فحص المنتجات جزءاً مهماً في إدارة الجودة لضمان مطابقة المواصفات، وغالباً ما تُجرى الفحوصات يدوياً. مهام التصنيف في التعلم العميق تستخدم متغيرات كمية أو وصفية لتصنيفها وفق معايير محددة بدقة وسرعة، ويمكن برمجتها ضمن نظام معالجة المعلومات لإعطاء النتائج آلياً. وتهدف هذه الدراسة إلى توظيف تقنيات التصنيف ضمن التعلم العميق لبناء نظام خبير لتحديد أسباب الانحرافات في إنتاج أحد منتجات الصابون السائل، وتشخيص الخلل في العملية الإنتاجية. والدراسة تطبق في الشركة العامة للمنتجات الغذائية، قسم الصابون السائل، لمعالجة مشاكل ضبط الجودة.

تقسم الدراسة إلى خمس مباحث:

1. منهجية الدراسة
2. الجانب النظري حول نظم المعلومات والتعلم العميق وضبط الجودة
3. الجانب العملي وتطبيق الشبكة العصبية الصناعية في ضبط جودة المنتجات
4. الاستنتاجات
5. التوصيات

## 2. منهجية البحث

## 2.1 أهمية الدراسة

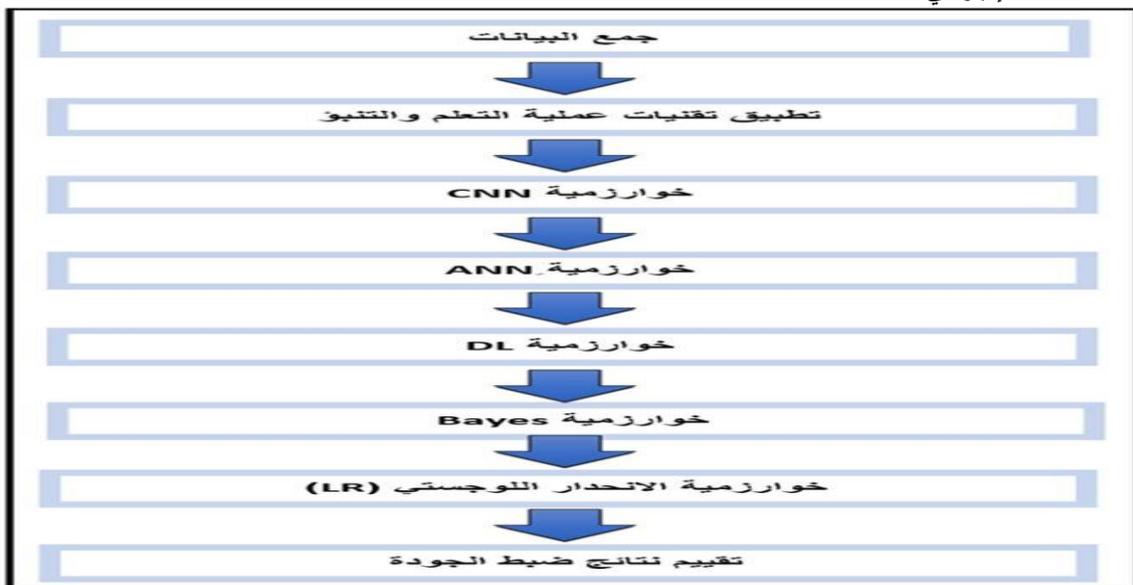
1. اثراء المكتبات في موضوع تقنيات التعلم العميق في ضبط جودة المنتج وتحسينه.
2. تمثيل تقنيات والبيات التعلم العميق حقلاً جديداً في مجال التنبؤ بمشكلات المعيب وحلها وضبط جودة الإنتاج في الشركة.
3. إدراك المسؤولين في الشركة أهمية تقنيات والبيات التعلم العميق في ضبط جودة المنتج وتقليل الوحدات المعيبة.
4. محاولة اعتماد نموذج تقنيات الشبكات العصبية الذي يسهم في تحقيق ضبط جودة المنتج والتحول من عمليات الفحص التقليدية إلى تطبيق تقنيات حديثة حاسوبية تقلل الوقت والجهد في عمليات الفحص.

## 2.2 أهداف الدراسة Study Objective

تسعى الدراسة إلى تحقيق جملة أهداف عبر الآتي:

1. استعراض مفاهيم تقنيات التعلم العميق ومفاهيم ضبط جودة المنتج.
2. تحديد أدوات ضبط جودة المنتج في الشركة.
3. استخدام خوارزميات التعلم العميق - تقنية الشبكات العصبية الاصطناعية والشبكة الالتفافية وشجرة القرارات ومصنّف بيز وبالتجربة التعرف إلى أيهما أفضل واعتمادها لضبط جودة المنتج.
4. محاولة إيجاد الحلول للعقبات التي تؤدي إلى انحراف ضبط جودة المنتج ومعالجتها حاسوبياً.

## 2.3 المخطط الإجرائي



الشكل 1: المخطط الإجرائي لمسار الدراسة

المصدر: إعداد الباحث

## 2.4 مشكلة الدراسة

تحتاج الشركات إلى حلول مبنية على المعرفة لضبط جودة الإنتاج. الفحص التقليدي لا يكفي لتشخيص الخلل أو اقتراح حلول لتحسين الأداء، مما يستدعي البحث في تقنيات حديثة لضبط الجودة. بناء نظام خبير باستخدام تقنيات التعلم العميق يمكن أن يقلل الهدر في المواد الأولية والعيوب في المنتجات. الأسئلة الرئيسية للدراسة تشمل:

1. مدى معرفة الشركة بتقنيات التعلم العميق لضبط الجودة.
2. أدوات ضبط الجودة المستخدمة.
3. تأثير تقنيات التعلم العميق على ضبط جودة المنتجات.
4. إمكانية وضع نموذج يوضح إجراءات وآليات تقنية محددة لضبط الجودة وتطبيقها في الشركة.

## 2.5 حدود الدراسة

تتضمن الحدود المكانية والزمانية للدراسة الآتي:

1. الحدود المكانية  
اختيرت شركة الصناعات الغذائية وبالخصوص قسم الصوابين السائلة (الصابون السائل لتنظيف الاواني – الزاهي) التابع لمصنع المأمون مكاناً لإجراء الدراسة.

### 2. الحدود الزمانية

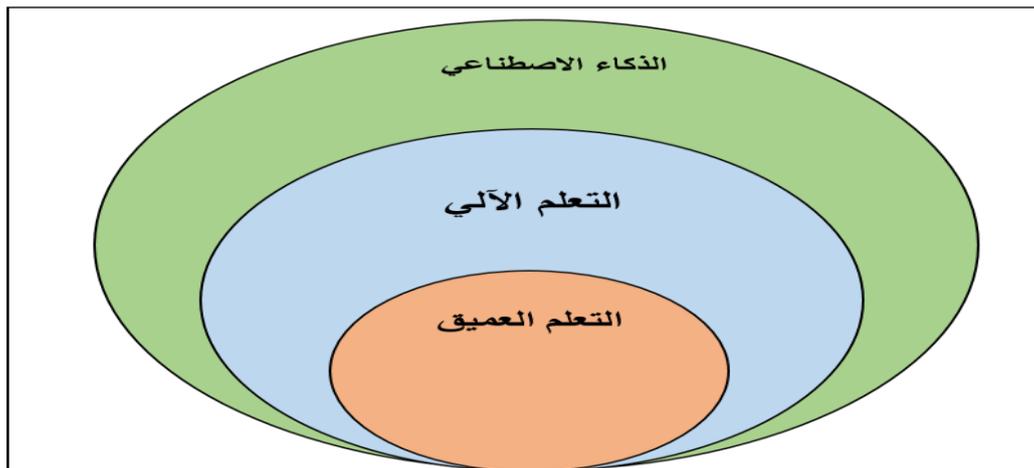
شملت الفترة للحصول على البيانات لعينة الدراسة لجزء من شهر تشرين الأول وتشرين الثاني وكانون الأول ولمدة (80) يوماً لأيام العمل الفعلية للربع الأخير لعام (2023) وهي مدة المعاشة الميدانية التي قضاها الباحث للحصول على البيانات اللازمة في الشركة.

### 3. الإطار المفاهيمي

#### 3.1 التعلم الآلي

أدى التطور التكنولوجي إلى تقليل الجهد البشري في مختلف المجالات، خصوصاً في تعلم الآلة (ML). يُعرف التعلم وفقاً لـ Vazan (2021: 41) بأنه "تحسين الأداء في مهمة معينة باستخدام الخبرة والممارسة". التعلم الآلي هو برنامج كمبيوتر يحسن أدائه بناءً على تجارب معينة. تطورت الأنظمة التكنولوجية في السنوات الأخيرة إلى أنظمة مؤتمتة وديناميكية، وهذا التطور يسمى التعلم الآلي (Machine Learning)، وهو فرع من الذكاء الاصطناعي يهتم بتطوير وتصميم خوارزميات وتقنيات رياضية تعمل على التنبؤ بالقرارات باستخدام البيانات المتوفرة (Njoku, 2019: 36). يسمح التعلم الآلي لبرامج الكمبيوتر باتخاذ قرارات دون برمجتها صراحة باستخدام خوارزميات تركز على التنبؤات. تطورت دراسة التحسين الرياضي ومجالات تطبيقه في التعلم الآلي لاستخراج البيانات (Ogunleye & Wang, 2019: 13).

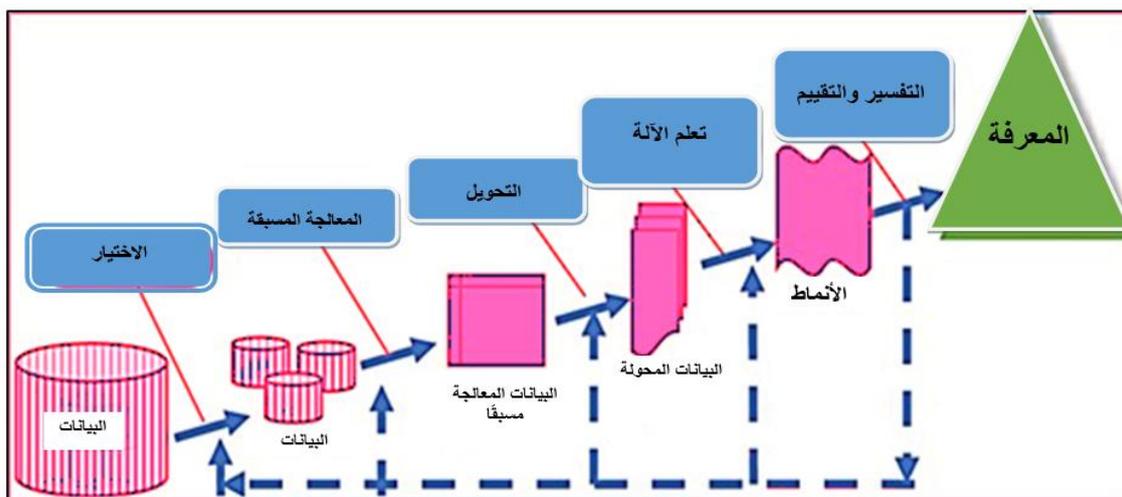
ويوضح الشكل 1 التعلم الآلي (Machine Learning) الذي يعد جزءاً من خوارزميات الذكاء الاصطناعي (Artificial Intelligence).



الشكل 1: العلاقة بين الذكاء الاصطناعي والتعلم الآلي والتعلم العميق

Source: Dogan, A., & Birant, D. (2021). Machine learning and data mining in manufacturing. Expert Systems with Applications, 166, 114060.

خوارزميات التعلم الآلي تتمثل في خطوات منطقية موضحة في الشكل 2.



الشكل 2: مراحل تعلم الماكينة وادخال ومعالجة البيانات الأولية

Source: Capuano, G., & Rimoli, J. J. (2019). Smart finite elements: A novel machine learning application. *Computer Methods in Applied Mechanics and Engineering*, 345, 363-381.

من ذلك نلاحظ "أداء المهام التي لم يتم التخطيط لها بشكل صريح، ويتم تحسين أداء الجهاز تلقائياً من خلال الخبرة في أداء هذه المهمة". تحول التعلم الآلي إلى قوة صناعية رئيسية في صنع القرار الآلي بفضل قدرته على التعلم من البيانات المصنفة وغير المصنفة، مما يساعد في اتخاذ قرارات دقيقة. يمكن تقسيم خوارزميات تعلم الآلة إلى أربعة أقسام: التعلم الخاضع للإشراف، التعلم غير الخاضع للإشراف، التعلم المعزز، والتعلم العميق (Vazan, 2021: 44).

### 3.2 التعلم العميق

التعلم العميق هو نوع من التعلم الآلي، جزء من الذكاء الاصطناعي، يستخدم لتقليد الطريقة التي يكتسب بها العقل البشري أنواعاً معينة من المعرفة. العلماء صمموا خوارزميات مستوحاة من الدراسات العصبية الطبية لتقليد عمل العقل البشري بطرق حاسوبية. تشمل هذه الخوارزميات الشبكات العصبية الالتقافية والتكرارية. خوارزمية CNN (الشبكات العصبية التلافيفية) تُعتبر من أنجح خوارزميات التعلم العميق، وتُستخدم في التنبؤ، تمييز الأنماط، وعمل المصنفات (Glackin et al., 2018: 34).

### 3.3 خوارزميات التعلم العميق

#### 3.3.1 خوارزمية أشجار القرار

شجرة القرار هي تقنية تعلم إحصائي تُستخدم في مشاكل الانحدار والتصنيف، وتتميز بقدرتها على التنظيم الذاتي وإعادة ترتيب البيانات أثناء التعلم وتصحيح الأخطاء (عبد العزيز، 2006: 119-133). كما تتمتع بالقدرة على التعلم التكيفي ومعالجة آلاف الحالات وتصنيفها في الوقت الحقيقي (Jiawei & Micheline, 2006) عن (Abdelwahab, 2018: 43). تُستخدم أشجار القرار كمية كبيرة من المعلومات لاستنتاج القرارات، وتعتمد على شكل هرمي يبدأ من الجذر (root) وينتهي بالأوراق (leafe)، حيث تمثل العقد (nodes) المتغيرات، بينما تمثل الأوراق نتائج القرارات (Rashed, 2022: 30).

#### أنواع العقد في شجرة القرار:

1. عقدة الجذر: هي العقدة الأولى التي تتفرع منها باقي العقد.

2. عقدة القرار: يتم فيها اختبار السمات وتحتوي على عقد فرعية.

3. العقدة الطرفية: تمثل النتائج النهائية وتقع في أوراق الشجرة.

تُستخدم أشجار القرار على نطاق واسع في تصنيف الإنتاج الجيد والمعييب ومعالجة كميات ضخمة من البيانات (Masethe & Masethe, 2014) عن (Rashed, 2022: 31). من أشهر أنواع أشجار القرار:

#### 1. خوارزمية C4.5

ظهرت هذه الخوارزمية لتحسين خوارزمية ID3، وتعمل تحت إشراف (Supervised) لتصنيف المشاكل المعقدة إلى أجزاء أبسط (AI-Qaragholi, 2021: 4). وتُستخدم لتقييم خوارزميات التصنيف الأخرى من خلال قياس اكتساب المعلومات (Information Gain)، معتمدة على مقياس (Shannon Entropy).

#### 2. خوارزمية تعزيز التدرج الأقصى

تعمل خوارزمية XGBoost على تكوين نماذج جديدة تتنبأ بالمتبقي من النماذج القديمة، وتستند إلى تقنية أشجار القرار لتقليل دالة الخسارة (Ogunleye & Wang, 2019: 15). وتتميز بالسرعة والتعامل مع بيانات متنوعة وكبيرة، وتستخدم ثلاث تقنيات (التعزيز المتدرج، التعزيز المنتظم، والتعزيز العشوائي) لتحسين البيانات والتنبؤ بدقة عالية (Dhaliwal, Nahid, & Abbas, 2018: 14). المعادلات الأساسية:

▪ معادلة دالة الخسارة الأولى:

$$L_{xgb} = \sum_{n=1}^N L(y_i, F(x_i)) + \sum_{m=1}^M \Omega(h_m) \dots 1$$

▪ معادلة دالة الخسارة الثانية:

$$\Omega(h) = \gamma t + \frac{1}{2} \lambda \|w\|^2 \dots 2$$

تساعد هذه الخوارزمية في تقليل الجهد والوقت، وتحسين الأخطاء باستخدام تقنية التعزيز وإضافة أوزان محددة للنموذج (Mishra et al, 2018: 156).

### 3.3.2 خوارزمية مصنف نييف بيز

تعد خوارزمية نييف بيز من الخوارزميات الاحتمالية المستخدمة في تصنيف النصوص تحت إشراف، حيث تعتمد على مبدأ الاحتمال لتوقع الأحداث بناءً على البيانات المتوفرة، مع افتراض استقلالية المدخلات وثبات العلاقة بينها وبين المخرجات، مما يتيح نتائج دقيقة وسريعة (Adam et al., 2011).

#### 3.3.2.1 مميزات خوارزمية نييف بيز

تتميز هذه الخوارزمية بالبساطة والقوة في إعطاء نتائج دقيقة وعالية السرعة، وتستخدم بشكل واسع في تصنيف النصوص والتنبؤ، حيث تعتمد على كميات كبيرة من البيانات السابقة (Dhaliwal, Nahid, & Abbas, 2018: 149).

#### 1- مبدأ العمل

تفترض الخوارزمية أن تأثير قيمة الصفة على الصنف المعين مستقل عن قيم الصفات الأخرى، ويسمى هذا بالاستقلال الشرطي للصنف (class conditional independence) (Jiawei & Micheline, 2006: 30).

#### 2- طريقة التقدير

تستخدم الخوارزمية طريقة التعلم لتقييم احتمالية الأصناف أثناء التنبؤ، وتستخدم توزيع كاوس للمتغيرات المستمرة وفقاً للمعادلة:

$$f(x|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) \dots 3$$

#### 3- قانون بيز Bayes

تعتمد الخوارزمية على قانون بيز لحساب الاحتمال اللاحق:

$$P(H|X) = \frac{P(X|H)P(H)}{P(X)} \dots 4$$

#### 4- التنبؤ

يتنبأ المصنف بالصنف الذي يمتلك أعلى احتمال لاحق بين الأصناف المتاحة

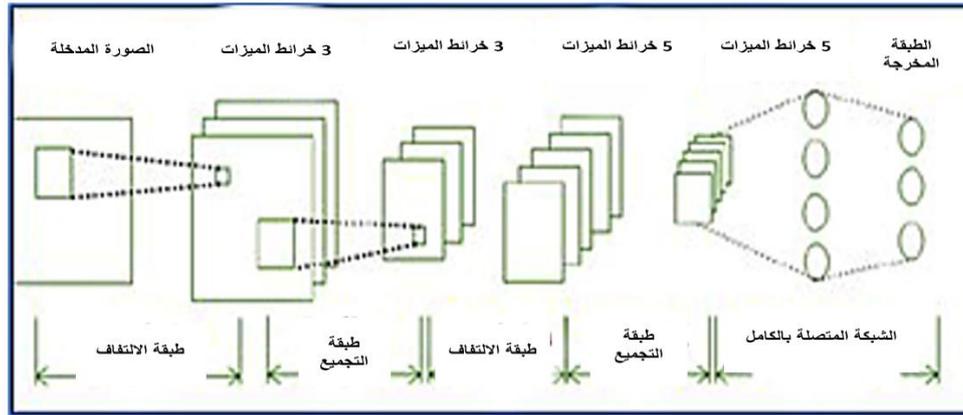
$$P(X|Ci)P(Ci) > P(X|Cj)P(Cj) \text{ for } 1 \leq j \leq m, j \neq i$$

### 3.3.3 الهيكل العام لخوارزمية الشبكة العصبية الالتفافية

الشبكة العصبية الالتفافية (CNN) أحد أنواع التعلم العميق (الشبكات العصبونية العميقة)، تتألف من عدة طبقات مثل الشبكات العصبية الأخرى وهذه الطبقات هي (Glackin et al., 2018: 34):

1. طبقة الإدخال: إدخال البيانات.
  2. الطبقة الالتفافية: استخدام نواة الالتفاف أو ما يسمى الفلتر لرسم الخرائط واستخراج المعالم.
  3. طبقة التحفيز: الالتفاف عملية خطية، لذا يجب إضافة الخرائط غير الخطية.
  4. طبقة التجميع: تقليل كمية حساب البيانات، أخذ العينات، والمعالجة المتفرقة لخرائط المعالم.
  5. طبقة متصلة بالكامل: عادةً في ذيل الشبكة يتم تجديدها لتقليل فقد معلومات الميزة.
- وهناك ثلاث خصائص للشبكة العصبية الالتفافية:

- (1) الاتصال المحلي: كل خلية عصبية متصلة بجزء صغير من الخلايا العصبية ولم تكن متصلة بجميع الخلايا العصبية في الطبقة العليا، وهذا يقلل الكثير من المعلمات.
- (2) مشاركة الوزن: يمكن أن تشترك مجموعة من الاتصالات في نفس الوزن، بدلاً من أن يكون لكل اتصال وزن مختلف، هذا يقلل من العديد من المعلمات.
- (3) الاختزال: يستخدم التجميع لتقليل عدد العينات في كل طبقة وتقليل عدد المعلمات، وهذا يحسن مناعة النموذج. ويوضح الشكل 3 الشبكة العصبية الالتفافية.



الشكل 3: الشبكة العصبية الالتفافية في التصنيف

Source: Chien, H. C., Yu, J., Zhu, B., Shi, J., Cai, Y., Xiao, X., ... & Chen, Y. (2018, September). Probabilistically shaped DP-64QAM coherent optics at 105 Gbd achieving 900 Gbps net bit rate per carrier over 800 km transmission. In 2018 European Conference on Optical Communication (ECOC) (pp. 1-3). IEEE.

**3.3.3.1 بنية أو مكونات الشبكات العصبونية الالتفافية**  
تتكون الشبكات العصبونية الالتفافية من عدة طبقات رئيسية:

#### 1. طبقة الالتفاف

تعد من أهم الأجزاء في CNN وتستخدم كطبقة أولى عادة. تتولى معظم الحمل الحسابي وتستخدم مرشحات لاستخراج الصفات من البيانات. تتضمن المكونات الأساسية:

- 1) صورة الإدخال
- 2) كشف الميزات
- 3) خريطة الميزات

#### 2. طبقة التجميع

تقلل حجم خرائط التفعيل وتستخدم بشكل دوري بين طبقتين. تشمل نوعين:

- 1) التجميع بالقيم الأقصى (Max-pooling)
- 2) التجميع المتوسط (Average pooling)

#### 3. طبقة الارتباط الكامل

توجد في النهاية وتتكون من مرحلتين: استخراج الميزات والتصنيف. ترتبط كل عصبونة بالعقد السابقة وتتم عملية التصنيف النهائية.

#### 3.3.4 الشبكات العصبونية الاصطناعية

أول من وضع مفهوم الشبكات العصبونية كان في عام 1943 (Al-Qaragholi, 2021: 4). بدأت باستخدامها حتى منتصف عام 1980، وهي نظام حسابي يتكون من وحدات معالجة مترابطة وديناميكية في معالجة البيانات (Atiya, 2022: 18). تعتمد الشبكات العصبونية على المحاكاة لحل مشاكل يصعب حلها بالطرائق التقليدية، مثل تصنيف الأنماط، وتستخدم في مجالات متعددة مثل المالية، الطب، الهندسة، والكيمياء.

الشبكات العصبونية الاصطناعية (ANN) هي نوع من الذكاء الاصطناعي يشبه سلوك العقل البشري في التعلم والمعرفة، وتتكون من طبقات إدخال، طبقات مخفية، وطبقات إخراج (Azarang, Hansen, & Kehtarnavaz, 2019: 18). تتكون من وحدات معالجة تُسمى العقد أو العصبونات، وتخزن المعرفة التجريبية باستخدام الأوزان التشابكية، مما يجعلها قادرة على معالجة وتصنيف كميات كبيرة من البيانات بفعالية أكبر من الطرق التقليدية (Pelikan et al., 2011: 6).

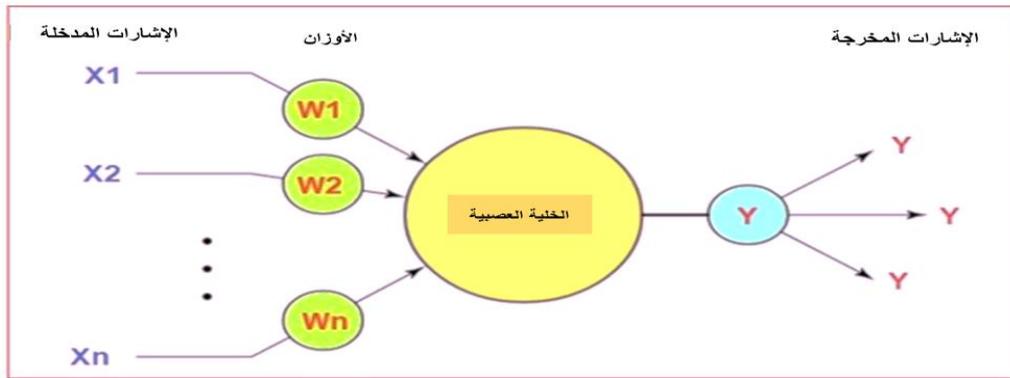
#### 3.3.4.1 أنواع الشبكات العصبونية:

##### 1. الشبكات وحيدة الطبقة

تتكون من طبقتين: وحدات الإدخال ووحدات الإخراج، والأوزان تُحدد بخوارزمية معينة، والإشارات تتدفق باتجاه إمامي (AI- (Qaragholi, 2021: 18).

##### 2. الشبكات متعددة الطبقات

تحتوي على طبقة أو أكثر من الطبقات الوسيطة (المخفية)، وتتميز بقدرتها على حل مشاكل أكثر تعقيداً بفضل مرونة الطبقات الوسيطة في بناء دالة التنشيط بين وحدات المدخلات والمخرجات (Abdelwahab, 2018: 23).

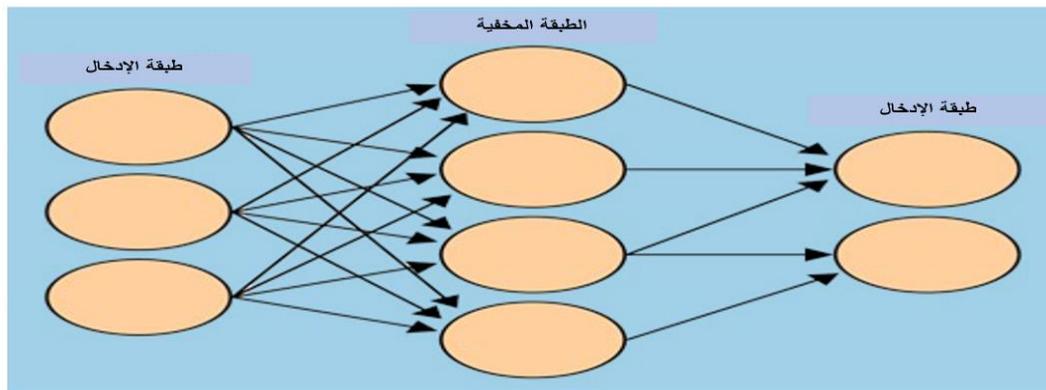


الشكل 4: مكونات الشبكة العصبية الاصطناعية

Source: Masethe, H. D., & Masethe, M. A. (2014, October). Prediction of heart disease using classification algorithms. In Proceedings of the world Congress on Engineering and computer Science (Vol. 2, No. 1, pp. 25-29).

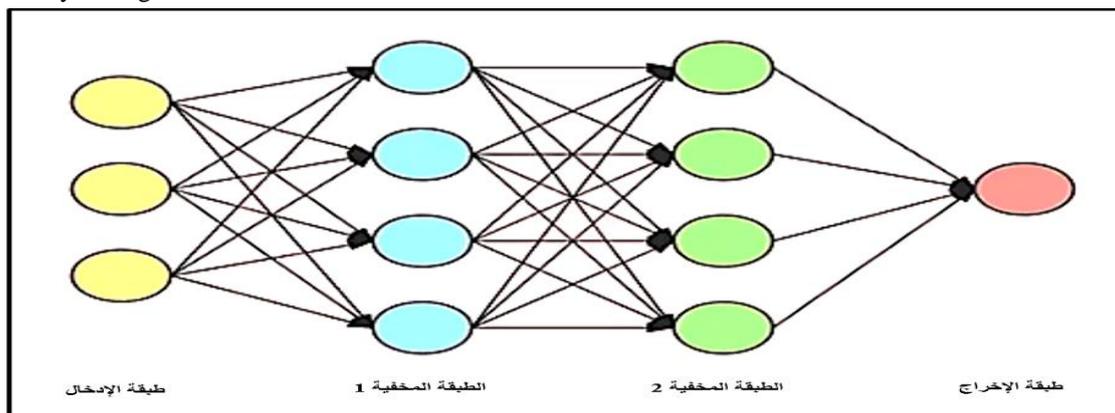
### 3.3.4.2 أنواع الشبكات العصبية الاصطناعية 1. الشبكات العصبية ذات التغذية الأمامية

تعد من أكثر الشبكات استخداماً، تتكون من طبقتين على الأقل: المدخلات والمخرجات، بدون حلقات مغلقة. تنتقل العمليات الحسابية من طبقة المدخلات إلى طبقة المخرجات مروراً بالطبقة المخفية التي تكون عادة بينهما. يمكن أن تحتوي على طبقة واحدة أو أكثر من الطبقات المخفية (Ashour, 2019: 23).



الشكل 5: نموذج شبكة عصبية ذات تغذية أمامية بطبقة مخفية واحدة

Source: Ashour, M. A. (2019). Artificial neural networks and time series forecasting methods (PhD thesis). University of Baghdad.

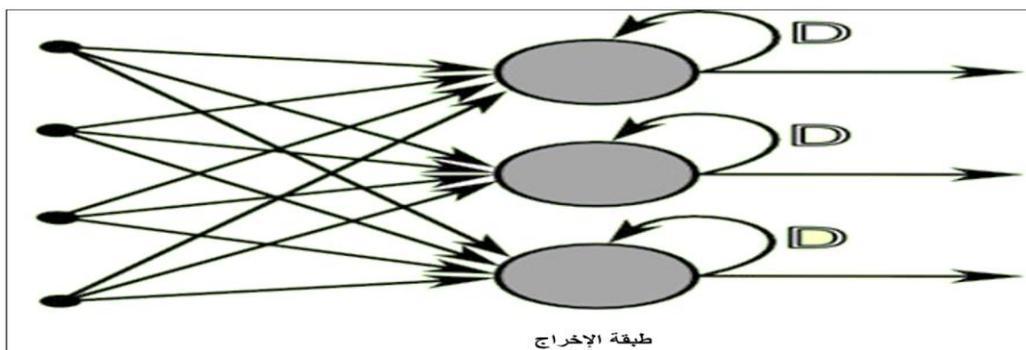


الشكل 6: شبكة عصبية ذات تغذية أمامية متعددة الطبقات المخفية

Source: Al-Hajjaj, H. E. A. (2017). Exploring the nature of the relationship between elements of intelligent organizations and electronic knowledge using neural networks: A case study of Bank of Lebanon and the Emigrants (PhD thesis). Middle East University.

### 2. الشبكة العصبية ذات التغذية العكسية

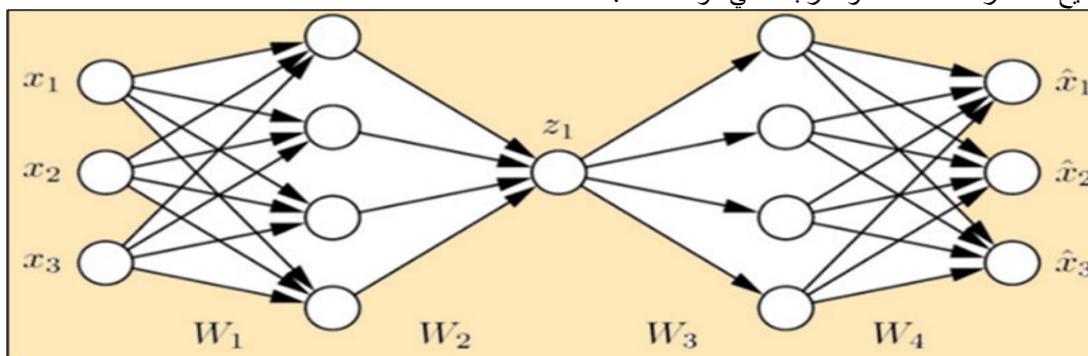
تقوم بإعادة استخدام المخرجات كمدخلات، مما يعطي نتائج أدق وأفضل.



الشكل 7: شبكة عصبية ذات تغذية ذات عكسية

Source: Abdullah, D. A. K. (2021). Financial distress classification of companies in the Iraq Stock Exchange using data mining techniques (Master's thesis). Technical College of Administration/Baghdad.

### 3. الشبكات العصبية ذات الترابط الذاتي (Auto Associative Neural Networks): تعمل جميع عناصرها كمدخلات ومخرجات في الوقت نفسه.



الشكل 8: الشبكات العصبية ذات الترابط الذاتي

Source: Abdullah, D. A. K. (2021). Financial distress classification of companies in the Iraq Stock Exchange using data mining techniques (Master's thesis). Technical College of Administration/Baghdad.

### 4. خوارزمية الانتشار العكسي

خوارزمية الانتشار العكسي تستخدم لتحديد وتصحيح الخطأ من خلال دالة الخطأ، وتستخدم في الشبكات كاملة الارتباط ذات الانتشار الأمامي وغير الخطية ومتعددة الطبقات (Ashour, 2019: 26). تعتمد على تحديث الأوزان خلال مرحلة التدريب بهدف الوصول إلى أقل خطأ عند تغيير البيانات في كل دورة للوصول إلى المخرجات المطلوبة.  
مراحل التنفيذ:

#### 1. مرحلة الانتشار الأمامي

يتم تحديد المدخلات والمخرجات وقيم biases، والأوزان تكون ابتدائية بدون تعديل (Ashour, 2019: 26).

#### 2. خوارزمية الانتشار الخلفي للخطأ

تعمل على تعديل الأوزان، وتسمى "خوارزمية قاعدة دلتا العمومية"، وهي الطريقة القياسية لتدريب الشبكات العصبية. تهدف إلى تقليل الخطأ لإيجاد القيمة الصغرى لمربع الخطأ الكلي. تبدأ العملية بإيجاد وتحديد الخطأ في كل عقدة في الطبقة المخفية، ثم يحصل انتشار عكسي للخطأ من المخرجات إلى المدخلات، مما يؤدي إلى تعديل الأوزان لدفع الخطأ إلى النقصان حتى الوصول للصفر، وبالتالي الحصول على أوزان جديدة للتنبؤ بالبيانات الجديدة (Pelikan et al., 2011: 9 عن Abdelwahab, 2018: 24). تستخدم هذه الطريقة مع شبكات التغذية الأمامية، حيث تعني بنية الشبكة، بينما يقصد بانتشار الخطأ الخلفي طريقة التدريب المستخدمة.

#### 3.3.5 الأنموذج اللوجستي

الأنموذج اللوجستي هو أسلوب إحصائي لفحص العلاقة بين المتغير المستجيب الثنائي ومتغير واحد أو أكثر من المتغيرات التفسيرية. يُستخدم الانحدار اللوجستي عندما يأخذ المتغير المستجيب (Y) قيمتين: وقوع الحدث (1) باحتمال (P) أو عدم وقوعه (0) باحتمال (1-P). يتميز هذا التحليل بقدرته على اختبار معنوية المعاملات وتحديد قوة وتأثير المتغيرات المستقلة على المتغير المستجيب الثنائي (Abdelwahab, 2018: 32).

##### 3.3.5.1 أنواع الانحدار اللوجستي

- 1- الانحدار اللوجستي الثنائي (Logistic Binary Regression): الأكثر شيوعاً، يستخدم عندما يكون للمتغير التابع قيمتان فقط (Pavlyshenko, 2016: 9).
- 2- الانحدار اللوجستي المتعدد (Logistic Multinomial Regression): يُستخدم عندما يكون للمتغير التابع أكثر من قيمتين.
- 3- الانحدار اللوجستي الرتبي (Logistic Ordinal Regression): يُستخدم عندما يكون للمتغير التابع ترتيباً.

### 3.3.5.2 تطبيقات الدالة اللوجستية

تستخدم الدالة اللوجستية في التطبيقات الكيميائية وغيرها، حيث يتميز المنحنى اللوجستي بسهولة الحساب ومقارنته للمنحنى الطبيعي. كما أنه لا يضع قيوداً على أنواع المتغيرات المستقلة، سواء كانت فئوية أو متصلة أو خليطاً منهما (Bakir et al., 2008, p. 8; Abdelwahab, 2018: 36).

### 3.4 ضبط الجودة

ضبط الجودة هو عملية إحصائية مهمة لمراقبة مدى مطابقة عملية الإنتاج للمعايير المحددة، خاصة في الصناعة. التطور التكنولوجي أسهم في زيادة الاهتمام بجودة المنتجات لتحقيق رضا الزبائن. وتُعرف الجودة بأنها "مجموعة خصائص لمنتج أو خدمة تحدد قابليته لتحقيق المتطلبات المصرح بها". تبدأ جودة المنتج من الزبون وتشمل جودة المواد الخام والإنتاج والفحص والتغليف وخدمات ما بعد البيع. يتم تنظيم الجودة في الشركات عبر نظم موثقة للتحكم في ضمان الجودة. فالجودة أساساً في المنظمات الإنتاجية والخدمية، وهي مفهوم حديث يركز على الأداء الأفضل. تُعني الكلمة اللاتينية للجودة "خصائص أو ترتيب أو نوع". في الوقت الحالي، تُعتبر الجودة عاملاً استراتيجياً لنجاح المنظمات بسبب المنافسة المتزايدة بين الشركات. تُعرف الجودة بأنها "تلبية أو تجاوز توقعات الزبون" و"مجموعة خصائص وصفات المنتج أو الخدمة التي تلبى احتياجات الزبون". والجودة هي "السمات والخصائص التي تلبى حاجات وتوقعات الزبائن وتقديم منتج مطابق للمعايير والمقاييس الفنية". كل جزء من المنتج يؤثر ويتأثر بجودة الأجزاء الأخرى لتحقيق جودة المنتجات أو الخدمات التي تلبى احتياجات الزبائن (Al-Bakate & Al-Saffar, 2022: 10).

### 4. تطبيق طرائق التصنيف للمتغيرات وتحليل النتائج

#### 4.1 خوارزمية أشجار القرار

تم تطبيق خوارزمية شجرة القرار على بيانات منتج الزاهي، حيث تكون مخرجات الطريقة على شكل تمثيل شجري يبدأ بنقطة الجذر لأهم متغير، ومن ثم تتفرع الأقسام وصولاً إلى النهايات التي تحدد ما إذا كان المنتج مطابقاً أو غير مطابق بالاعتماد على المتغيرات. تبين أن الصفة "Ad" كانت الأهم في تحديد نوعية المنتج، حيث بدأت الشجرة منها لإجراء أفضل تقسيم للبيانات. تم استخلاص 9 قواعد قرار شكلت فيها الصفة "Ad" جذر الشجرة. القواعد تشمل:

1. إذا كانت قيمة "Ad" أقل من 15.75 فإن المنتج غير مطابق.
  2. إذا كانت قيمة "Ad" أكبر من 15.75 و"pH" أكبر من 9.15 فإن المنتج غير مطابق.
  3. إذا كانت قيمة "Ad" أكبر من 15.75 و"pH" أقل من 9.15 وأقل من 5.75 فإن المنتج غير مطابق.
  4. إذا كانت قيمة "Ad" أكبر من 15.75 و"pH" أقل من 9.15 وأكبر من 5.75 و"NaCl" أقل من 0.55 واللزوجة أقل من 480 فإن المنتج مطابق.
  5. قواعد أخرى تتبع نفس النمط باستخدام قيم مختلفة من المتغيرات.
- مصفوفة الارتباك لخوارزمية شجرة القرار أظهرت دقة عالية، حيث تم التنبؤ بـ 151 حالة صحيحة من أصل 154 حالة مقبولة، و48 حالة غير مقبولة كانت صحيحة. الدقة العامة كانت 97%.

الجدول 4 يوضح مؤشرات الدقة المختلفة:

- (1) الدقة: 97%
- (2) الضبط: 97%
- (3) الاسترداد: 98%
- (4) F-Score: 98%

الصفة "Ad" كانت الأعلى أهمية في التصنيف، تليها اللزوجة، الحموضة (pH)، ثم نسبة الملح (NaCl). هذه الصفات يمكن استخدامها لتصنيف المنتج بدقة وضمان جودته وتلبية احتياجات الزبون.

فيما يلي شرح مستمر لتطبيق خوارزمية الشبكة العصبية الالتفافية لتصنيف بيانات معينة:

#### 4.2 خوارزمية مصنف بييز

تم تطبيق خوارزمية مصنف بييز لحساب الاحتمالات الشرطية اللاحقة باستخدام المتغيرات اللزوجة، pH، Ad، و NaCl كمداخل، والنتيجة الفئوية (مطابق أو غير مطابق) كمخرجات. تم تقسيم البيانات إلى 80% للتدريب و20% للاختبار. استخدمت بيانات التدريب لتقدير الاحتمالات الشرطية وبيانات الاختبار للتحقق من دقة النموذج.

#### النتائج:

- (1) دقة النموذج: 86%.
- (2) مصفوفة الارتباك:
- (3) الحالات المقبولة والمنتنبأ بها صحيحة: 154.
- (4) الحالات المقبولة والمنتنبأ بها خطأ: 3.
- (5) الحالات غير المقبولة والمنتنبأ بها صحيحة: 1.
- (6) الحالات غير المقبولة والمنتنبأ بها خطأ: 48.

## مؤشرات الدقة:

- (1) الدقة: 98%
- (2) الضبط: 99%
- (3) الاسترداد: 98%
- (4) الحساسية: 98%
- (5) F-Score: 99%

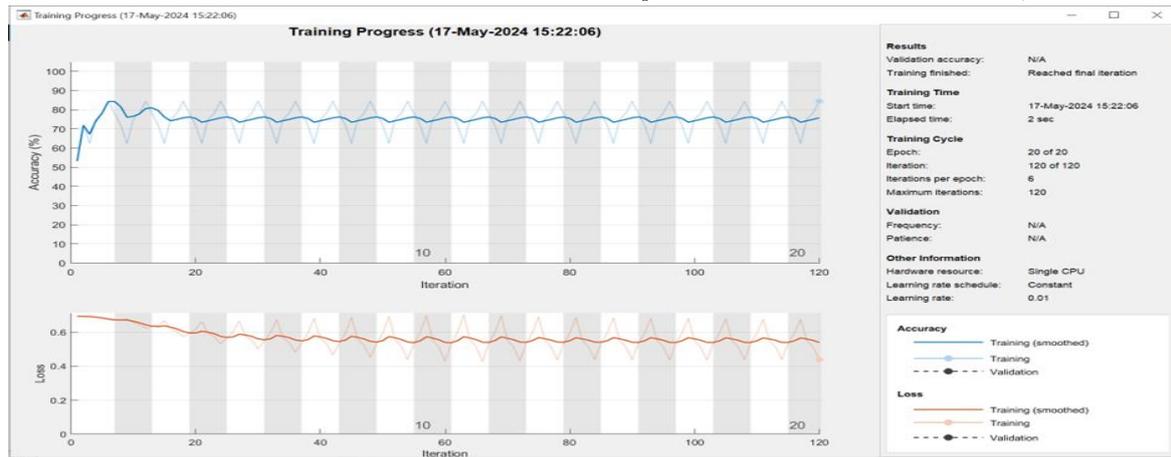
أظهرت الخوارزمية دقة عالية في التنبؤ بالحالات الصحيحة وغير الصحيحة، مما يعكس كفاءتها العالية في تصنيف البيانات. تم استخدام خوارزمية الشبكة العصبية الاصطناعية لتصنيف منتج الشركة، حيث تم تحديد مدخلات ومخرجات الشبكة وتخصيص مراحل تعريف وتدريب الشبكة. تم تقدير قيم الأوزان من خلال التدريب باستخدام جزء من البيانات، ثم تم اختبار الشبكة باستخدام جزء آخر من البيانات لتقييم دقتها. استخدم برنامج SPSS لتنفيذ الخوارزمية وتم الحصول على دقة بلغت 83.6%. تمت مراجعة الأداء باستخدام مصفوفة الارتباك وجدول الأهمية النسبية للمتغيرات.

خلصت النتائج إلى أن الخوارزمية قادرة على التنبؤ بنتائج متغير المنتج بدقة، حيث بلغت دقة التنبؤ 82% والضبط 83% ونسبة الاسترداد 95%. كما أظهرت مصفوفة الارتباك قدرة الخوارزمية على التنبؤ بالحالات المقبولة وغير المقبولة بدقة، وأظهرت الأهمية النسبية للمتغيرات أن صفة Ad هي الأكثر أهمية في التصنيف النهائي للمنتج بدقة.

## 4.3 خوارزمية الشبكة العصبية الالتفافية

تطبيق خوارزمية الشبكة العصبية الالتفافية يتضمن إدخال المتغيرات الأربعة "الزوجة، Ph، Ad، NaCl" كمدخلات في طبقة الإدخال، بينما يكون المتغير التابع من النوع الفئوي في طبقة الخروج، ويتضمن مستويين: "مطابق" أو "غير مطابق". الخطوات الأساسية لتعريف وتدريب الشبكة تشمل (7: Hadi et al., 2021):

1. **تعريف الطبقات (Specification Layers):** تحديد عدد طبقات الإدخال، الطبقات الالتفافية، وطبقة الإخراج بما يتلاءم مع طبيعة المتغيرات المستقلة ونتيجة الفحص.
2. **تدريب الشبكة (Network Training):** تقدير قيم الأوزان، وهي المعلمات التي تتحكم بقوة العلاقات بين العقد، عبر طريقة تكرارية تبدأ بأوزان أولية تتبع التوزيع الاحصائي المنتظم بين الصفر والواحد الصحيح. وتقسيم البيانات إلى 80% لمجموعة التدريب (Training Set) التي تستخدم لتقدير الأوزان حسب معيار أقل خطأ تصنيف.
3. **مرحلة الاختبار أو التحقق (Verification & Testing):** استخدام 20% من البيانات كمجموعة الاختبار (Testing Set) لاختبار صدق وصحة النتائج. وتغذية الشبكة بمتغيرات مجموعة الاختبار كمدخلات والحصول على النتائج (المخرجات) باستخدام الأوزان المقدرة. ومقارنة القيم التنبؤية بالقيم الحقيقية لمجموعة الاختبار وحساب عدد حالات التطابق الصحيح وغير الصحيح.
4. **حساب مصفوفة الارتباك (Confusion Matrix):** استخدام مصفوفة الارتباك والمؤشرات الأخرى لقياس دقة نتائج الشبكة. ومن خلال تطبيق الشفرة البرمجية ضمن بيئة برنامج MatLab-ver 2023 المرفقة بالمحور، تم تنفيذ البرنامج كما في الخطوات أعلاه وبعد 120 تكرار تم الوصول لدقة اجمالية بلغت 84% كما في الجدول 5 والشكل 34.



الشكل 34: مسار تقدم حساب الدقة لكل تكرار للشبكة العصبية الالتفافية لمتغيرات منتج الشركة

المصدر: إعداد الباحث بالاعتماد على مخرجات برنامج MATLAB R2023b

الجدول 5: مؤشرات خوارزمية الشبكة العصبية الالتفافية لمتغيرات منتج الشركة

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Mini-batch Loss	Base Learning Rate
1	1	00:00:00	53.13%	0.6932	0.0100
9	50	00:00:01	71.88%	0.5928	0.0100
17	100	00:00:02	75.00%	0.5502	0.0100
20	120	00:00:02	84.38%	0.4378	0.0100

المصدر: إعداد الباحث بالاعتماد على مخرجات برنامج MATLAB R2023b

من خلال الشكل 35، نلاحظ من مصفوفة الارتباك Confusion Matrix لخوارزمية الشبكة العصبية الالتفافية ان عدد الحالات التي كانت بالأساس مقبولة وتم التنبؤ بها عن طريق الخوارزمية انها مقبولة هو 155 حالة وهو عدد كبير جدا يعكس دقة تلك الطريقة بالتنبؤ.

الجدول 6: مؤشرات الدقة المختلفة لخوارزمية الشبكة العصبية الالتفافية لمتغيرات منتج الشركة

الطريقة	الدقة	الدقة الإيجابية	الاسترجاع	التحديد	درجة F
CNN	75%	100%	75%	0%	86%

المصدر: إعداد الباحث بالاعتماد على مخرجات برنامج MATLAB R2023b

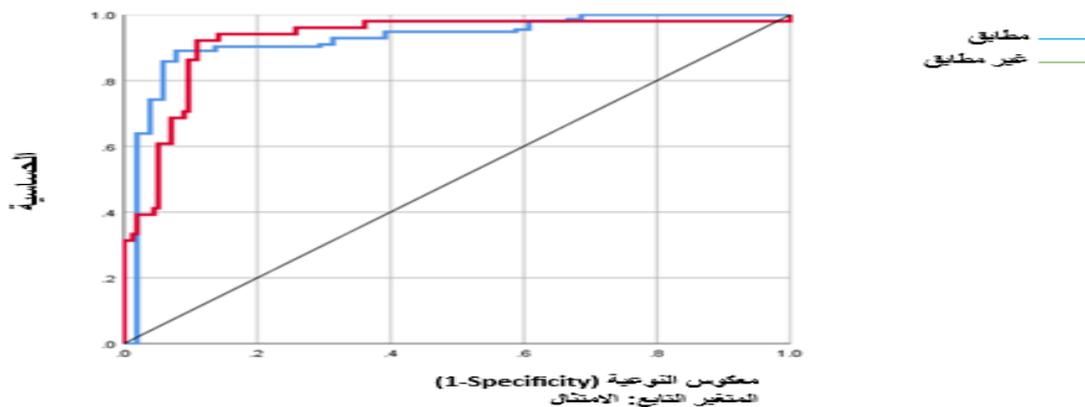
يبين الجدول 6، معايير مختلفة للدقة لخوارزمية الشبكة العصبية الالتفافية اذ بلغت 75% وهي تقيس دقة التنبؤات بالحالات الصحيحة

#### 4.4 خوارزمية الشبكة العصبية الاصطناعية (ANN)

من خلال تطبيق خوارزمية الشبكة العصبية الاصطناعية، ستكون المدخلات Inputs المتغيرات الأربعة "الزوجة، Ad، Ph،"، "nacl" ضمن طبقة الإدخال، والمتغير التابع من النوع الفئوي Categorical ضمن طبقة الإخراج Output، وتضمن مستويين "مطابق Conformable أو غير مطابق Non-Conformable". يتم تخصيص مراحل تعريف الشبكة وتدريبها عن طريق الخطوات التالية:

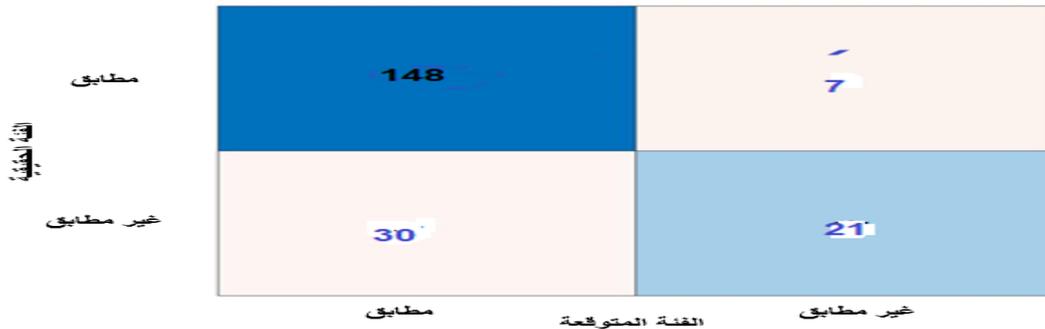
1. **تعريف الطبقات:** وتسمى أيضاً تعريف معمارية أو بنية الشبكة. تحدد عدد طبقات الإدخال والطبقات المخفية وطبقة الإخراج بحيث تتلاءم مع طبيعة المتغيرات الداخلة "المستقلة" والمتغير الخارج "نتيجة الفحص".
2. **مرحلة التدريب:** تقدير قيم الأوزان "المعلمات التي تتحكم بقوة العلاقات بين العقد" باستخدام طريقة تكرارية. يتم تقسيم البيانات إلى مجموعة التدريب ومجموعة الاختبار.
3. **مرحلة الاختبار والتحقق:** استخدام مجموعة الاختبار لاختبار صدق وصحة نتائج الشبكة. يتم حساب مصفوفة الارتباك ومؤشرات الدقة لنتائج الشبكة.

تم تنفيذ البرنامج والوصول لدقة اجمالية بلغت 83.6% كما في الشكل 9.



الشكل 9: مسار تقدم حساب الدقة لكل تكرار للشبكة العصبية الاصطناعية لمتغيرات منتج الشركة

المصدر: إعداد الباحث بالاعتماد على مخرجات برنامج MATLAB R2023b



الشكل 10: مصفوفة الارتباك لخوارزمية الشبكة العصبية الاصطناعية

المصدر: إعداد الباحث بالاعتماد على مخرجات برنامج MATLAB R2023b ومن خلال الشكل 10، نلاحظ من مصفوفة الارتباك Confusion Matrix لخوارزمية الشبكة العصبية الاصطناعية أن عدد الحالات المقبولة وتم التنبؤ بها بشكل صحيح هو 148 حالة، وعدد الحالات المقبولة وتم التنبؤ بها بشكل غير صحيح هو 7 حالات، وعدد الحالات غير المقبولة وتم التنبؤ بها بشكل صحيح هو 30 حالة، وعدد الحالات غير المقبولة وتم التنبؤ بها بشكل غير صحيح هو 21 حالة.

#### 4.5 طريقة الانحدار اللوجستي الثنائي

باستخدام طريقة الانحدار اللوجستي الثنائي، كانت المدخلات "اللزوجة، Ad، Ph، NaCl" والمتغير التابع "مطابق أو غير مطابق". باستخدام SPSS-Ver 28، كانت الدقة الإجمالية 83.6% كما في الشكل 42.

الجدول 10: معامل التوضيح لأنموذج الانحدار اللوجستي الثنائي

معامل التوضيح		
Step	-2 Log likelihood	Nagelkerke R Square
1	178.642	0.331

المصدر: إعداد الباحث بالاعتماد على مخرجات برنامج SPSS-Ver.28

يوضح الجدول 10 أن المتغيرات "اللزوجة، Ad، Ph، NaCl" تفسر 33% من التغيرات في المتغير التابع، والباقي 67% يمثل تغيرات أخرى.

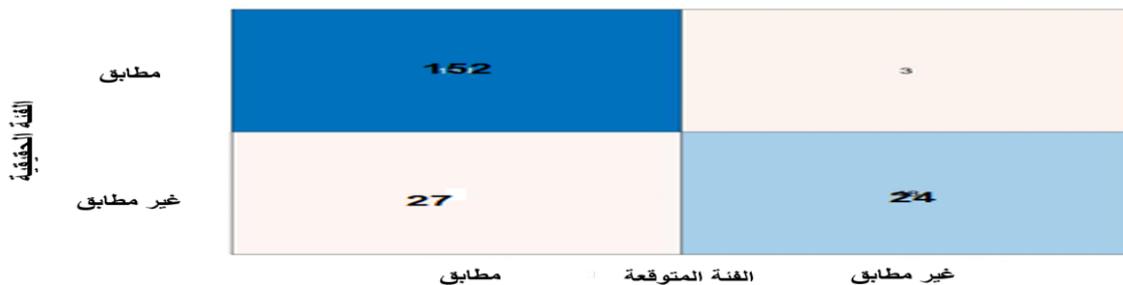
الجدول 11: معاملات أنموذج الانحدار اللوجستي الثنائي

المتغيرات	معاملات أنموذج الانحدار اللوجستي	المعنوية لاختبار Hosmer & Lemeshow	التعليق	المعنوية لاختبار Wald	الحد الأدنى المقدر للمعاملات	الحد الأعلى المقدر للمعاملات	التعليق
viscosity	1.008	0.001	معنوي	0.001	1.003	1.013	معنوي
ph	1.083			0.627	0.786	1.492	غير معنوي
nacl	127.674			0.001	6.719	2426.206	معنوي
ad	0.426			0.000	0.312	0.582	معنوي
Constant	2320.769			0.001			معنوي

المصدر: إعداد الباحث بالاعتماد على مخرجات برنامج SPSS-Ver.28

يظهر الجدول 11 أن المتغيرات "اللزوجة، Ad، NaCl" كانت معنوية، والنموذج المقدر النهائي سيكون:

$$\hat{y}_i = \exp(2320.769 + 1.008Viscosity + 127.674Nacl + 0.426Ad) \dots (5)$$



الشكل 42: مصفوفة الارتباك لخوارزمية الشبكة العصبية الاصطناعية

المصدر: إعداد الباحث بالاعتماد على مخرجات برنامج SPSS-Ver.28

بين الجدول 12 معايير مختلفة للدقة لطريقة الانحدار اللوجستي. الدقة 85%، الضبط 85%، الاسترداد 98%، الحساسية 47%، ومؤشر F-Score 91%. هذه النسب تظهر دقة عالية للطريقة في كشف الحالات المطابقة وغير المطابقة.

## 5. الاستنتاجات

1. خوارزمية أشجار القرار أظهرت فعالية ودقة عالية في تصنيف جودة المنتجات، محققة دقة تصل إلى 97%. تبين أن الصفة Ad هي الأكثر أهمية في تحديد نوعية المنتج، بينما تلعب صفات أخرى مثل اللزوجة والحموضة ونسبة الملح أدواراً هامة أيضاً.
2. خوارزمية الشبكة العصبية الالتفافية (CNN) حققت دقة إجمالية بنسبة 75%، وكانت فعالة في تحديد المنتجات المطابقة بنسبة ضبط بلغت 100%. ومع ذلك، كانت قدرتها على كشف المنتجات غير المطابقة ضعيفة، مع معدل كشف للحالات السلبية يبلغ 0%.
3. خوارزمية مصنف بيز (Naive Bayes Classifier) أظهرت فعالية عالية في تصنيف المنتجات بدقة إجمالية بلغت 98%. كانت نسبة الدقة في التنبؤات بالحالات الصحيحة (مطابقة وغير مطابقة) 98%، ونسبة الضبط للحالات المطابقة 99%.
4. خوارزمية الشبكة العصبية الاصطناعية أظهرت أداءً واعداً في تصنيف منتجات الشركة بدقة 82% ونسبة استرداد 95%.
5. خوارزمية الانحدار اللوجستي الثنائي حققت دقة جيدة بنسبة 85%. وكانت الصفات الأربعة (اللزوجة، Ph، NaCl، Ad) معنوية في التنبؤ بما إذا كان المنتج مطابقاً أم غير مطابق، مع إمكانية تحسين النموذج بمزيد من البيانات أو المتغيرات.

## 6. التوصيات

1. تطبيق خوارزمية أشجار القرار بشكل موسع في عمليات ضبط الجودة، مع التركيز على الصفات الأكثر تأثيراً مثل الصفة Ad لتحسين دقة التصنيف وتقليل نسب المنتجات المرفوضة؛ وذلك من خلال تطوير نظام آلي لضبط الجودة باستخدام خوارزمية أشجار القرار، وتدريب الموظفين على استخدامه ودمجه مع خطوط الإنتاج.
2. تعديل وتطوير معمارية الشبكة العصبية الالتفافية وزيادة عدد التكرارات لتحسين قدرتها على كشف الحالات غير المطابقة، ويمكن استخدام تقنيات تحسين إضافية مثل تعديل معدلات التعلم أو أساليب تنظيم إضافية؛ وذلك من خلال زيادة التكرارات واستخدام تقنيات تحسين مثل تعديل معدلات التعلم، واختبار وتحسين النموذج بانتظام.
3. تطبيق خوارزمية مصنف بيز بشكل أوسع في نظم مراقبة الجودة، مع تدريب المشغلين والمهندسين على استخدام وتفسير نتائج الخوارزمية ودمجها مع أنظمة الإنتاج الحالية؛ وذلك من خلال تدريب المشغلين على استخدام الخوارزمية ودمجها مع أنظمة الإنتاج الحالية.
4. تبني خوارزمية الشبكة العصبية الاصطناعية كأداة رئيسية لتصنيف منتج الشركة، مع تحسين جودة البيانات المستخدمة في التدريب والتحقق وتطوير النموذج بانتظام؛ وذلك من خلال تحسين جودة البيانات المستخدمة في التدريب وتحديث النموذج بانتظام، ودمج الخوارزمية مع نظام مراقبة الجودة.
5. تحسين نموذج الانحدار اللوجستي باستخدام متغيرات إضافية مؤثرة مثل درجة الحرارة أو وقت الإنتاج، ومراجعة البيانات للتحقق من استخدام المتغيرات الصحيحة، واستكشاف تقنيات تعلم آلي أخرى لتحسين الدقة والأداء العام للنموذج؛ وذلك من خلال جمع بيانات إضافية مثل درجة الحرارة ووقت الإنتاج، وتحديث النموذج بانتظام واختبار تقنيات تعلم آلي أخرى لتحسين الأداء.

## المصادر

1. Abdelwahab, M. A. (2018). Proposal for an automated quality control system: A case study (Master's thesis in Administrative Information Technology/Technical College of Administration - Baghdad).
2. Abdulaziz, G. (2006). The use of C4.5 classifier in object feature recognition: A comparative study. Rafidain Development Journal, 31(3), 119-133.
3. Abdullah, D. A. K. (2021). Financial distress classification of companies in the Iraq Stock Exchange using data mining techniques (Master's thesis). Technical College of Administration/Baghdad.
4. Adam, A., Shapi, M. I., Ibrahim, Z., Khalid, M., & Jau, L. (2011). Development of a hybrid Artificial Neural Network-Naive Bayes classifier for binary classification problem of imbalanced datasets. ICIC Express Letters, 5(8), 3171-3175.
5. Al-Bakate, A. M. H., & Al-Saffar, S. S. (2022, December). The relationship between the policies and procedures of International Auditing Standard (220) quality control and enhancement of audits. Journal of Techniques, 4(4).
6. Al-Hajjaj, H. E. A. (2017). Exploring the nature of the relationship between elements of intelligent organizations and electronic knowledge using neural networks: A case study of Bank of Lebanon and the Emigrants (PhD thesis). Middle East University.
7. Al-Qaragholi, D. A. H. (2021). The effect of cleaner production strategies on product quality: An analytical study in the General Company for Food Products / Al-Mamoun Factory (Master's thesis). Technical College of Administration/Baghdad.
8. Ashour, M. A. (2019). Artificial neural networks and time series forecasting methods (PhD thesis). University of Baghdad.

9. Atiya, O. S. (2022). "Comparison of COVID-19 case classification using machine learning approaches" (Article). *Iraqi Journal of Electrical and Electronic Engineering*, 18(1).
10. Azarang, A., Hansen, J., & Kehtarnavaz, N. (2019, June). Combining data augmentations for CNN-based voice command recognition. In 2019 12th International Conference on Human System Interaction (HSI) (pp. 17-21). IEEE.
11. Bakır, B., Batmaz, İ. N. C. İ., Güntürkün, F. A., İpekçi, İ. A., Köksal, G., & Özdemirel, N. E. (2008). Defect cause modeling with decision tree and regression analysis. *International Journal of Industrial and Manufacturing Engineering*, 2(12), 1334-1337.
12. Capuano, G., & Rimoli, J. J. (2019). Smart finite elements: A novel machine learning application. *Computer Methods in Applied Mechanics and Engineering*, 345, 363-381.
13. Chien, H. C., Yu, J., Zhu, B., Shi, J., Cai, Y., Xiao, X., ... & Chen, Y. (2018, September). Probabilistically shaped DP-64QAM coherent optics at 105 Gbd achieving 900 Gbps net bit rate per carrier over 800 km transmission. In 2018 European Conference on Optical Communication (ECOC) (pp. 1-3). IEEE.
14. Dhaliwal, S. S., Nahid, A. A., & Abbas, R. (2018). Effective intrusion detection system using XGBoost. *Information*, 9(7), 149.
15. Dogan, A., & Birant, D. (2021). Machine learning and data mining in manufacturing. *Expert Systems with Applications*, 166, 114060.
16. Glackin, C., Wall, J. A., Chollet, G., Dugan, N., & Cannings, N. (2018, January). Convolutional Neural Networks for Phoneme Recognition. In ICPRAM (pp. 190-195).
17. Hadi, Z. G., Ajel, A. R., & Al-Dujaili, A. Q. (2021). Comparison between convolutional neural network CNN and SVM in skin cancer images recognition. *Journal of Techniques*, 3, 15-22.
18. Jiawei, H., & Micheline, K. (2006). *Data mining: concepts and techniques*. Morgan kaufmann.
19. Masethe, H. D., & Masethe, M. A. (2014, October). Prediction of heart disease using classification algorithms. In *Proceedings of the world Congress on Engineering and computer Science (Vol. 2, No. 1, pp. 25-29)*.
20. Mishra, A.K., Keserwani, P.K., Samaddar, S.G., Lamichaney, H.B., Mishra, A.K. (2018). A Decision Support System in Healthcare Prediction. In: Bhattacharyya, S., Gandhi, T., Sharma, K., Dutta, P. (eds) *Advanced Computational and Communication Paradigms. Lecture Notes in Electrical Engineering*, vol 475. Springer, Singapore. [https://doi.org/10.1007/978-981-10-8240-5\\_18](https://doi.org/10.1007/978-981-10-8240-5_18)
21. Njoku, O. C. (2019). Decision trees and their application for classification and regression problems.
22. Ogunleye, A., & Wang, Q. G. (2019). XGBoost model for chronic kidney disease diagnosis. *IEEE/ACM transactions on computational biology and bioinformatics*, 17(6), 2131-2140.
23. Pavlyshenko, B. (2016, December). Machine learning, linear and bayesian models for logistic regression in failure detection problems. In 2016 IEEE international conference on big data (big data) (pp. 2046-2050). IEEE. DOI:10.1109/BigData.2016.7840828
24. Pelikan, M., Raju, M. M., Srivastava, R. K., Bisht, D. C. S., Sharma, H. C., & Kumar, A. (2011). Development of artificial neural-network-based models for the simulation of spring discharge. *Advances in Artificial Intelligence*, 2011, Article 686258. <https://doi.org/10.1155/2011/686258>
25. Rasheed, S. S. (2022). Using machine learning algorithms to improve decision support systems (Master's thesis in Administrative Information Technology/Technical College of Administration - Baghdad).
26. Vazan, M. (2021). Deep learning: principles, concepts and approaches. *Miad andishe*. [https://www.researchgate.net/publication/349928501\\_Deep\\_learning\\_principles\\_concepts\\_and\\_approaches](https://www.researchgate.net/publication/349928501_Deep_learning_principles_concepts_and_approaches)