

عنوان البحث

**التنبؤ بأسعار النفط الخام باستخدام الشبكات العصبية الاصطناعية بالتطبيق على
اسعار خام غرب تكساس الوسيط (MTI)**

د. مصطفى بشير على عبد الله¹

¹ كلية شرق النيل الجامعية - السودان - بريد الكتروني: wadbashir26@yahoo.com

HNSJ, 2025, 6(6); <https://doi.org/10.53796/hnsj66/13>

المعرف العلمي العربي للأبحاث: <https://arsri.org/10000/66/13>

تاريخ النشر: 2025/06/01م

تاريخ القبول: 2025/05/15م

تاريخ الاستقبال: 2025/05/07م

المستخلص

هدفت الدراسة الي اقتراح نموذج للتنبؤ بأسعار النفط الخام غرب تكساس الوسيط (WTI) باستخدام تقنية الشبكات العصبية الاصطناعية واعتمدت الدراسة علي بيانات سلاسل زمنية لسعر البرميل اليومي للخام (WTI) في الفترة من 2021/1/1 الي 2024/12/31 حيث بلغ حجم العينة 1232 مشاهدة وتم استخدام المنهج الوصفي والمنهج الاستقرائي الاستنباطي للتحقق من فرضيات الدراسة وبناء نموذج الدراسة المقترح باستخدام لغة البرمجة R وتوصلت الدراسة الي ان متوسط سعر اليومي للخام (WTI) بلغ 79.24 دولار واعتمدت الدراسة على شبكة البيرسبترون متعدد الطبقات (MLP) لبناء معالم الشبكة العصبية الاصطناعية وتوصلت الدراسة كذلك الي ان معمارية الشبكة المكونة من ثلاث طبقات (1,10,1) هي الافضل والأنسب لبناء نموذج الدراسة المقترح واثبتت النموذج قوة تفسير عالية جدًا حيث فسرت قيمة معامل التحديد حوالي 98.12% من التغيرات والاختلافات في أسعار النفط الخام الفعلية والمتنبأ بها واطهر النموذج كذلك أداءً قويًا جدًا في عملة التنبؤ مع أخطاء منخفضة جدًا حيث بلغت قيمة متوسط الخطأ المطلق (MAE=1.27) واعطى النموذج تنبؤات مستقبلية جيدة وذات جودة عالية في الفترة من 2025/1/1 الي 2025/1/10 هذا ما يجعله يساعد في رسم السياسات الاقتصادية والمالية المستقبلية للدول.

الكلمات المفتاحية: الذكاء الاصطناعي، الشبكات العصبية الاصطناعية (ANN)، التنبؤ، سعر النفط خام غرب تكساس الوسيط (MTI)، لغة البرمجة R.

RESEARCH TITLE

Forecasting Crude Oil Prices Using Artificial Neural Networks: An Application to West Texas Intermediate (WTI) Prices

Received at 07/05/2025

Accepted at 15/05/2025

Published at 01/06/2025

Abstract

. The study aimed to propose a forecasting model for West Texas Intermediate (WTI) crude oil prices using Artificial Neural Network (ANN) techniques. The research was based on time series data of the daily price per barrel of WTI crude oil during the period from January 1, 2021, to December 31, 2024, comprising a sample size of 1,232 observations. Both the descriptive approach and the inductive-deductive method were utilized to validate the study's hypotheses and to develop the proposed model using the R programming language. The study found that the average daily price of WTI crude oil during the study period was \$79.24. It employed the Multilayer Perceptron (MLP) network to define the structure of the ANN, and concluded that the optimal and most suitable architecture consisted of three layers (1,10,1). The model demonstrated a very high explanatory power, with the coefficient of determination (R^2) explaining approximately 98.12% of the variations between actual and predicted oil prices. Furthermore, the model exhibited strong forecasting performance, with very low prediction errors, as the Mean Absolute Error (MAE) was recorded at 1.27. The model also provided accurate and high-quality forecasts for the period from January 1, 2025, to January 10, 2025, making it a valuable tool for informing future economic and financial policy-making.

Key Words: Artificial Intelligence, Artificial Neural Networks (ANN), Forecasting, West Texas Intermediate (WTI) Crude Oil Price, R Programming Language.

1- مقدمة:

بعد الحرب العالمية الثانية أصبح النفط المحرك الرئيسي للطاقة العالمية، والمحرك للاقتصاد العالمي في ظل النمو المتزايد نظرا لملائمته للتطورات المستمرة في الصناعات الحديثة، (مولود وجمال، 2017). حيث ان سوق النفط لا يتأثر بقوانين السوق فحسب، بل تتحكم فيها جملة من السياسات والاستراتيجيات المتضاربة بين مصالح الدول المستهلكة وخصوصا الدول الصناعية الكبرى وبين الدول المنتجة للنفط، وكذا بين الهيئات والمنظمات التي تمثل كل طرف ولا سيما من ناحية تحديد الاسعار (الموسوي، 2004). وان التقلبات المستمرة في اسعار النفط العالمية، جعل من النفط العامل الرئيسي في مؤشرات التنمية الدولية، والامر الذي جعله يعتمد عليه في تقييم حركة الاقتصاد الدولي، ومراقبة اسعار الصرف، وضبط موازين التجارة الدولية، وباتت التغيرات السعرية تلعب دور المتحكم في جميع المؤشرات الاقتصادية (Hunt, Muir, & Sommer, 2015).

وأصبح الاعتماد على مبدأ التنبؤ بالمستقبل من خلال بيانات الماضي والحاضر من أهم الاستراتيجيات في عالم اليوم خاصة فيما يتعلق بالمتغيرات الاقتصادية الكلية لا سيما سعر الصرف، معدلات التضخم، والبطالة، واسعار الاسهم، واسعار الطاقة، وغيرها، لذلك فان عملية التنبؤ المستقبلي لاتجاهات تلك المتغيرات تعتبر في غاية الاهمية اذ تستطيع الادارات الاقتصادية لدى الدول من خلال المعلومات المتوقعة عن الظاهرة في المستقبل ان تجنب الاقتصاد القومي من مشاكل كثيرة من خلال التخطيط المسبق لاحتواء الآثار المتوقع حدوثها بسبب اضطراب احد تلك المتغيرات الاقتصادية الكلية. (عاشور، 2014)

وتعتبر نماذج الشبكات العصبية الاصطناعية (Artificial Neural Networks (ANN أحد تقنية الذكاء الاصطناعي التي لاقت اهتمام كبير في السنوات الأخيرة من قبل الباحثين والأكاديميين وصناع القرار، وتم استخدامها كبديل عن النماذج التقليدية. ولقد أثبتت هذه النماذج (ANN) قدرتها على التنبؤ بحل المشكلات بدقة وسهولة مقارنة بالأساليب الإحصائية التقليدية، حيث يمكن تطبيق أسلوب الشبكات بدون النظر إلى فرضيات معينة عن طبيعة المتغيرات وعلاقتها مع بعضها البعض وذلك على العكس من الطرق التقليدية العادية في التنبؤ. (بشير: 2024).

1-1- مشكلة الدراسة:

ان اسعار النفط العالمية تتحكم فيها العديد من المتغيرات الديناميكية سواء من ناحية القوانين الاقتصادية كقانون العرض والطلب، او التوترات والظروف الجيوسياسية او المشاكل اللوجستية، الخ...، مما يصعب التنبؤ بأسعاره. لذلك تكمن مشكلة الدراسة في الاجابة على الاسئلة التالية:

هل نموذج الشبكات العصبية الاصطناعية المقترح قادر على التنبؤ المستقبلي بأسعار النفط الخام اليومية؟

إذا كان كذلك مما مدى كفاءته في التنبؤ بأسعار النفط الخام اليومية وفقا لمعايير الدقة التنبؤية، وكذلك عند مقارنته بأسعار النفط اليومية الفعلية؟

1-2- فرضية الدراسة:

تم صياغة الفرضيات بناء على الاجابة على اسئلة مشكلة الدراسة على النحو التالي:

نموذج الشبكات العصبية الاصطناعية المقترح قادر على التنبؤ المستقبلي بأسعار النفط اليومية؟

النموذج المقترح ذو كفاءة عالية في التنبؤ وفقا لمعايير الدقة التنبؤية () وكذلك عند مقارنة الأسعار المتنبأ بها بأسعار النفط الفعلية.

3-1- أهداف الدراسة:

تهدف الدراسة الي اقتراح نموذج احصائي باستخدام تقنية الشبكات العصبية الاصطناعية له مقدرة ذات دقة عالية في التنبؤ المستقبلي بالسعر اليومي لبرميل خام نفط غرب تكساس الوسيط، وذلك لان سعر هذا الخام يستخدم كعميار لتحديد اسعار الخامات الأخرى للنفط. ويجب ان يكون هذا النموذج قادر علي محاكاة واقع اسعار النفط الفعلية مولدا اسعار قريبة جدا من الاسعار الحقيقية، مما يسهم بدوره في مساعدة الادارات الاقتصادية للدول المستهلكة والمنتجة معا في رسم سياستها الاقتصادية الكلية، وخصوصا عند ابرام صفقات العقود الآجلة.

4-1- اهمية الدراسة:

تخضع السوق العالمية للنفط الي مجموعة من التطورات المهمة التي بمقدورها تحدث اختلاف كبير في ميزان العرض والطلب، حيث ان السوق النفطية ذو طبيعة خاصة تأخذ خصوصيته من تداخل العوامل الاقتصادية مع العوامل الجيوسياسية، التي تتفاوت اهميتها ودرجة تأثيرها على اسعار الخام في السوق. لذلك فان معرفة الية للتنبؤ بأسعار النفط تساعد الادارة الاقتصادية لتلك الدول في اتخاذ القرارات المناسبة لرسم خططها الاستراتيجية وتقدير ميزانياتها بما يحمي اقتصاداتها من المخاطر المحتملة جراء تقلبات الاسعار.

5-1- منهجية الدراسة:

يستخدم في هذه الدراسة المنهج الوصفي والمنهج الاستقرائي الاستنباطي. في التحليل البيانات، حيث من خلال المنهج الوصفي سوف يتم وصف بيانات الدراسة وعن طريق اساليب الاحصاء الوصفي ومستعينا ببعض المقاييس الوصفية من مثل الوسط الحسابي والحد الأعلى والأدنى والانحراف المعياري من اخذ فكره عامة عن طبيعة حركة اسعار النفط، اما المنهج الاستقرائي يستخدم في بناء نموذج الشبكات العصبية الاصطناعية من اجل التوقع المستقبلي بأسعار النفط الخام. وذلك باستخدام لغة البرمجة R.

6-1- حدود الدراسة:

تعتمد الدراسة على بيانات سلاسل زمنية لسعر البرميل اليومي لخام غرب تكساس الوسيط بدولار الامريكي، في الفترة من 2021/1/1 الي 2024/12/31م.

7-1- الدراسات السابقة:

هناك العديد من الدراسات التي تناولت هذا الموضوع سواء بنفس النماذج او بأساليب احصائية اخري مختلفة، وكذلك بالتطبيق على بيانات مختلفة. منها على سبيل المثال لا الحصر:

- دراسة (Kuo, Hit, and Chen;2009)، هدفت الدراسة الي اقتراح الي خوارزمية التعلم القائم على التطور باستخدام الشبكة العصبية RBF للتنبؤ، وتطبيقه على التنبؤ بأسعار البترول، واطهرت النتائج ان هذه الطريقة قادرة على تحقيق الدقة في عملية التنبؤ بأسعار البترول، كما أثبتت ايضا أن الخوارزمية المقترحة تتوفق على طريقة (ARIMA) في التنبؤ.
- دراسة: (المبجوح، 2018)، حاولت هذه الدراسة استخدام كل من نماذج الانحدار الذاتي والمتوسطات المتحركة التكاملية الكسرية (ARFIMA (p,d,q) Auto Regressive Fractionally Integrated Moving Average) واسلوب الشبكات العصبية الاصطناعية (ANN) Artificial Neural Networks ، في التنبؤ بأسعار البترول الخام وذلك

بالاعتماد علي بيانات السلسلة الزمنية اليومية في ولاية تكساس الامريكية لأسعار البترول الخام للفترة الزمنية 2013/9/30 الي 2018/3/9.

ومن خلال المقارنة بين نتائج هذه النماذج توصلت الباحثة الي ان نموذج الشبكات العصبية الاصطناعية (MLP(2-25-1) لدية قدرة أكبر في التنبؤ مقارنة بنموذج الانحدار الذاتي والمتوسطات المتحركة التكاملية الكسرية (ARFIMA (1,0.375,1)، لامتلاكه اقل قيم لمقاييس دقة التنبؤ (RMSE, MAE (Mean Absolute Error) (Root of Mean Squared Error)، وبذلك يكون هو النموذج الأكفأ في القدرة على التنبؤ المستقبلي بأسعار البترول الخام اليومية.

- دراسة: (الفهود واخرون، 2019) تناولت هذه الدراسة تطبيق نمذج هجين من خلال الدمج بين نموذج الانحدار الذاتي والمتوسطات المتحركة التكاملية ARIMA، ونموذج الانحدار الذاتي المعمم المشروط بعد ثبات التباين GARCH وذلك باستخدام بواقي نموذج ARIMA، كمدخلات لنموذج GARCH علي بيانات السلسلة الزمنية الشهرية لمعدلات اسعار برميل النفط الخام لمنظمة الدول المصدرة للنفط (أوبك)، خلا الفترة الزمنية (يناير 2003- مايو 2018)، تم اقتراح عدد من النماذج ومن ثم المفاضلة بينها باستخدام معايير التقييم حيث تبين ان نموذج GARCH - (2,2,1) ARIMA (1,1) الهجين هو النموذج الانسب لتحليل البيانات قيد الدراسة والأكفأ في دقة التنبؤ المستقبلي مقارنة بنموذج ARIMA نظرا لامتلاكه اقل قيم لمعايير دقة التنبؤ (RMSE), (MAPE), (MAE). وعليه تم استخدامه في التنبؤ باثنتي عشرة قيمة شهرية، استخدمت الستة الأولى منها للمقارنة مع القيم الفعلية والأخرى للتنبؤ بالقيم خلال الأشهر الست القادمة.
- دراسة (مرابطي، 2019)، هدفت هذه الدراسة الي التنبؤ بالقيم المستقبلية لأسعار البترول الخام برنت Brent Crude، وذلك باستخدام تقنية الشبكات العصبية الاصطناعية، وقد تم استخدام بيانات يومية لأسعار البترول للفترة من 2011/05/16 الي غاية 2019/04/01، وقد تم الاعتماد على شبكة البيروسترون متعدد الطبقات (MLP) لبناء معالم الشبكة العصبية للبيانات وذلك باستخدام برنامج Alyuda لتحليل المعطيات.
- وقد توصلت الدراسة الي ان استخدام نموذج الشبكات العصبية الاصطناعية في التنبؤ، له جودة عالية في التنبؤ بأسعار البترول محل الدراسة، وهذا ما يجعله يساعد في رسم السياسات المالية الاقتصادية للدول.
- دراسة (آسيا ووثام، 2023)، هدفت هذا الدراسة القياسية الي استخدام الذكاء الاصطناعي للتنبؤ بأسعار البترول الجزائري، تم استخدام بيانات خلال الفترة الممتدة من 1986 الي 2023. وقد تم الاعتماد على برنامج MATLAB لتحليل المعطيات، واختبار مستوى الخطأ لشبكة عصبية، وقد توصلت الدراسة الي أن استخدام نموذج الشبكات العصبية الاصطناعية في التنبؤ، له جودة عالية ما يجعله يساعد في رسم السياسة المالية والاقتصادية للدول.
- تتفق هذه الدراسة مع الدراسات السابقة من حيث الهدف في بناء نموذج احصائي للتنبؤ بأسعار النفط، بغض النظر عن الاسلوب الاحصائي المستخدم في تحقيق الهدف، الان انها تميزت عن سابقتها في عينة الدراسة المستخدمة، وكذلك تميزت في البرنامج الاحصائي المستخدمة في عملية تحليل البيانات وبناء نموذج الشبكة العصبية الاصطناعية، حيث تم استخدام لغة البرمجة R. وهذه الميزة الاخيرة انفردت بها هذه الدراسة على الاطلاق عن سابقتها، وارجو ان تكون اضافة حقيقة في المجال.

2- الإطار النظري للدراسة:

2-1- تعريف مفهوم الشبكات العصبية الاصطناعية (ANN) Artificial Neural Networks

منهجية الشبكات العصبية الاصطناعية هي من أحد أهم طرق الذكاء الاصطناعي، وتعتبر من المواضيع المهمة والحديثة في بناء النماذج والتحليل وتقييم البيانات والتنبؤ والسيطرة عليها بدون الرجوع الي نموذج او طريقة إحصائية شائعة تشخص مسبقا سلوك الظاهرة. وسميت الشبكات العصبية الاصطناعية بهذا الاسم كونها شبكة من وحدات الاتصالات الداخلية، اذ ان

هذه الوحدات مستوحاة من دراسة أنظمة الاعصاب الحيوية ويرمز لها اختصاراً بـ ANN.

وهناك عدة تعاريف للشبكات العصبية الاصطناعية من أهمها الآتي:

- عرف العالم Nilsson الشبكات العصبية على أنها نظام حسابي مكون من عدد من وحدات المعالجة (processing units) المترابطة فيما بينها وتتصف بطبيعتها الديناميكية والمتوازنة في معالجة البيانات الداخلة إليها.
- عرف العالم Haykin الشبكات العصبية في عام 1994 على أنها متوازنة هائلة توزع المعالج الذي لديه ميل أو نزعة طبيعية لتخزين المعرفة التجريبية وجعلها متاحة للاستعمال. أنها تماثل الدماغ البشري في ناحيتين، تكتسب المعرفة بواسطة الشبكة من خلال عملية التعلم نقاط اتصال العصبون المعرف باسم مشبكي Synaptic وتستعمل الأوزان لتخزين المعرفة.
- عرف العالم Zurada الأنظمة العصبية أو الشبكات العصبية الاصطناعية في عام 1992 على أنها أنظمة خلوية فيزيائية التي يمكن فيها من كسب وتخزين واستعمال المعرفة التجريبية.
- تعرف الشبكات العصبية الاصطناعية أيضاً على أنها نماذج رياضية تختص بخصائص معالجة المعلومات التي تتصف بها الأنظمة البيولوجية. (عاشور: 2018)

ويمكن ايجاز تعريف الشبكات العصبية الاصطناعية بالتعريف التالي:

هي تقنيات حسابية مصممة لمحاكاة الطريقة التي يؤدي بها الدماغ البشري مهمة معينة، وذلك عن طريق معالجة ضخمة موزعة على علي التوازي، ومكونة من وحدات معالجة بسيطة، هذه الوحدات ما هي الا عناصر حسابية تسمى عصبونات أو عقد (Nodes, Neurons) والتي لها خاصية عصبية، من حيث أنها تقوم بتخزين المعرفة العملية والمعلومات التجريبية لتجعلها متاحة للمستخدم وذلك عن طريق ضبط الأوزان. (الحسين والساعدي: 2019)

ومن الناحية الإحصائية يمكن اعتبار الشبكة العصبية عبارة عن نموذج رياضي أو مجموعة من الأدوات لنمذجة البيانات الإحصائية غير الخطية.

2-2- خصائص الشبكات العصبية الاصطناعية:

- تتسم الشبكات العصبية الاصطناعية بمجموعة من الخصائص التي تميزها عن التقنيات الكلاسيكية الأخرى، بالنحو التالي:
- المقدرة الفائقة في معالجة البيانات الضخمة ذات المتغيرات المعقدة في وقت وجيز. وبالتالي تحقيق الوفرة في وقت التنفيذ مقارنة بالبرامج الإحصائية الكلاسيكية التي تعتمد على المعالجة التسلسلية للمتغيرات بالاعتماد على الفرضيات.
 - القدرة على التمرن والتعلم الفعال للشبكة يمكنها من استيعاب محددات جديدة للمشاكل من خلال المعطيات الجديدة للمحيط الخارجي، كما ان هذه الخاصية تمكنها أيضاً من القدرة على التعميم بالتعرف على الأمثلة المتشابهة.
 - سهولة بناء نموذج الشبكة الاصطناعية ويتم ذلك بكتابة برنامج والقيام بالاختيار للمعطيات بالاعتماد على أجهزة الحاسوب المجزأة ببرمجيات حديثة. (رفايكية: 2019).
 - تعتمد على أساس رياضي قوي.
 - تمثل إحدى تطبيقات تكنولوجيا التشغيل الذكي للمعلومات التي تقوم على محاكاة العقل البشري.
 - تقبل أي نوع من البيانات الكمية أو النوعية.
 - يمكن تطبيقها في العديد من المجالات العلمية المختلفة.
 - ذات عمليات غير خطية، أي مقدرتها على تقديم مخططات تتضمن علاقات غير خطية مضادة للوضوء التي تجعل منها مصدراً جيداً لعمليات التصنيف والإسناد (classification predication).
 - مقدرتها العالية على التكيف مع النظام اللوغاريتم التعليمي القوي وذات تنظيم داخلي يسمح باستخدامها للتكيف الداخلي الذي يعيش في محيط دائم التغيير. (محمد: 2021)

2-3- مجالات استخدام الشبكات العصبية الاصطناعية:


يتم الاستعانة بتقنية الشبكات العصبية الاصطناعية في العديد من المجالات بمختلف جوانب الحياة، وهذه المجالات على سبيل

المثال لا الحصر هي:

- مجال الطب: وهو تطبيق الطب الفوري الذي يرتبط بمبدأ الذاكرة كما في حالة العقل البشري، أي مبدأ العلامات المرضية والتشخيص، كشف وتقييم الظواهر الطبيعية.
 - مجال الاتصالات السلكية واللاسلكية مثل التخلص من صدى الصوت الذي قد ينتج في خطوط التلغرافات، وفي الرادارات العسكرية لتحديد الأهداف.
 - مجال الأعمال المصرفية: وذلك لفتح الحسابات الخاصة بالبنوك عن طريق اللمس أو الصوت أو بصمة العين، وكذلك للتعرف على التوقعات البنكية وخطوط اليد.
 - مجالات الأعمال: كتطبيق الشبكات في عدة أعمال وبصفة خاصة في مجال الأعمال الاقتصادية. (Kurnar:2010).
 - مجال علم البيانات: التنبؤ، تصنيف البيانات، الكشف عن التغير والانحراف في البيانات، اكتشاف المعرفة، نمذجة الاستجابة، تحليل السلاسل الزمنية.
 - المجال المالي: التنبؤ بتطور الأسواق المالية، الجدارة الائتمانية، التصنيف الائتماني، توقع الإفلاس، تقييم الممتلكات، الكشف عن الغش، توقعات الأسعار، توقعات المؤشر الاقتصادي.
 - المبيعات والتسويق: التنبؤ بالمبيعات، التسويق المستهدف، التنبؤ باستخدام الخدمة، التنبؤ بهوامش التجزئة.
 - الصناعة: مراقبة العمليات، مراقبة الجودة، تقدير المواد الخام والطاقة المستخدمة في عملية الإنتاج.
 - مجال الطاقة: تقدير الحمولة الكهربائية، توقع الطلب على الطاقة، توقع أسعار النفط والغاز والفحم، أنظمة التحكم في الطاقة، مراقبة السد المائي.
 - مجالات أخرى: التنبؤ الكمي بالطقس، تطوير الألعاب، تقديرات الإنتاج الزراعي. (مرابطي، 2019).
- 2-4- مكونات الشبكات العصبية الاصطناعية:

كما ان للإنسان وحدات ادخال توصله بالعالم الخارجي وهي حواسه الخمس، فكذلك الشبكات العصبية تحتاج لوحدة ادخال ووحدات معالجة يتم فيها عمليات حسابية تضبط بها الاوزان ونحصل من خلالها على ردة الفعل المناسبة لكل مدخل من المدخلات للشبكة. فوحدات الادخال تكون طبقة تسمى المدخلات، ووحدات المعالجة تكون طبقة المعالجة وهي التي تخرج نواتج الشبكة. وبين كل طبقة من الطبقات هناك طبقة من الوصلات البينية التي تربط كل طبقة بالطبقة التي تليها والتي يتم فيها ضبط الاوزان الخاصة بكل وصلة بينية، وتحتوي الشبكة على طبقة واحدة فقط من وحدات الادخال، ولكنها قد تحتوي على أكثر من طبقة من طبقات المعالجة.

والمعادلة التالية توضح الشكل الرياضي للشبكة العصبية الاصطناعية.



مما سبق فإن الشبكة العصبية الاصطناعية تتكون من جزئين أساسيين هما:

أولاً: الشكل العام للشبكة العصبية:

البنية العامة أو الشكل العام للشبكات العصبية الاصطناعية تتألف من المكونات الأساسية التالية أو بعض منها على الأقل حيث توجد بعض الشبكات لا تحتوي على كل هذه العناصر وهذه العناصر هي:

1- طبقة المدخلات Input Layer:

هي الطبقة التي يتم عبرها تغذية الشبكة بالبيانات من الخارج وتستقبل البيانات بواسطة وحدات المعالجة (العصبونات) التي تتألف منها الشبكة، وقد تتألف هذه الشبكة من وحدة معالجة واحدة أو أكثر على حسب تركيبة الشبكة. ومدخلات الشبكة يمكن ان تكون على صورة بيانات خام (Raw Data) أو قد تكون مخرجات من عناصر معالجة أخرى. وحدات المعالجة في طبقة الإدخال لا يتم فيها أي معالجات حسابية بل تقوم بنقل البيانات المدخلة من هذه الطبقة عبر الوصلات البينية (الأوزان) الي وحدات المعالجة في الطبقة الخفية أو مباشرة الي وحدات المعالجة في طبقة المخرجات إذا كانت الشبكة لا تحتوي على طبقة خفية واي شبكة عصبية تحتوي على طبقة واحدة فقط من وحدات الإدخال.

2- طبقة المخرجات Output Layer:

تتكون هذه الطبقة من وحدات المعالجة التي عبرها يتم اخراج الناتج النهائي. وقد تحتوي هذه الطبقة على وحدة معالجة واحدة أو أكثر من وحدة وفقاً للبنية المعمارية للشبكة. تستقبل وحدات المعالجة في طبقة المخرجات الإشارات القادمة اليها من طبقة الإدخال مباشرة أو من الطبقة الخفية وبعد اجراء المعالجات اللازمة قد ترسل إشارة بالمخرجات النهائية أو قد تقوم بإعادة هذه المخرجات كمدخلات مرة أخرى للشبكة وذلك عندما لا تتم المعالجة المطلوبة للبيانات، وتحتوي الشبكة عادة على طبقة مخرجات واحدة فقط.

3- الطبقة الخفية Hidden Layer:

تقع هذه الطبقة بين طبقة المدخلات وطبقة المخرجات وقد لا تحتوي تراكيب بعض الشبكات على الطبقة الخفية وقد تحتوي الشبكة على طبقة واحدة أو أكثر من طبقة خفية. تستقبل الطبقة الخفية الإشارات القادمة اليها من طبقة المدخلات عبر الوصلات البينية فتقوم بمعالجتها واجراء اللازم عليها ومن ثم ارسالها عبر الوصلات الي طبقة المخرجات.

4- الوصلات البينية (الأوزان) Connections:

هي عبارة عن وصلات اتصال بين الطبقات المختلفة تقوم بربط الطبقات مع بعضها أو الوحدات داخل كل طبقة عبر الأوزان التي تكون مصاحبة أو مرفقة مع كل وصلة بينية ومهمة هذه الوصلات نقل البيانات أو الإشارات الموزونة بين وحدات المعالجة أو الطبقات. (عبد الرحمن: 2002)

ثانياً: وحدات المعالجة (العصبونات) Processing Elements:

وحدات المعالجة أو العصبونات هي الوحدات التي تقوم بعملية معالجة المعلومات في الشبكة العصبية وهي تشكل المكونات الأساسية التي تتألف منها كل طبقات الشبكة العصبية وتتصل هذه الوحدات بطرق مختلفة بواسطة الوصلات البينية لتعطي الشكل العام أو البنية المعمارية للشبكة العصبية الاصطناعية.

تتبع عناصر المعالجة نظام المعالجة المتوازنة (parallel processing) في اجراء الحسابات المسندة اليها أو معالجة البيانات، وهي في ذلك تشبه عمل العقل البشري.

وتتألف أي وحدة معالجة أو عصبون من المكونات الأساسية التالية:

1-معاملات الأوزان weighting Coefficients:

يعتبر الوزن هو العنصر الرئيسي في الشبكات العصبية الاصطناعية، فهي تمثل الروابط المختلفة التي يتم عبرها نقل البيانات من طبقة إلى أخرى ويعبر الوزن عن القوة النسبية أو الأهمية النسبية لكل مدخل إلى عنصر المعالجة، وتمثل الأوزان الوسيلة الأساسية لذاكرة الشبكة العصبية من خلال ضبط الأوزان ويرمز للوزن بين عنصري معالجة (i) و (j) بالرمز w_{ij} .

2-دالة الجمع Summation Function:

إن أول عملية تقوم بها وحدة المعالجة هي حساب مجموع المدخلات الموزونة القادمة إلى الوحدة باستخدام دالة الجمع، حيث تقوم هذه الدالة بحساب متوسط الأوزان لكل مدخلات وحدة المعالجة ويتم ذلك بضرب كل قيمة مدخلة في وزنها المصاحب ومن ثم لإيجاد المجموع لكل حواصل الضرب. ويعطي ذلك رياضياً كما يلي:

$$S_j = \sum_{i=1}^n X_i W_{ij}$$

حيث أن:

S_j : نتائج عملية الجمع لكل وحدة معالجة j .

X_i القيمة المدخلة القادمة من الوحدة (i) والمدخلة إلى الوحدة (j).

W_{ij} الوزن الذي يربط وحدة المعالجة (j) بالوحدة (i) الموجودة في الطبقة السابقة.

أحياناً تكتب المعادلة السابقة على الصيغة التالية:

$$S_j = b_j + \sum_{i=1}^n X_i W_{ij}$$

حيث:

b_j يمثل انحياز (bias) ويعتبر أحد مكونات الدخل ويأخذ دائماً القيمة واحد $X_0 = 1$ وعمل الانحياز مشابه لعمل الأوزان لذلك يعمل معاملة أي وزن ويمكن أن يرمز له بالرمز ($b_j = w_{0j}$) وإضافة وحدة انحياز إلى وحدات الدخل يغير من شكل تابع التنشيط أو دالة التحويل.

3- دالة التحويل Transfer Function

إن العملية الثانية في وحدة المعالجة بعد عمل دالة الجمع هو تحويل ناتج الجمع إلى أحد القيم التي يفترض أن تكون ضمن نواتج الشبكة المرغوب بها. وتتم هذه الخطوة باستخدام دالة تسمى بدالة التحويل حيث تقوم هذه الدالة بتحويل ناتج عملية الجمع الموزون في الخطوة الأولى إلى قيمة محصورة في مدى معين ويتم ذلك بمقارنة نتيجة الجمع مع قيمة معينة تسمى قيمة العتبة (threshold) ويرمز لها بالرمز θ ليتحدد الناتج ويطبق على المجموع عادة قبل المقارنة تابع تنشيط معين (Activation function) ويسمى أحياناً بتابع التحويل وتتوقف مخرجات الشبكة بصورة أساسية على هذا التوزيع وبناءً على هذه التوابع أو الدوال تعطي الشبكة دائماً مخرجات محصورة ضمن المجال (0,1) أو المجال (-1,+1).

وهناك العديد من دوال التنشيط التي قدمت من قبل الباحثين والتي اختلفت تبعاً لاختلاف نوعية المخرج الذي يتم الحصول عليها وأهداف الشبكة المراد تحقيقها. ومن أهم توابع التحويل أو توابع التنشيط:

• دالة السيغمويد أو السينية sigmoid function:

القيم المدخلة في الدالة محصورة ما بين $-\infty$ و $+\infty$ ، ويتم تحويل هذه القيم المدخلة الي مخرجات قيمها محصورة بي (0,1) وتسمى في هذه الحالة بدالة تنشيط سيغمويد ثنائي، وهي أكثر الدوال استخداما بسبب سهولة اشتقاقها. أو تحويل المخرجات إلى قيم بين (1,-1) وتسمى بدالة تنشيط ثنائي سيغمويد ثنائي القطبية. وتأخذ دالة السيغمويد الصيغة الرياضية التالية:

$$F(x) = \frac{1}{1 + \exp(-\mu x)}$$

حيث ان:

x : تمثل حاصل ضرب القيمة المدخلة في الوزن المناظر لها.

μ : تمثل ميل الدالة وتكون قيمتها تساوي واحد.

$F(x)$ تمثل مشتقة الدالة وهي:

$$f'(x) = f(x)[1 - f(x)]$$

وتعتبر الدالة السينية أو دالة السغمويد من أهم وأكثر الدوال المستخدمة في الشبكات العصبية الاصطناعية وذلك لقدرتها على نشر وحصر القيم بين (0-1) بشكل انسيابي وتساعد في تحقيق القيمة المخرجة لكافة قيم المدخلات ومهما كانت واطئة وكذلك تمتاز بسهولة الحساب والتنفيذ.

• دالة الخطوة step function:

تحدد هذه الدالة مخرج العصبون بين 0 و 1 بحيث تصبح القيمة المخرجة مساوية الي الواحد إذا كانت القيمة المدخلة أكبر او تساوي صفر، وتصبح القيمة المخرجة مساوية للصفر إذا كانت القيمة المدخلة أصغر من الصفر، وذلك بموجب الصيغة الآتية:

$$f(s) = \begin{cases} 0 & \text{if } s < 0 \\ 1 & \text{if } s \geq 0 \end{cases}$$

وتسمى أيضا بدالة العتبة Threshold. (بشير:2024).

• الدالة الخطية Linear function:

توفر دالة التنشيط الخطي مخرجات تساوي المدخلات الموزونة لوحدة المعالجة وعادة تستخدم وحدات المعالجة بالدالة الخطية في التقريب الخطي وتأخذ الشكل الرياضي التالي: (عاشور:2018)

$$f(x) = S$$

• دالة الإشارة sign function:

تعتبر هذه الدالة من دوال الحد الصلب (hard limiter) وتستخدم عادة في وحدات المعالجة لشبكات عصبية تستخدم في عمليات التصنيف وتميز الأنماط وتستخدم هذه الدالة قيمة معينة تدعى θ وتأخذ الشكل الرياضي التالي: (Ciaburro and Venkateswaran:2020)

$$f(x) = \begin{cases} +1, & \text{if } s \geq \theta \\ -1, & \text{if } s < \theta \end{cases}$$

• دالة المخرجات Output function :

بعد أن تقوم دالة الجمع بعملية الجمع الموزون للمدخلات ومن ثم دالة التحويل بتحويل ناتج الجمع إلى قيمة محصورة في مدى معين، فقد تكون المخرجات في اغلب الأحيان مساوية لناتج دالة التحويل، ولكن هناك بعض الشبكات تقوم وحدة المعالجة فيها بتعديل نتيجة دالة التحويل ويتم ذلك خلال تنافس وحدات المعالجة المجاورة مع بعضها البعض ويتم التنافس عادة بين وحدات المعالجة التي لها تنشيط أكبر، هذه المنافسة تحدد وحدة المعالجة التي ستكون نشطة أو التي ستقوم بالإخراج وكذلك تساعد المنافسة في تحديد الوحدات التي سوف تشترط في عملية التعلم والتدريب.

ويمكن تلخيص عمل وحدة المعالجة في الشبكة العصبية في الخطوات التالية:

- استقبال الإشارات أو المدخلات من العالم الخارجي.
- تعديل الإشارة الداخلة إلى الوحدات عن طريق الأوزان حيث يضرب كل إشارة داخلة بالأوزان الموجود في خط ربط الوحدة.
- جمع أوزان الداخل القادمة من الوحدات الأخرى باستخدام قاعدة أو دالة الجمع.
- تطبيق تابع تنشيط معين على مجموع إشارات الدخل الموزونة حتى يتم تحديد إشارة المخرج الناتج من هذه الوحدة.
- المخرج الناتج عن هذه الوحدة يمكن أن يبيت إلى عدة وحدات معالجة أخرى أو يمكن أن يكون هو الناتج النهائي للشبكة. (عاشور: 2014)


4-2 معمارية الشبكات العصبية الاصطناعية Architecture of ANN:

يقصد بمعمارية الشبكة العصبية الطريقة التي ترتبط بها وحدات المعالجة مع بعضها البعض داخل كل طبقة أو بين الطبقات المختلفة في الشبكة. ويمكن تصنيف معمارية الشبكة العصبية وفقاً لذلك إلى الآتي:

أ- شبكات وحيدة الطبقة Single layer Network:

وهي من أبسط أنواع الشبكات العصبية وتتألف من طبقة واحدة من عناصر المعالجة. ترتبط مدخلات الشبكة في هذا النوع بشكل مباشر مع مخرجاتها، يتم إجراء كل الحسابات في طبقة المخرجات

الشكل (4-2) يوضح معمارية الشبكة العصبية الاصطناعية وحيدة الطبقة




المصدر: مقدمة في الشبكات العصبية الاصطناعية (الحسين والساعدي: 2019)

ب- شبكة متعددة الطبقات Multilayer Network:

تعد الشبكة متعددة الطبقات، واختصاراً (MLP) من أشهر أنواع الشبكات العصبية وأكثرها استخداماً، حيث تعتمد على خوارزمية الانتشار الخلفي (Back propagation) كأسلوب لتصحيح الخطأ والتعلم، تتميز معمارية الشبكة متعددة الطبقات بوجود طبقات في الوسط تدعى الطبقات المخفية (Hidden Layers)، والسبب في وجود هذه الطبقات هو للتمكن من حل المشكلات غير

الخطية (Nonlinear problems) التي لا تستطيع شبكات الانتشار الامامي حلها، يمكن ان تحتوي شبكة متعددة الطبقات على عدد لا نهائي من الطبقات المخفية، ويكون ذلك تبعاً لمدى تعقيد المشكلة التي تحاول الشبكة معالجتها. ومن عيوب كثر الطبقات الخفية في هذه الشبكة هو انها تبطئ من عملية المعالجة. (الحساوي ومالك:2022)

الشكل (2-5) يوضح معمارية الشبكة العصبية الاصطناعية متعددة الطبقات



المصدر: (الحسين والساعدي:2019)، مرجع سبق ذكره

2-5- أنواع الشبكات العصبية الاصطناعية Types of ANN

إن الشبكات العصبية الاصطناعية تكون على نوعين: شبكات ثابتة (Static Network) و شبكات حركية (Dynamic Network) التي تعد امتداداً للشبكات العصبية الثابتة، إذ أن الشبكات الثابتة ليس لها عناصر تغذية عكسية (Feedback) ولا تمتلك تأخيراً زمنياً (Delay time)، أما الشبكات الحركية في تحتوي في الأقل على طبقة واحدة ذات تغذية متكررة، وهذا النوع من الشبكات المخرجات لا تعتمد فيه على المدخلات الشبكة فقط، وإنما تعتمد أيضاً على المدخلات والمخرجات السابقة، فالإشارة في هذا النمط من الشبكات العصبية تتجه نحو الإخراج بالاتجاه العكسي لتكون ادخالا في الوقت نفسه، لذلك يطلق عليه بالشبكات الحركية (الديناميكية). وهنا لابد من الإشارة الى وجود نوعين من التغذية في الشبكات العصبية يمكن ان تصنف على أساسها هي: (صابوا ومطر:2014)

أ- الشبكات العصبية ذات التغذية الامامية feed forward Neural Networks :

وهي الشبكات التي يخلو تركيبها من وجود حلقة مغلقة من الترابطات بين الوحدات المكونة لها، وتعد هذه الشبكات من أكثر الشبكات استخداماً، حيث تتكون الشبكة من هذا النوع من طبقتين على الأقل، كما تتواجد في كثير من الأحيان طبقات مخفية (Hidden Layer) بين طبقة المدخلات وطبقة المخرجات، وتنتقل العمليات الحسابية في اتجاه واحد إلى الأمام من طبقة المدخلات إلى طبقة المخرجات عبر الطبقات المخفية. وبذلك فن الإشارة الخارجة من أي خلية تعتمد على الإشارات الداخلة فقط. ويعد البيرسيترون متعدد الطبقات (Multilayer Perceptron)، وشبكة دالة الشعاعي (Radial Basis Function Network) من أبرز الأمثلة من هذا النوع من الشبكات. (Da Silva et al:2017).

ب- الشبكات العصبية ذات التغذية الراجعة feed Back Neural Networks :

ويأخذ هذا النوع من الشبكات العصبية شكل الشبكة متعددة الطبقات، حيث على الأقل على حلقة تغذية خلفية واحدة. فمخرجات أحد العصبونات اما ان تعود لتمثل مدخلات لنفس العصبون فيما يسمى بالتغذية الخلفية الذاتية او ان تكون مدخلات لعصبون آخر. ومن الأمثلة على الشبكات العصبية ذات التغذية الراجعة شبكة ليمن Elman وشبكة الانحدار الذاتي غير الخطي (NARX). (الامام واخرون: 2025).

2-6- تعليم الشبكات العصبية الاصطناعية Learning in ANN:

ان الخاصية المميزة للشبكات العصبية الاصطناعية هي مقدرتها على التعلم من بيئتها وتحسين ادائها من خلال التدريب، ويهدف التعلم في الشبكات العصبية الي تحديد قيمة الأوزان المرجحة من خلال تدريب الشبكة والذي يمكن ان يتم بإحدى الطرق الثلاثة وهي

1- **التعلم المراقب:** ويسمى بهذا الاسم نظرا لان الشبكة تحتاج فيه اثناء التدريب الي مراقبة ليبين لها المخرج المطلوب لكل من المدخلات. وذلك لان المراقب يملك بعض المعرفة حول البيئة التي لا تكون معروفة عند الشبكات العصبية الاصطناعية، ويعتمد التعلم هنا على مقارنة قيم المخرج الفعلي مع قيم المخرج المطلوب، ثم يتم بناء على ذلك تعديل أوزان الشبكة لتقليص الاختلاف او الخطأ. وتتوقف عملية التعلم او التدريب عندما يكون الاختلاف بين القيم المحسوبة وقيم المخرجات المستهدفة قد وصل الي حده الأدنى المقبول.

2- **التعلم غير المراقب:** ويسمى ايضا التعلم الذاتي، حيث تقوم اساليب التعلم هنا على أساس قدرة الشبكة على اكتشاف الملامح المميزة لهيكل المدخلات من خلال مجموعة البيانات المتاحة ومن ثم يتم تعميم هذه الملامح المميزة على المخرجات. بمعنى ان للشبكات العصبية هنا القدرة على التنظيم الذاتي لأوزان ترابطاتها طبقا لطبيعة ما يعرض عليها من انماط. (Adhikari & Agrawal:2012).

3- **التعلم بإعادة التدعيم:** تقوم عملية التدعيم على اساس الخلط بين طريقة التعلم المراقب والتعلم غير المراقب. حيث لا يفصح للشبكات العصبية الاصطناعية عن القيم الحقيقية للمخرجات كما هو الحال في التعلم غير المراقب، ولكن يشار الي الشبكة بصحة نتائجها او خطأها كما في طريقة التعلم المراقب. التعلم بإعادة التدعيم هو تعلم يتم فيه التدريب بدون مراقب، وهو يعد تقييم لنظام التغذية الخلفي حيث يتم تقييم سلوك النظام. (العباس:2013)

2-7 استخدام الشبكات العصبية الاصطناعية في التنبؤ:

استخدمت تقنية الشبكات العصبية كأسلوب بديل أو أسلوب موازي للأساليب الإحصائية التقليدية التي تستخدم في التنبؤ بالسلاسل الزمنية، كالمتموسطات المتحركة والتمهيد الآسي ونماذج بوكس جنكيز وتعرف هذه الأساليب التقليدية بصورة عامة بأساليب تحليل السلاسل الزمنية، وعلى الرغم من أن هذه الطرق تعطي توقعات دقيقة في مجال السلاسل الزمنية الخطية، إلا أنها تتسم بعائق المكونات المشوشة أو اللاخطية التي تكثر في الواقع العملي. تجاوزا لهذا العائق (تحميل التشويش واللاخطية) اكتشفت أساليب تنبؤ حديثة من أهمها الشبكات العصبية الاصطناعية، وقد نافست نماذج الشبكات العصبية المستخدمة في التنبؤ أساليب التنبؤ التقليدية وتفوقت عليها في كثير من الحالات في دقة النتائج المتحصل عليها.

وتظهر مقدرة الشبكات العصبية في التنبؤ بالسلاسل الزمنية في قدرتها الكبيرة في التعامل مع سلوك عدم الخطية في البيانات، حيث في الواقع تظهر معظم سلاسل البيانات علاقات غير خطية وهذا الأمر يضيف ميزة إضافية على الشبكات العصبية بالمقارنة مع الطرق التقليدية في التنبؤ حيث معظمها تعتبر أساليب خطية أي تتعامل مع بيانات خطية. (أمانة 2014).

ويمكن إيجاز عملية التنبؤ بالاعتماد على الشبكة العصبية الاصطناعية في الخطوات التالية:

الخطوة 1 اختيار المتغيرات Variable Selection: تحديد متغيرات الدراسة. متغيرات مستقلة (المدخلات)، متغيرات تابعة (تسمى الأهداف وقيم التدريب).

الخطوة 2 اختيار البيانات Data Selection: في هذه المرحلة يتم جمع البيانات عن متغيرات الدراسة.

الخطوة 3 معالجة البيانات Data Processing: وذلك بتحويل البيانات الي تمثيل في الشبكة إما بالصورة الثنائية (1,0)

أو بالتمثيل ثنائي القطبية $(-1, +1)$ ، ويعتبر التمثيل ثنائي القطبية هو الاختيار الأفضل لمعظم الشبكات.

الخطوة 4 مجموعة التدريب، الاختبار، والصحة. Training, Testing, and Validation sets: في هذه المرحلة يتم تقسيم البيانات إلى ثلاث فئات وهي فئة التدريب (Training set) وفئة الاختبار (Test set) وفئة التأكيد أو الصحة (Validation set)، وفي الغالب تتم عملية التجزئة للبيانات بصورة عشوائية.

الخطوة 5 نماذج شبكات الخلايا العصبية Neural Network Paradigm: يتم اختيار النموذج أو التركيبة الملائمة عادة بناءً على الغرض من الدراسة وهناك العديد من تراكيب الشبكات العصبية وعلى سبيل المثال شبكات عصبية بنظام الذاكرة الترابطية، تراكيب ذات طبقات مزدوجة، تراكيب ذات طبقات خفية. وكذلك في هذه المرحلة يتم تحديد خوارزمية التعلم التي تتناسب مع تركيبة الشبكة، حيث يتم استخدام هذه الخوارزمية في تدريب الشبكة ومن أهم خوارزميات التدريب خوارزمية الانتشار الخلفي Back propagation algorithm، وايضا يتم تحديد الاتي:

- عدد الطبقات المخفية • Number of Hidden Layers
- عدد الخلايا العصبية المخفية • Number of Hidden Neurons
- عدد خلايا الناتج العصبية • Number of Output Neurons
- دالة النقل • Transfer Function

الخطوة 6 تدريب شبكة الخلايا العصبية Neural Network Training: وذلك بتقديم بيانات التدريب التي تم تجهيزها في الخطوات السابقة ومن خلال التدريب تتغير الأوزان بشكل متكرر، وباستمرار المحاولات التدريبية تتمكن الشبكة من الحصول على متوافقة من الأوزان بشكل متكرر، وباستمرار المحاولات التدريبية تتمكن الشبكة من الحصول على فئة متوافقة من الأوزان يمكننا من الحصول على المخرجات المطلوبة لكل المدخلات، ويتوقف زمن التدريب على تركيبة الشبكة وعدد وحدات المعالجة وعدد الطبقات والقيم الابتدائية المختارة للأوزان ومعدل التعلم، ويتم التوقف من التدريب عندما يصل خطأ الشبكة إلى المستوى المقبول إحصائياً.

الخطوة 7 قواعد التقويم Evaluation Criteria: بعد الانتهاء من عملية التدريب تبدأ عملية الاختبار وذلك بتقديم بيانات الاختبار للشبكة حتى يتم التأكد من أداء الشبكة ومدى قدرتها على حساب المخرجات الصحية وتعتمد هذه المرحلة بصورة أساسية على الأوزان المتحصل عليها من مرحلة التدريب.

الخطوة 8 التنفيذ Implementation: يتم في هذه المرحلة استخدام الشبكة للغرض الذي أنشئت من أجلها ومن ثم المتابعة والتطوير المستمر لتحسين أداء الشبكة. (عبد الله 2012)

2-8- المصطلحات الإحصائية ومصطلحات الشبكات العصبية:

معظم نماذج الشبكات العصبية تشابه أو تكاد تطابق الكثير من النماذج الإحصائية المعروفة مثل النماذج الخطية العامة، الانحدار متعدد الحدود و الانحدار اللامعلمي و التحليل العنقودي والتحليل التمييزي، أيضاً النماذج الغير الخطية أما نماذج الشبكات العصبية التي لا يوجد ما يناظرها من النماذج الإحصائية فهي لا تتعدى القليل مثل نماذج الانتشار المضاد Counter propagation ونماذج خرائط التنظيم الذاتي Self-Organizing Maps ونماذج Learning Vector Quantization وهذه النماذج رغم عدم وجود ما يناظرها من النماذج الإحصائية إلا أنها كذلك تستخدم في تحليل البيانات، وتعتبر عملية تحليل البيانات واحدة من الاتجاهات الثلاثة الأساسية التي تستخدم في تطبيقات نماذج الشبكات العصبية. وبالرغم من التماثل والتشابه بين نماذج الشبكات العصبية والنماذج الإحصائية، إلا أن المصطلحات التي تعبر بها نماذج

الشبكات العصبية وتلك التي تعبر بها النماذج الإحصائية يوجد بينهما اختلاف كبير، أدناه بعض التعبيرات الإحصائية وما يقابلها من الشبكات العصبية.

- المتغيرات المستقلة تسمى مدخلات
- القيم المتنبأ بها تسمى مخرجات.
- المتغيرات التابعة تسمى الأهداف وقيم التدريب.
- البواقي تسمى أخطاء.
- التقدير يسمى تدريب التعلم.
- معيار التقدير يسمى بدالة الخطأ أو دالة التكلفة.
- المشاهدات تسمى الأنماط أو أزواج التدريب.
- تقديرات المعلمة تسمى الأوزان المشابك.
- التفاعلات تسمى عصبونات.
- التحويلات تسمى الوصلات الوظيفية.
- الانحدار وتحليل التمايز تسمى التعلم الموجه.
- تقليل البيانات تسمى التعلم الذاتي أو الاتجاه الذاتي.
- المتغيرات الداخلة والخارجة تسمى التعميم. (عاشور 2018).

3- الجانب التطبيقي من الدراسة:

3-1- مقدمة:

يعتبر خام غرب تكساس الوسيط (WTI) West Texas Intermediate ، إلى جانب خام برنت، من المعايير الأساسية في تسعير النفط عالميًا. تستخدم هذه المعايير لتحديد أسعار العديد من الخامات الأخرى، حيث يتم مقارنة جودة ومواصفات كل خام بهذه المعايير لتحديد سعره النسبي. على سبيل المثال، إذا كان هناك خام ذو جودة أقل أو يحتوي على نسبة أعلى من الكبريت مقارنة بـ WTI ، فقد يُباع بسعر أقل. ويتميز خام غرب تكساس الوسيط بكثافته المنخفضة نسبيًا ومحتواه المنخفض من الكبريت، مما يجعله خامًا "نقيًا". ، ويعتبر مصدر أساسي للبنزين وإنتاج الجازولين في أمريكا الشمالية ويتم استخراجه من حقول النفط في الولايات المتحدة وتحديدًا في ولايات تكساس ولouisiana وداكوتا الشمالية، ثم يتم نقله للتسليم عبر خط أنابيب يمتد إلى مدينة **كوشينغ** التي تعتبر مركزاً هاماً لقطاع مجموعة كبيرة من أنابيب النفط والتصدير إلى الموانئ الأمريكية أو إلى الموانئ العالمية المختلفة. وقد اعتمدت بورصة نيويورك في عقودها تسمية خام غرب تكساس الوسيط على أي مزيج له نفس المواصفات مهما كانت الولاية المنتجة له.

ويتأثر سعر خام غرب تكساس الوسيط بعدة عوامل، مثل الأحداث الجيوسياسية والاقتصادية، وديناميكا العرض والطلب، ومستويات المخزون، والمضاربة في السوق، والمؤشرات الاقتصادية الأمريكية. وكذلك يمكن أن يكون للعوامل المحلية مثل معدلات إنتاج النفط الأمريكي، وتغييرات خطوط الأنابيب، وتقارير المخزونات أيضًا تأثيرات فورية على تسعير الخام. بالإضافة إلى ذلك، تلعب الظروف الاقتصادية العالمية وقرارات إنتاج أوبك وتقنيات الطاقة الناشئة أدوارًا مهمة في تحدي أسعاره. ويمكن أيضًا أن تؤثر الظروف الجوية القاسية، مثل الأعاصير، على عمليات الحفر البحرية وإنتاج المصافي، مما يؤدي إلى ارتفاع تقلبات الأسعار.

باختصار، يُعتبر خام غرب تكساس الوسيط معيارًا مهمًا في سوق النفط العالمي، وتُستخدم أسعاره كمرجع لتسعير العديد من الخامات الأخرى، مما يعكس أهميته في تحديد ديناميكيات أسعار النفط. ويتم تداول أكثر من 85 مليون برميل منه يوميًا في البورصات العالمية.

2-3- عينة الدراسة:

عينة الدراسة عبارة عن سلسلة زمنية للسعر اليومي للبرميل، لخام غرب تكساس الوسيط (WTI) بالدولار الأمريكي. تم جمع بيانات الدراسة من موقع Investing على الانترنت حيث بلغ حجم عينة الدراسة 1232 مشاهدة.


3-3- التحليل الوصفي لبيانات الدراسة:

الجدول رقم (3-1) التالي يوضح الإحصاء الوصفي لبيانات عينة الدراسة

الحد الأدنى	الحد الأعلى	حرف المعياري	متوسط الحسابي	المتغير
47.28	128.26	13.17	79.24	غرب تكساس الوسيط (WTI)

المصدر: من اعداد الباحث من بيانات الدراسة، بناءً على مخرجات برنامج لغة البرمجة R.4.4.3

يلاحظ من رقم (1) ان متوسط سعر برميل خام غرب تكساس الوسيط (WTI) هو (79.24) دولار، بانحراف معياري (13.17) دولار، وبلغ اعلي سعر له (128.26) دولار، وادني سعر (47.28) دولار. خلال فترة الدراسة



الرسم

البياني (3-1) يوضح تطور السعر اليوم لخام غرب تكساس الوسيط (WTI) خلال فترة الدراسة (2024-2021)

المصدر: من اعداد الباحث من بيانات الدراسة، بناءً على مخرجات برنامج لغة البرمجة R.4.4.3

يلاحظ ان من بداية الرسم البياني أعلاه كان هناك اتجاه تصادي في الفترة من 2021 الي منتصف 2022، حيث شهدت الأسعار ارتفاعاً تدريجياً مع دخول عام 2021 واستمرت بالصعود حتى وصلت إلى ذروة واضحة في حدود منتصف عام 2022 (كما يظهر في قمة الرسم). وعقب ذلك، بدأت الأسعار بالتذبذب والانخفاض بشكل ملحوظ، في الفترة من بعد منتصف 2022 الي نهاية 2023 تقريباً، ما يشير إلى مرحلة تقلبات متأثرة بالعوامل الاقتصادية أو الجيوسياسية خلال هذه الفترة. أما الفترة من اواخر 2023 الي ديسمبر 2024. تبدو الأسعار مستقرة نسبياً في هذه الفترة مقارنةً بذروة 2022، حيث تتحرك الاسعار في نطاق أقل من مستويات الذروة.

3-4- بناء نموذج الشبكة العصبية للتنبؤ بالسعر اليومي للبرميل لخام غرب تكساس الوسيط (WTI):

لبناء نموذج الشبكة العصبية المقترح باستخدام لغة البرمجة R نتبع الخطوات التالية:

3-4-1 معالجة البيانات:

تعتبر هذه الخطوة الاولى وفقا للغة البرمجة R، حيث يتم تقديم هذه الخطوة على خطوة تقسيم البيانات حتى يتم تعميم المعالجة على كافة البيانات قبل تقسيمها. وفي هذه الخطوة يتم معالجة البيانات عن طريق تمثيل البيانات في الشبكة أم بصورة الثنائية (0,1)، أو بالتمثيل ثنائي القطبية (-1,1)، ويعتبر التمثيل ثنائي القطبية هو الاختيار الأفضل لمعظم الشبكات.

كود لغة البرمجة R لمعالجة البيانات بالتمثيل ثنائي القطبية (-1,1).

```
> # معالجة البيانات
> dataset_wti$WTI_scaled <- rescale(dataset_wti$WTI, to = c(-1, 1))
```

3-4-2 تقسيم البيانات:

في هذه الخطوة تم تقسيم البيانات التي تم معالجتها في الخطوة السابقة الي ثلاث مجموعات، وهي مجموعة التدريب، ومجموعة التأكيد، ومجموعة الاختبار، وتم تقسيم البيانات يدويا.

كود لغة البرمجة R تقسيم بيانات الدراسة بلغة البرمجة R.

```
> # تقسيم البيانات
> set.seed(1232)
> n <- nrow(dataset_wti)
> train_index <- 1:round(0.7 * n)
> test_index <- (round(0.7 * n) + 1):round(0.85 * n)
> val_index <- (round(0.85 * n) + 1):n
> train_dataset <- dataset_wti[train_index,]
> test_dataset <- dataset_wti[test_index,]
> val_dataset <- dataset_wti[val_index,]
```

الجدول (3-4-1) يوضح نتيجة تقسيم بيانات الدراسة الي المجموعات المستخدمة في بناء الشبكة العصبية.

المجموعة	نسب المشاهدات	عدد المشاهدات
مجموعة التدريب	70%	862
مجموعة التأكيد	15%	185
مجموعة الاختبار	15%	185
المجموع	100%	1232

المصدر: من اعداد الباحث من بيانات الدراسة، بناءً على مخرجات برنامج لغة البرمجة R.4.4.3


في هذه المرحلة تم تقسيم البيانات محل الدراسة والبالغ عددها (1232) مشاهدة الي ثلاث مجموعات، حيث تم استخدام 70% من البيانات بعدد (862) مشاهدة لتدريب الشبكة العصبية. و 15% من البيانات بواقع (185) مشاهدة كمجموعة اختبار. وبمثله كمجموعة تأكيد.

3-4-3 معمارية الشبكة العصبية:

تم الاعتماد على شبكة البيرسبترون متعددة الطبقات (MLP) لبناء معالم نموذج الشبكة العصبية المقترح. وبعد تجريب عدد من معمارية الشبكات العصبية باستخدام برنامج لغة البرمجة R، وتقييمها بواسطة متوسط مربع الخطاء والجزر التربيعي لمتوسط مربع الخطاء ومعامل التحديد اتضح ان المعمارية الي تتكون من ثلاث طبقات هي المعمارية الأنسب لبناء نموذج الدراسة المقترح. الرسم ادناه يوضح ذلك.

```
> # رسم بنية الشبكة العصبية
> plotnet(nn_model)
```

كود لغة البرمجة R، لطباعة معمارية الشبكة العصبية المستخدمة في بناء نموذج الدراسة.



الشكل رقم (3-4-3) يوضح معمارية الشبكة العصبية المستخدمة في بناء نموذج الدراسة.

المصدر: من اعداد الباحث من بيانات الدراسة، بناءً على مخرجات برنامج لغة البرمجة R.4.4.3

من الشكل رقم (3-4-3) الذي يظهر معمارية الشبكة العصبية الاصطناعية المستخدمة في تحليل بيانات الدراسة، والتنبؤ بها، انها تتكون من ثلاث طبقات وهي: طبقة المدخلات (Input Layer) وهي طبقة واحدة ويعبر عنها بالمتغير X1 وهو يمثل السعر اليومي لخام غرب تكساس الوسيط (WTI) في الزمن t. وطبقة خفية (Hidden Layer) واحدة وتضم هذه الطبقة 10 خلايا عصبية (H1 إلى H10). وطبقة اخراج (Output Layer) وهي خلية واحدة يعبر عنها بالمتغير X2 وهو يمثل القيم المتوقعة للسعر اليومي لخام غرب تكساس الوسيط (WTI).

3-4-4- تدريب الشبكة العصبية:

في هذه الخطوة سوف يتم تدريب نموذج الشبكة العصبية المقترح بناءً على المعمارية التي تم التوصل اليها في الخطوة السابقة.

```
> nn_model <- neuralnet(X2 ~ X1, data=train_seq, hidden=c(10), linear.output=TRUE)
```

كود لغة البرمجة R، لتدريب نموذج الشبكة العصبية المقترح

كود لغة البرمجة R، لإظهار نتائج تدريب نموذج الشبكة العصبية المقترح.

```
> nn_model$result.matrix
      [,1]
error      1.218780540
reached.threshold 0.009684416
steps      361.000000000
Intercept.to.1layhid1 -1.001390245
```

الجدول رقم (3-4-4) التالي يشرح كود تدريب الشبكة العصبية المستخدم في بناء النموذج المقترح

الكود	الشرح
nn_model <-	تخزين النموذج المدرب في متغير باسم nn_model
neuralnet(...)	دالة إنشاء وتدريب شبكة عصبية.
X2 ~ X1	المتغير الهدف (X2) يتم التنبؤ به بناءً على المدخل (X1).
data = train_seq	استخدام بيانات التدريب من train_seq
hidden = c(10)	طبقة مخفية واحدة تحتوي على 10 خلايا عصبية (Neurons)
linear.output = TRUE	الإخراج خطي مناسب لمهام الانحدار (Regression)
Backpropagation	لتقليل الخطأ يتم تحديث الأوزان باستخدام خوارزمية الانتشار العكسي
361	تم تكرار عملية التدريب حتى الوصول إلى تحقيق دقة كافية

المصدر: من اعداد الباحث من بيانات الدراسة، بناءً على مخرجات برنامج لغة البرمجة R.4.4.3

3-4-5- اختبار الشبكة العصبية:

حتى يتم التأكد من جودة الاوزان التي تم التوصل اليها من عملية تدريب الشبكة العصبية، يجب تطبيق هذه الأوزان على مجموعة التأكد ومجموعة الاختبار، حتى يتم التأكد من أداء الشبكة ومدى مقدرتها على حساب المخرجات بصورة جيدة وعالية الدقة. الكود التالي يوضح تنفيذ هذه الخطوة في لغة البرمجة R.

```
> # التنبؤ على بيانات الاختبار
> test_pred <- compute(nn_model, test_seq[,1:2])$net.result
> test_actual <- test_seq$X2

> # تحويل القيم المتنبأ بها إلى المقياس الأصلي
> test_pred_rescaled <- rescale(test_pred, to = range(dataset_wti$WTI))
> test_actual_rescaled <- rescale(test_actual, to = range(dataset_wti$WTI))

> # حساب RMSE و MAE و R^2
> rmse <- sqrt(mean((test_actual_rescaled - test_pred_rescaled)^2))
> mae <- mean(abs(test_actual_rescaled - test_pred_rescaled))
> r2 <- cor(test_actual_rescaled, test_pred_rescaled)^2
> rmse
[1] 1.871816
> mae
[1] 1.275602
> r2
[1,]
[1,] 0.9812574
```

لحساب معايير تقييم النموذج المقترح للتأكد من جودته في عملية التنبؤ. R. كود لغة البرمجة


يلاحظ من النتائج تقييم نموذج الشبكات العصبية المقترح أعلاه ان قيمة الجذر التربيعي لمتوسط مربع الخطاء يساوي (RMSE=1.87)، وهذه القيمة تعتبر منخفضة نسبياً، مما يدل على ان متوسط الخطأ بين التنبؤات والقيم الحقيقية (الفعالية) صغير وهذا أمر جيد. ونلاحظ أيضاً ان قيمة متوسط الخطأ المطلق تساوي (MAE=1.27)، وهي أيضاً منخفضة نسبياً مما يشير الى دقة جيدة للنموذج في التنبؤ. اما بالنسبة لمعامل التحديد فهو يقيس التغير في المتغير التابع (القيم الفعلية) التي يمكن تفسيرها بواسطة النموذج (القيم المتنبأ بها)، نجد انها تساوي ($R^2=98.12$)، وهذا يعني ان نموذج الشبكات العصبية المقترح يفسر حوالي 98.12% من التغيرات والاختلافات في أسعار النفط الفعلية (WTI)، وفقط 1.88% لم يتمكن النموذج من تفسيرها (تعزى الى عوامل اخرى)، وهذا أداء ممتاز للغاية. وهذا دليل على ان الشبكة العصبية تعلمت النمط الموجد في البيانات بشكل جيد.

```

> # رسم القيم الفعلية والمتنبأ بها
> plot_df <- data.frame(Date = dataset_wti$date[2:length(dataset_wti$date)], Actual = test_actual_rescaled, Predicted = test_pred_rescaled)
> ggplot(plot_df, aes(x = Date)) +
+   geom_line(aes(y = Actual, color = "Actual"), color = "blue") +
+   geom_line(aes(y = Predicted, color = "Predicted"), color = "red") +
+   labs(title = "Actual vs Predicted WTI Prices", x = "Date", y = "WTI Price") +
+   theme_minimal()

```

كود لرسم القيم الفعلية مع القيم المتنبأ بها:



الرسم البياني رقم (3-4-5) التالي يوضح مقارنة بين الاسعار الفعلية لخام غرب تكساس الوسيط والاسعار المتنبأ بها بواسطة نموذج الشبكة العصبية المقترح.

المصدر: من اعداد الباحث من بيانات الدراسة، بناءً على مخرجات برنامج لغة البرمجة R.4.4.3

من الرسم اعلاه يتضح ان القيم التنبؤية (المخرجات) تحاكي القيم الفعلية بنسبة تقارب 100%، خلال فترة الدراسة. وشبه التتابع التام بين منحي الأسعار الفعلية (باللون الازرق)، ومنحي الأسعار المتنبأ بها (باللون الاحمر) خير دليل على ذلك. عليه يمكن الاعتماد على النموذج المقترح بالتنبؤ بأسعار خام غرب تكساس الوسيط (WTI) في المستقبل.

3-4-6- التنبؤ:

وهي تعتبر المرحلة الأخيرة من مراحل تصميم النموذج والتي يتم من خلالها استخدام الشبكة العصبية من أجل الغرض الذي انشأت من اجله وهو التنبؤ، وقد اعطى النموذج تنبؤات مستقبلية لسعر اليومي لخام غرب تكساس الوسيط (WTI) للفترة من 2025/1/1 الي 2025/1/10. وعند مقارنتها مع الأسعار الفعلية لأسعار الخام التي لدينا معلومات مسبقه عنها. وجدنا ان هذه الأسعار (المتنبأ بها) أظهرت توافقاً مع الأسعار الفعلية وقريبة جداً منها، ما يؤكد دقة وجودة نموذج الشبكة العصبية المقترح في التنبؤ بأسعار الخام (WTI). نتائج الكود ادناه توضح ذلك.

كود من لغة البرمجة R لإظهار السعر اليومي لخام غرب تكساس الوسيط (WTI) في الفترة من 2025/1/1 الي 2025/1/10


```

> عرض النتائج #
> results <- data.frame(Date = dataset_wti$date[2:length(dataset_wti$date)],
+                         Actual = train_actual_rescaled,
+                         Predicted = train_pred_rescaled)
> print(results)
      Date   Actual Predicted
1 2025-01-02 71.80000 72.74968
2 2025-01-03 73.45129 71.82177
3 2025-01-05 74.94614 71.80000
4 2025-01-06 75.05043 72.55290
5 2025-01-07 73.69464 71.95753
6 2025-01-08 75.85000 72.77824
7 2025-01-09 73.41652 71.80632
8 2025-01-10 75.01567 75.85000

```

3-5 - نتائج الدراسة:

- استخدام تقنية الشبكات العصبية الاصطناعية (ANN) كبديل عن الأساليب الإحصائية التقليدية. وذلك لأنها أثبتت قدرتها على التنبؤ وحل المشكلات بدقة وسهولة مقارنة بهذه الأساليب، حيث يمكن تطبيقها بدون النظر إلى فرضيات معينة عن طبيعة المتغيرات وعلاقتها مع بعضها البعض وذلك على العكس من الطرق التقليدية العادية المستخدمة في التنبؤ.
- توصلت الدراسة إلى أن متوسط سعر اليومي لبرميل خام غرب تكساس الوسيط (WTI)، بلغ (79.24) دولار، وبلغ أعلى سعر له (128.26) دولار، وأدنى سعر كان (47.28) دولار. ويتم تداول أكثر من 85 مليون برميل نفط منه يوميا في البورصات العالمية.
- تم معالجة بيانات الدراسة عن طريق تمثيل ثنائي القطبية (-1,1)، وكذلك تم تقسيم بيانات الدراسة البالغ عددها (1232) مشاهدة، إلى ثلاث مجموعات المجموعة الأولى هي مجموعة التدريب تمثل 70% من البيانات بعدد (862) مشاهدة، المجموعة الثانية مجموعة الاختبار تمثل 15% من البيانات بواقع (185) مشاهدة، والمجموعة هي مجموعة التأكيد تمثل 15% من البيانات بواقع (185) مشاهدة.
- اعتمدت الدراسة على شبكة بيرسبترون متعددة الطبقات (MLP) لبناء معالم الشبكة العصبية للبيانات، وبعد تجريب عدد من معماريات الشبكات العصبية باستخدام برنامج لغة البرمجة R، وتقييمها بواسطة معايير التقييم توصلت الدراسة إلى أن المعمارية المكونة من ثلاث طبقات (1,10,1) الأنسب في لبناء نموذج الدراسة المقترح. كما استخدمنا دالة الانحدار (Regression) كدالة تحفيز في الطبقة الخفية وفي طبقة المخرجات، مستعينا بخوارزمية الانتشار العكسي Backpropagation، وتكررت عملية التدريب 361 مرة، للوصول إلى الدقة كافية.
- من خلال الرسم البياني (3-4-5) نجد أن القيم التنبؤية (المخرجات) تحاكي القيم الفعلية بنسبة تقارب 100%، خلال فترة الدراسة. وهناك شبه تطابق التام بين منحي الأسعار الفعلية للخام ومنحي الأسعار المتنبأ بها، هذا يدل على النموذج المقترح ذو دقة عالية في التنبؤ بأسعار الخام (WTI) في المستقبل.
- أثبتت نموذج المقترح قوة تفسير عالية جداً وفقاً لقيمة معامل التحديد، حيث يفسر حوالي 98.12% من التغيرات والاختلافات في أسعار النفط الفعلية (WTI)، والمتنبأ بها. وحوالي 1.88% فقط لم يتمكن النموذج من تفسيرها (تعزي إلى عوامل أخرى مثل مستويات المخزون من الخام، الإنتاجية، التوترات الجيوسياسية، ... الخ)،
- أظهر النموذج المقترح أداءً قوياً جداً في التنبؤ، مع أخطاء منخفضة جداً. حيث بلغت قيمة متوسط الخطأ المطلق (MAE=1.27). مما يساعد في رسم سياسات مالية والاقتصادية للدول بشكل جيد لتجنب مخاطر تقلبات أسعار النفط مستقبلاً.
- أعطى النموذج المقترح تنبؤات مستقبلية جيدة لسعر البرميل اليومي لخام غرب تكساس الوسيط (WTI) في الفترة من 2025/1/10 إلى 2025/1/1. وعند مقارنتها مع الأسعار الفعلية لأسعار الخام والتي لدينا معلومات مسبقة عنها. وجدنا أن

هذه الأسعار (المتنبأ بها) أظهرت توافقاً مع الأسعار الفعلية وقريبة جداً منها، هذا ما يؤكد دقة وجودة نموذج الشبكة العصبية المقترح.

- توصلت الدراسة الي ان هناك عوامل أخرى غير ديناميكا العرض والطلب تتحكم في أسعار النفط الخام (WTI) ولا يمكن التنبؤ بها مثل التوترات الجيوسياسية والاقتصادية، والمشاكل اللوجستية خصوصاً في منطقة الشرق الاوسط، ومستويات مخزون النفط، والمؤشرات الاقتصادية الأمريكية ومعدلات الإنتاج.
- تلعب الظروف الاقتصادية العالمية وقرارات إنتاج أوبك وتقنيات الطاقة الناشئة أيضاً أدواراً مهمة في تحديد أسعار النفط الخام. أضف الي ذلك تأثير قرارات الرئيس الأمريكي المنتخب مثل القرارات بشأن فرض الرسوم الجمركية على الدول وغيرها من القرارات الأخرى التي لها تأثير مباشر بأسعار النفط.

3-6- توصيات الدراسة:

- ضرورة استخدام تقنية الشبكات العصبية الاصطناعية (ANN) في عملية التنبؤ بأسعار النفط الخام نظراً لاستنادها على المنهج العلمي واستخدامها لوسائل الاقناع الرياضي والأدوات الإحصائية التي تساعد متخذ القرار برسم السياسات ووضع الافتراضات حول أسعار النفط الخام على المدى القصير والطويل، لتجنب مخاطر تقلبات أسعار النفط الخام مستقبلاً خصوصاً عند ابرام الصفقات الآجلة.
- يجب على القائمين على الإدارات الاقتصادية للدول المنتجة والمستهلكة وصناع القرار ان يدركوا ان هناك عوامل اخري غير ديناميكا العرض والطلب تتحكم في أسعار النفط الخام في العالم، وهذه العوامل غير ملموسة ولا يمكن التنبؤ بها مما تؤثر سلباً في دقة وجودة التنبؤ بأسعار الخام.
- استخدام الطاقة النظيفة والمتجددة والصديقة للبيئة في عمليات الإنتاج لتقليل تلوث البيئة والحفاظ على استدامة الطاقة، وتقليل نفقات الطاقة مما يؤدي الي تقليل مخاطر تقلبات أسعار النفط الخام على موازنة الدولة.
- ضرورة اجراء مزيد من الدراسات في هذا المجال، واقتراح استخدام نموذج هجين بين نماذج إحصائية تقليدية ونماذج الشبكات العصبية الاصطناعية، في عملية التنبؤ، مثلاً دمج نماذج بوكس-جينكنز مع تقنية ANN.
- قبل البدء في استخدام لغة البرمجة R في بناء نماذج الشبكات العصبية الاصطناعية، يجب تحميل واستدعاء المكتبات التالية (install.packages & library (neuralnet , caret, ggplot2, scales, scales من الانترنت. وتتميز هذه اللغة عن غيرها في انها مرنة وسهلة ومجانية ويتم تحديثها بشكل دوري.

3-7- قائمة المراجع

أولاً: المراجع باللغة العربية:

- 1- آسيا، س، ونام، س، (2023). استخدام الذكاء الاصطناعي للتنبؤ بأسعار البترول، دراسة قياسية بالجزائر من (1986-2023)، رسالة ماجستير غير منشورة، جامعة بلحاج بوشعيب عين تموشنت، الجزائر.
- 2- الامام، س، أبوريا، م، محمد، م، (2025). نموذج مقترح لتحسين منهجية بوكس-جينكنز اعتماداً على أسلوب الشبكات العصبية، المجلة العلمية للدراسات والبحوث المالية والتجارية، المجلد السادس، العدد الأول، الجزء الرابع، 325-324.
- 3- أمينة، د، (2014). محاولة التنبؤ بمؤشرات الاسواق المالية العربية باستعمال النماذج القياسية، دراسة حالة سوق دبي المالي، أطروحة دكتوراة غير منشورة، جامعة ابي بكر بلقايد، الجمهورية الجزائرية.
- 4- الحساوي، س، مالك، و، (2022). التنبؤ بأسعار الاغلاق للأسهم باستخدام الشبكات العصبية لعينة من المصارف الإسلامية العراقية، مجلة بيت المشورة، العدد 18، 81.
- 5- الحسين، ق، الساعدي، أ، (2019). مقدمة في الشبكات العصبية الاصطناعية.

- 6- رقايقية، ف، (2019). كتاب جماعي بعنوان: تطبيقات الذكاء الاصطناعي كتوجه حديث لتعزيز تنافسية منظمات الاعمال، الطبعة الاولى.
- 7- بشير، م (2024). المقارنة بين نماذج الشبكات العصبية الاصطناعية (ANN) ونماذج GARCH في نمذجة تقلبات عائدات الخرطوم للأوراق المالية والتنبؤ بها، أطروحة دكتوراه غير منشورة، جامعة ام درمان الإسلامية، جمهورية السودان.
- 8- صابوا، ر، مطر، ظ، (2014). تقييم تنبؤ السلسلة الزمنية لمعدلات دراجات الحرارة باستخدام الشبكة العصبية، المجلة العراقية للعلوم الإحصائية العدد 26، 14-15.
- 9- عاشور، م، (2014). استخدام الشبكات العصبية الاصطناعية المحسنة ونماذج بوكس-جنكينز في تحليل السلاسل الزمنية، أطروحة مقدمة لنيل درجة الدكتوراه فلسفة (PHD) في الإحصاء التطبيقي، رسالة غير منشورة، جامعة السودان للعلوم والتكنولوجيا، جمهورية السودان.
- 10- عاشور، م، (2018). الشبكات العصبية الاصطناعية وطرائق تنبؤ السلاسل الزمنية، الأولى، بغداد، الذاكرة للنشر والتوزيع.
- 11- العباس، ع، (2013). التقيب في البيانات تطبيقات باستخدام SPSS.
- 12- عبد الرحمن، ع، (2002)، طرق التنبؤ الاحصائي (الجزء الاول)، جامعة الملك سعود.
- 13- عبد الله، ج، (2012). التنبؤ بالسلاسل الزمنية لمنسوب النيل الأزرق في محطة ود مدني باستخدام نماذج بوكس - جنكينز ونماذج الشبكات العصبية الاصطناعية، رسالة دكتوراه غير منشورة- جامعة السودان للعلوم والتكنولوجيا، السودان.
- 14- الفرهود، س، ناصر، س، العيسى، م، (2019). النمذجة والتنبؤ بأسعار النفط الخام لمنظمة أوبك باستخدام نموذج ARIMA-GARCH الهجين، مجلة كلية التجارة للبحوث العلمية، المجلد 56، العدد الثاني، 1-2.
- 15- المبحوح، م، (2018). التنبؤ بأسعار البترول دراسة مقارنة بين نموذج ARFIMA و ANN، رسالة ماجستير غير منشورة، جامعة الازهر، غزة.
- 16- محمد، ت، (2021). تصميم نظام معرفي باستخدام الشبكات العصبية والانحدار اللوجستي والمترج لتصنيف الطلاب لمدارس الموهوبين، بحث مقدم لنيل درجة الدكتوراه في الاقتصاد القياسي، رسالة غير منشورة، جامعة بخت الرضا، السودان.
- 17- مرابطي، س، (2019). استخدام الشبكات العصبية الاصطناعية في التنبؤ بسعر البترول الخام برنت، مجلة الدراسات المالية والمحاسبية والإدارية، المجلد 06، العدد 04، 160-161.
- 18- الموسوي، ض، (2004). ثورة أسعار النفط، الجزائر، الديوان الوطني للمطبوعات الجامعية.
- 19- مولود، ب، جمال، ه، (2017). العلاقة بين أسعار النفط وبعض المتغيرات الاقتصادية في الجزائر، مقاربة تحليلية وصفية، مجلة الريادة لاقتصاديات الاعمال، المجلد رقم 03، العدد 05، 119.
- ثانيا: المواقع الالكترونية:
- 20- موقع vantage (2025) تم استرجاع الرابط بتاريخ 2025-3-15
<https://www.vantagemarkets.com/ar/academy/brent-vs-wti-crude-oil>
- 21- موقع vantage (2025) تم استرجاع من الموقع بتاريخ 2025-3-20 www.investing.com
- ثالثا: المراجع الاجنبية:

- 22-Adhikari, R. and Agrawal, R. K. (2012) " Forecasting strong seasonal time series with artificial neural networks ", Journal of Scientific & Industrial Research, Vol. 71
- 23-Ciaburro, G. and Venkateswaran, B, (2020). Neural Networks with R, "Smart models using CNN, RNN, deep learning, and artificial intelligence principles", Packt -BIRMINGHAM-MUMBAI.
- 24-Da Silva , I. Spatti, D. Flauzino , R, Liboni, L. And Alves, S. (2017). Artificial Neural Networks: A Practical Course. Springer International Publishing Switzerland. pp: 23.
- 25-Hunt, B., D. Muir, and M. Sommer. (2015). The Potential Macroeconomic Impact of the Unconventional Oil and Gas Boom in the United States,” Working Paper 15/92, International
- 26-Kurnar, J. and aI,(2010). “Artificial Neural Networks an Application to Stock Market Volatility” International Journal of Engineering Science and Technology, DC, Vol. 02, NO. 05,pp:15-16.
- 27-Kuo, H. Chen, H. (2009), "Using the artificial neural network to predict fraud litigation: Some empirical evidence from emerging markets", Expert Systems With Application, Vol.36, No.2, pp.1478-1484.