

Using artificial networks to predict Algerian oil prices (Saharan Blend)

Hadj Kouider Abdelhadi¹, Benlaria Ahmed², Baghafar Abdelkader³

¹University Ahmed Draia -Adrar, Algeria (The Spatial and Entrepreneurial Development Studies Laboratory), H.abdelhadi@univ-adrar.edu.dz

²University Ahmed Draia -Adrar, Algeria (Algerian-African Economic Integration Laboratory), ahmed.benlaria@univ-adrar.edu.dz

³University Ahmed Draia -Adrar, Algeria (Algerian-African Economic Integration Laboratory), a.kaderbagheffar@univ-adrar.edu.dz

Received: 11/2023, Published: 12/2023

Abstract:

This study explores the efficacy of Artificial Neural Networks (ANN) in forecasting monthly crude oil prices. Utilizing data from January 1990 to August 2023, an ANN model was developed and trained to predict future values. The results were promising, showing a strong correlation with actual prices and underscoring the potential of ANNs in financial forecasting. The research indicates that machine learning can significantly contribute to the predictive analytics in the energy market, offering a valuable tool for economic and strategic planning.

Keywords: Artificial Neural Networks, Oil Price Forecasting, Time Series Prediction, Machine Learning, Energy Economics.

استخدام الشبكات العصبية الاصطناعية في التنبؤ بأسعار النفط الجزائري (Saharan Blend)

حاج قويدر عبد الهادي¹، بن العارية محمد²، بغفار عبد القادر³

¹ جامعة أحمد دراية أدرار - الجزائر (مخبر التكامل الاقتصادي الجزائري الافريقي)، H.abdelhadi@univ-adrar.edu.dz
² جامعة أحمد دراية أدرار - الجزائر (مخبر التكامل الاقتصادي الجزائري الافريقي)، ahmed.benlaria@univ-adrar.edu.dz
³ جامعة أحمد دراية أدرار - الجزائر (مخبر التكامل الاقتصادي الجزائري الافريقي)، a.kaderbagheffar@univ-adrar.edu.dz

الملخص

تستكشف هذه الدراسة فعالية الشبكات العصبية الاصطناعية (ANN) في تنبؤ أسعار النفط الخام الشهرية باستخدام بيانات من يناير 1990 إلى أغسطس 2023، تم تطوير وتدريب نموذج ANN للتنبؤ بالقيم المستقبلية. أظهرت النتائج وعودًا بمستوى توافق قوي مع الأسعار الفعلية، مما يؤكد على إمكانية الشبكات العصبية في التنبؤ المالي. تشير البحث إلى أن التعلم الآلي يمكن أن يساهم بشكل كبير في التحليلات التنبؤية في سوق الطاقة، مقدمًا أداة قيمة للتخطيط الاقتصادي والاستراتيجي.

الكلمات المفتاحية: الشبكات العصبية الاصطناعية، تنبؤ أسعار النفط، التنبؤ بالسلسلة الزمنية، التعلم الآلي، اقتصاد الطاقة.

مقدمة:

يعتمد التنبؤ بأسعار البترول على العديد من المتغيرات الاقتصادية، بالإضافة إلى العديد من العوامل الجيوسياسية. فأسعار البترول عرفت منذ عقود العديد من الهزات سواء بالارتفاع والانخفاض وهو ما يؤثر بشكل كبير على اقتصاديات العديد من الدول.

وباعتبار الجزائر تعد من دولة منتجة للنفط، وتعتمد عليه بشكل كبير في رسم سياستها الاقتصادية، فإن تقلبات أسعار النفط قد تحدث العديد من الأزمات سواء في الأجل القصير أو الطويل، نظرا لكون النفط وعوائده المالية يشكلان المورد الرئيسي لتمويل الاقتصاد في الجزائر.

الإشكالية:

هل يمكن للشبكات العصبية الاصطناعية أن تكون أداة فعالة للتنبؤ بأسعار النفط الجزائري؟

الفرضيات:

- التنبؤ باستخدام تقنية الشبكات العصبية الاصطناعية يعطي نتائج دقيقة وقريبة من النتائج الفعلية؛
- استخدام نموذج الشبكات العصبية الاصطناعية في التنبؤ بأسعار البترول الجزائري من شأنه أن يساعد الجزائر في رسم سياساتها الاقتصادية

أهداف الدراسة:

نسعى من خلال هذه الدراسة الى تطبيق الذكاء الاصطناعي في التنبؤ بأسعار النفط الجزائري، واستعراض كيفية قيام الشبكات العصبية الاصطناعية، بتحليل ومعالجة كميات هائلة من البيانات المتعلقة بأسعار النفط وعوامل السوق المختلفة، وتقديم تنبؤات دقيقة لأسعار النفط المستقبلية.

أهمية الدراسة

من خلال إشكالية الدراسة سوف نوضح قدرة التقنيات الحديثة مثل الشبكات العصبية الاصطناعية على تحقيق تنبؤات دقيقة لأسعار النفط، كما تثير إشكالية الدراسة قضايا أساسية تستكشف قدرة التكنولوجيا على التغلب على التحديات المرتبطة بالتنبؤ بأسعار النفط، وتستحضر الفوائد المحتملة للشبكات العصبية الاصطناعية في هذا السياق. وتعد تطبيقات التنبؤ بأسعار النفط باستخدام الذكاء الاصطناعي مفيدة للعديد من الأطراف المهتمة مثل مستثمري النفط والغاز وشركات النفط والحكومات والمحليلين الاقتصاديين. وتساعد هذه التوقعات على اتخاذ قرارات استراتيجية أفضل واكتساب ميزة تنافسية في سوق النفط العالمية، الشيء الذي يمكن واضعي السياسات في الجزائر تجنب سلبيات العديد من الازمات التي قد تشهدها أسعار النفط مستقبلا.

الدراسات السابقة:

لقد لاقت تطبيقات تقنيات الذكاء الاصطناعي، وبشكل خاص الشبكات العصبية الاصطناعية (ANN)، في التنبؤ بأسعار النفط اهتمامًا متزايدًا في السنوات الأخيرة. تهدف هذه المراجعة الأدبية إلى تلخيص النتائج الرئيسية من الدراسات الحديثة، مسلطة الضوء على فعالية وأداء النماذج العصبية الاصطناعية في هذا المجال.

- دراسة (ساهر ، مكيديش 2014) : حاولت هذه الدراسة المقارنة بين طريقة الشبكات العصبية الاصطناعية وطريقة استخدام البرمجة بالأهداف في تحليل الانحدار المبهم للتنبؤ بأسعار البترول، وتم الاعتماد على معيار متوسط القيم المطلقة لنسبة الخطأ للمفاضلة بين هذين الطريقتين. وتم التوصل إلى أن طريقة البرمجة بالأهداف في تحليل الانحدار المبهم تتفوق على طريقة الشبكات العصبية الاصطناعية في التنبؤ بأسعار البترول.

دراسة (عبد الوهاب، حميد 2017): حاول الباحثان الى بناء نموذج احصائي يمكن بواسطته التنبؤ باسعار النفط العراقي باستخدام نموذج الشبكات العصبية، وتم التوصل إلى ان التنبؤ باستخدام الشبكات العصبية يكون على اساس تدريب الشبكة العصبية ومحاكاتها لواقع البيانات مما يعطيها قوة اكثر في الحصول على قيم تقديرية افضل من الطرق الكلاسيكية وان اسعار النفط التي تم التنبؤ بها هي مقاربة الى حد كبير لواقع اسعار النفط العراقي خلال الفترة من 2016 الى 2020.

- دراسة (د. مرابطي، 2019) هدفت هذه الدراسة إلى 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 إلى غاية 2019/04/01، وقد تم الاعتماد على شبكة البيروسترون متعدد الطبقات (MLP) لبناء معالم الشبكة العصبية للبيانات وذلك باستخدام برنامج Aiyuda لتحليل المعطيات. وقد توصلت الدراسة إلى أن استخدام نموذج الشبكات العصبية الاصطناعية في التنبؤ، له جودة عالية في التنبؤ بأسعار البترول محل الدراسة، وهذا ما يجعله يساعد في رسم السياسة المالية والاقتصادية للدول.

- دراسة (Suleiman ، 2015) ، هدف هذه الدراسة الى التنبؤ بأسعار البترول النيجيري، باستخدام نماذج ARIMA و GARCH للفترة الزمنية الممتدة من جانفي 1998 إلى سبتمبر 2013 ، وتوصلت الدراسة الى أن نماذج ARIMA و GARCH تعتبر من بين أفضل نماذج التنبؤ بسلسلة بيانات أسعار البترول.

ركزت دراسة أجراها العرجاني وآخرون (2022) على توقع إنتاج النفط الخام في السعودية باستخدام نماذج مختلفة بما في ذلك ANN، ونموذج هولت-وينترز للتنعيم الأسي، ونموذج الانحدار الذاتي المتكامل المتوسط المتحرك (ARIMA). أظهرت نتائج الدراسة تفوق الشبكات العصبية الاصطناعية في توقع إنتاج النفط الخام، مما يشير إلى إمكانية استخدامها كأداة توقع موثوقة في صناعة النفط (Alarjani et al, 2022).

في سياق أوسع، أجرى محمد ومسعدية (2023) مراجعة أدبية تغطي الأعمال الأكاديمية من 2010 إلى 2022 حول خوارزميات الذكاء الاصطناعي لتوقع أسعار النفط. أبرزت مراجعتهم الانتشار المتزايد للشبكات العصبية الاصطناعية وآلات الدعم الناقل (SVMs) في توقع أسعار النفط. تعد هذه الدراسة قيمة للغاية حيث تقدم رؤى حول أحدث الاتجاهات والمنهجيات في توقع أسعار النفط باستخدام الذكاء الاصطناعي، مع التأكيد على الدور الرئيسي لـ ANN في الأبحاث الحديثة (Mohamed & Messaadia 2023).

في دراسة مقارنة أجراها يوسف وسمسدين، تم فحص أداء نماذج ANN و ARIMA في توقع أسعار نفط خام غرب تكساس الوسيط (WTI). خلصت الدراسة إلى أن نماذج ANN تفوقت على ARIMA من حيث دقة التوقع. تعتبر هذه النتيجة حاسمة لأنها لا تظهر فقط فعالية نماذج ANN ولكنها تشير أيضًا إلى تفوقها على النماذج الاقتصادية التقليدية في سياق توقع أسعار نفط WTI (Yusof & Samsudin 2020).

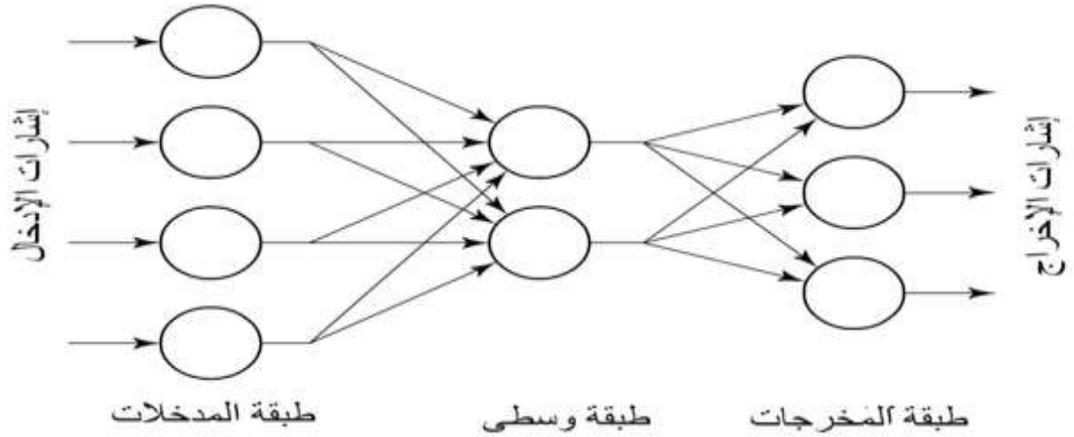
أخيرًا، أجرى سيفابراكاش ومانو (2021) دراسة تجريبية لاستكشاف استخدام الشبكات العصبية في توقع أسعار النفط الخام. وجدت الدراسة أن الشبكات العصبية البسيطة، وخاصة تلك التي تستخدم خوارزميات الانتشار العكسي، كانت أكثر كفاءة في التوقع من النماذج التقليدية للسلاسل الزمنية. تضيف هذه الدراسة إلى الأدلة المتزايدة التي تدعم استخدام ANN في توقع أسعار النفط، مسلطة الضوء على قابلية التكيف والدقة للنموذج (Sivaprakash & Manu 2021).

تشير هذه الدراسات مجتمعة إلى أن ANN لا تحمل فقط ميزة مقارنة على النماذج التقليدية للتوقع ولكنها تتكيف أيضًا بشكل جيد مع التعقيدات الكامنة في توقع أسعار النفط. توفر هذه الأعمال أساسًا متينًا لمزيد من الاستكشاف والتطبيق لـ ANN في مجال توقع أسعار النفط.

مفاهيم حول الشبكات العصبية الاصطناعية مفهوم الشبكة العصبية الاصطناعية ومكوناتها

تم تطوير الشبكات العصبية الاصطناعية من نماذج معروفة من الجهاز العصبي البيولوجي والدماغ البشري. وتتكون من وحدات معالجة تسمى بالخلايا العصبية الاصطناعية وهي نماذج مبسطة للخلايا العصبية البيولوجية. واستلهمت هذه النماذج من تحليل كيفية قيام غشاء الخلية في الخلايا العصبية بتوليد ونشر النبضات الكهربائية (Nunes, Hernane, Andrade, Liboni, & dos Reis, 2017, p. 11).

تتكون الشبكة العصبية الاصطناعية من عدد من المعالجات البسيطة والمتراصة تسمى بالخلايا العصبية الاصطناعية، والتي تشبه الخلايا العصبية البيولوجية في الدماغ. ترتبط الخلايا العصبية فيما بينها بروابط مرجحة تمرر الإشارات من عصبون إلى آخر. يتلقى كل عصبون عددًا من إشارات الإدخال من خلال الروابط، ولا ينتج أكثر من إشارة إخراج واحدة. تنتقل إشارة الإخراج من خلال عصبون وتنقسم بدورها إلى عدد من الفروع التي تنتقل نفس الإشارة. تنتهي هذه الفروع عند الاتصالات الواردة للخلايا العصبية الأخرى في الشبكة (Medsker & Liebowitz, 1994).



ويمثل الشكل (1) بنية شبكة عصبية اصطناعية.
شكل (1): بنية شبكة عصبية اصطناعية

ترتبط الخلايا العصبية بروابط ولكل رابط وزن رقمي مرتبط به. وتعتبر الأوزان عن قوة وأهمية كل مدخل من مدخلات الخلايا العصبية. وتتعلم الشبكة العصبية من خلال التعديلات المتكررة لهذه الأوزان. تتكون الشبكات العصبية الاصطناعية النموذجية كما هو موضح في الشكل (1) من تسلسل عدد من الطبقات، ويتم ترتيب الخلايا العصبية في الشبكات على طول هذه الطبقات. وتشكل الخلايا العصبية المتصلة بالبيئة الخارجية طبقات المدخلات والمخرجات. يتم تعديل الأوزان لمواءمة سلوك مدخلات ومخرجات الشبكة مع سلوك البيئة الخارجية. تعتبر كل خلية عصبية هي وحدة أولية لمعالجة المعلومات، ولديها وسيلة لحساب مستوى التنشيط بناءً على المدخلات والأوزان العددية (Michael, 2005, p. 168).

التدريب والتعليم في الشبكات العصبية

أهم ما تتميز به الشبكات العصبية الاصطناعية هو قدرتها على التعلم من خلال عرض العينات (الأنماط patterns)، والتي تعبر عن سلوك النظام. وبالتالي، بعد تعلم الشبكة العلاقة بين المدخلات والمخرجات، يمكنها تعميم ما تعلمته على مدخلات أخرى، مما يعني أن الشبكة يمكنها توليد متغيرات قريبة من المخرجات المتوقعة (أو المطلوبة) لأي قيم إدخال معينة (Nunes, Hernane, Andrade, Liboni, & dos Reis, 2017, p. 26).

عملية التدريب لشبكة عصبية تكون عبر خطوات منسقة لضبط الأوزان المشبكية وعتبات التنشيط للخلايا العصبية، وذلك من أجل تعميم الحلول التي تولدت من مخرجاتها. وتسمى هذه الخطوات المنسقة المستخدمة لتدريب الشبكة بخوارزمية التعلم (algorithm learning).

عادة يتم تقسيم مجموعة البيانات (المدخلات) إلى مجموعتين: المجموعة الأولى للتدريب والمجموعة الثانية للاختبار. تستخدم مجموعة التدريب والمكونة من 60-90% من العينات العشوائية من مجموعة البيانات بشكل أساسي في عملية التعلم؛ كما تستخدم مجموعة الاختبار والتي تتكون من 10-40% من مجموعة العينات للتحقق مما إذا كانت الشبكة قادرة على تعميم الحلول ضمن المستويات المقبولة مع مراعاة الخصائص الإحصائية للبيانات.

التعليم بالإشراف Supervised Learning

يقوم التعليم الخاضع للإشراف بضبط أوزان الشبكة من خلال مقارنة مباشرة بين مخرجات الشبكة الفعلية والمخرجات المطلوبة. وهو عبارة عن نظام تغذية عكسية مغلق، حيث يكون الخطأ هو إشارة هذه التغذية العكسية. يتم استخدام مقياس الخطأ الذي يعبر عن الفرق بين مخرجات الشبكة والمخرجات من عينات التدريب في توجيه عملية التعلم. ويتم عادة قياس الخطأ بمتوسط مربعات الأخطاء (MSE). وذلك حسب العلاقة التالية (Du & Swamy, 2013, p. 25):

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$$

حيث:

N : هو عدد الثنائيات (مدخلات-مخرجات) للعينة؛

y_i : هو المخرج رقم i من عينة التدريب؛

\hat{y}_i : هو المخرج الشبكة العصبية الناتج عن المدخل رقم i من عينة التدريب.

يتم حساب الخطأ E لكل مخرج من المخرجات، ويتم إنهاء عملية التعلم عندما يكون الخطأ صغيراً بما فيه الكفاية. ويمكن تطبيق نموذج التعليم بالإشراف على الشبكات العصبية ذات التغذية الأمامية (Feedforward Neural Networks) والشبكات العصبية المتكررة (Recurrent Neural Networks) (Tebelskis, 1995, p. 37).

التعليم بدون إشراف Unsupervised Learning

التعليم بدون إشراف لا يحتاج إلى المخرجات المطلوبة للمقارنة، وإنما يعتمد فقط على الارتباطات والخواص المشتركة لبيانات الإدخال. ويحاول تقسيم هذه المدخلات إلى مجموعات بناءً على خواصها المشتركة (Du & Swamy, 2013, p. 26).

التقنيات شائعة الاستخدام في التعليم بدون إشراف هي التحليل العنقودي (Cluster analysis)، تحليل المكونات الرئيسية (Principal Component Analysis PCA)، تحليل المكونات المستقلة (Independent Component Analysis ICA)، وبعض الشبكات العصبية مثل شبكات الخصومة التوليدية (Generative Adversarial Networks GANs) وأجهزة الترميز التلقائي (Autoencoders AEs) (De Marchi, 2019, p. 11).

الدراسة التطبيقية

أولاً: جمع البيانات

استخدمت هذه الدراسة مجموعة بيانات شاملة لمتوسط أسعار النفط الخام الشهرية من يناير 1990 إلى أوت 2023. تم الحصول على الأسعار، المعبر عنها بالدولار الأمريكي للبرميل الواحد، من قاعدة بيانات منظمة الاقطار المصدرة للبتروال OPEC لضمان دقة واتساق التحليل.

ثانياً: معالجة البيانات

خضعت البيانات الأولية لعدة خطوات معالجة لتهيئتها للتحليل:
- تطبيع البيانات: تم تحويل أسعار النفط إلى نطاق بين 0 و 1 باستخدام منظم النطاق الأدنى-الأقصى. هذه الخطوة ضرورية لضمان فعالية خوارزمية الانحدار الهابط خلال عملية التدريب.
- إنشاء القيم المبطأة: لتحويل التنبؤ إلى مشكلة تعلم تحت إشراف، تم إنشاء مجموعة بيانات تتضمن التباطؤات الزمنية للسلسلة الزمنية الأصلية. يعتمد هذا على استخدام أسعار الأشهر الـ 12 السابقة كمدخلات للتنبؤ بسعر الشهر الحالي، مما يعكس الاعتمادات الزمنية في بيانات السلسلة الزمنية.

ثالثاً: تكوين الشبكة العصبية الاصطناعية (ANN)

تم تصميم الشبكة العصبية الاصطناعية كنموذج تسلسلي بالخصائص التالية:
- طبقة الإدخال: تحتوي طبقة الإدخال على 12 عصبون، تتوافق مع الـ 12 مدخلة للتباطؤات الزمنية.
- الطبقات الخفية: تضمن النموذج طبقتين خفيتين. الطبقة الخفية الأولى بها 100 عصبون، والطبقة الخفية الثانية بها 50 عصبون. كلا الطبقتين تستخدمان دالة التنشيط "وحدة الخط المستقيم المعدلة" (ReLU)، المعروفة بكفاءتها في نماذج التعلم العميق.
- طبقة الإخراج: تتألف طبقة الإخراج من عصبون واحد بدالة تنشيط خطية للتنبؤ بالقيمة المستمرة لأسعار النفط.
- خوارزمية التعلم والتحسين: استخدم النموذج خوارزمية Adam optimizer وتم تدريبه لتقليل دالة الانحرافات (MSE). وازموية Adam optimizer تتميز بقدرتها على التكيف مع معدل التعلم، مما يساعد على الوصول إلى الأوزان المثلى بكفاءة.

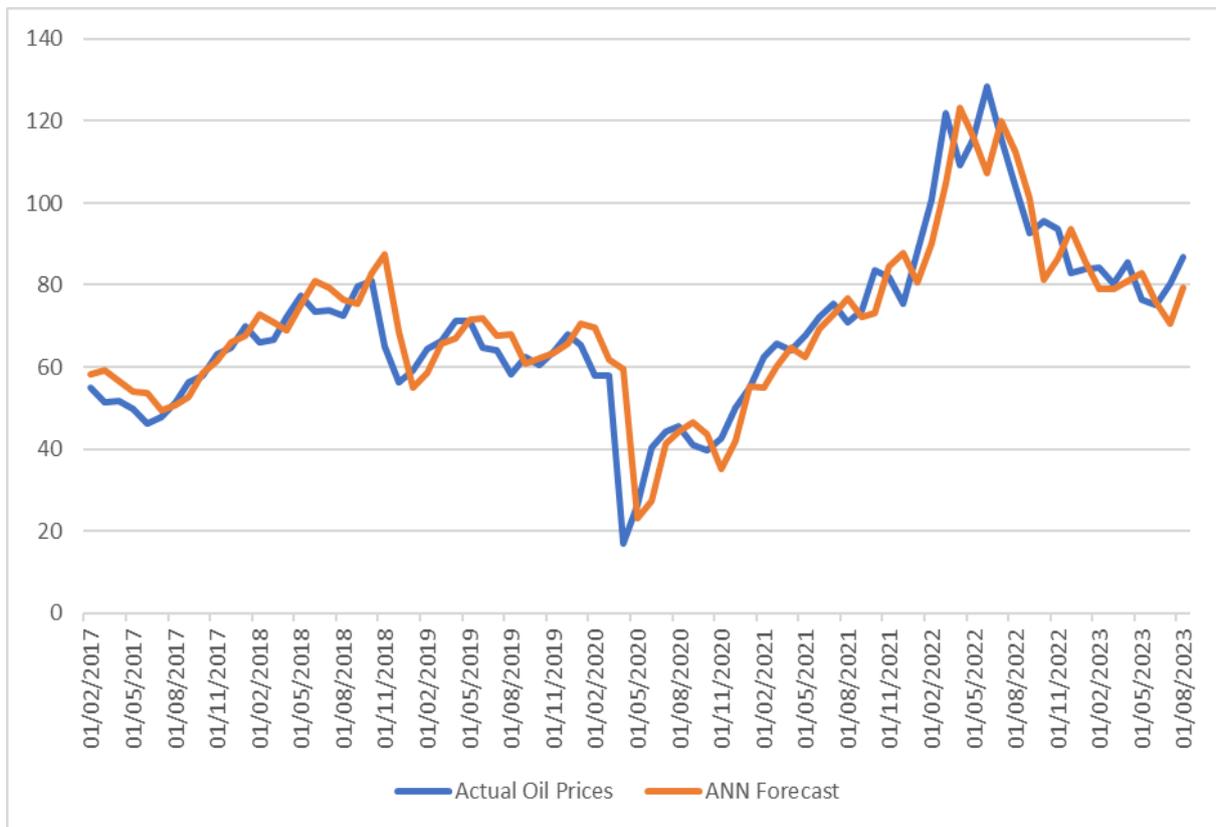
رابعاً: إجراءات التدريب

خضع النموذج لعملية التدريب التالية:

- تقسيم البيانات: تم تقسيم البيانات المتاحة إلى مجموعات تدريب واختبار، حيث تم تخصيص 80% للتدريب والباقي لاختبار قدرة النموذج التنبؤية.
- معلمات التدريب: تم تدريب الشبكة العصبية لمدة 50 دورة تدريبية (epoch) بحجم دفعة قدرها 32، وهو تكوين تم تحديده لتحقيق التوازن بين الطلبات الحسابية وكفاءة التعلم.
- التوقف المسبق للتدريب: لمنع الإفراط في التكيف (overfitting)، تم استخدام التوقف المبكر مع معلمة الصبر (patience parameter) لمراقبة خسارة التحقق، وبالتالي إيقاف التدريب عندما تتوقف أداء النموذج عن التحسن على مجموعة الاختبار.

خامساً: تقييم النموذج:

تم تقييم دقة التنبؤ للشبكة العصبية الاصطناعية كميًا باستخدام مقياس الخطأ التربيعي الجذري (RMSE). بالإضافة إلى ذلك، تم رسم مخطط خطي للمقارنة بين أسعار النفط الفعلية والتنبؤات التي قدمتها الشبكة العصبية، مما يوفر عرضًا حسيًا لأداء النموذج على مدى الأفق الزمني للتنبؤ.



شكل (2): مقارنة بين مخرجات النموذج والقيم الفعلية

تم تطبيق نموذج الشبكة العصبية الاصطناعية (ANN) للتنبؤ بأسعار النفط الخام على أساس شهري (جانفي 2017-أوت 2023)، وأظهرت النتائج قدرة النموذج على محاكاة التقلبات في الأسعار بدقة متناهية. يُعزى الأداء القوي للنموذج إلى قدرته على تعلم الأنماط المعقدة من البيانات التاريخية واستخدام هذه الأنماط لتوليد تنبؤات دقيقة.

يُظهر الشكل (2) المقارنة بين التنبؤات والأسعار الفعلية مدى التقارب الكبير وتتبع النموذج للاتجاهات العامة في البيانات. ومع ذلك، فإن النموذج أظهر بعض التباينات في الأسعار القصوى، مما يشير إلى أن هناك مجالاً للتحسين، ربما عن طريق تعديل معمارية الشبكة أو تحسين عملية التدريب.

يُعد مقياس RMSE المعيار الرئيسي لتقييم دقة النموذج، حيث سجل النموذج قيمة 2.74 وهي قيمة منخفضة تشير إلى ارتفاع مستوى التقارب بين القيم المتنبئ بها والقيم الفعلية. يشير هذا إلى أن النموذج قادر على التقاط الديناميكيات الأساسية للسوق بفعالية.

سادسا: مناقشة النتائج

من المهم التأكيد على أن نموذج ANN ، كأى نموذج تنبؤي آخر، يخضع لقيود معينة. فعلى سبيل المثال، قد تتأثر دقة التنبؤات بالأحداث العالمية غير المتوقعة التي لا يمكن للنموذج التقاطها من البيانات التاريخية وحدها. علاوة على ذلك، قد تكون هناك حاجة إلى استكشاف تقنيات تدريب إضافية مثل التعلم المعزز أو استخدام مجموعات بيانات متنوعة لتحسين قدرة النموذج على التعميم. توفر النتائج دليلاً واضحاً على إمكانية استخدام الشبكات العصبية الاصطناعية في التنبؤ بأسعار النفط بدقة. مع ذلك، فإنها تسلط الضوء على الحاجة إلى مزيد من البحث لاستكشاف تحسينات النموذج واستراتيجيات التدريب لتعزيز الأداء في مواجهة تقلبات السوق الكبيرة.

خاتمة

في ختام هذه الدراسة، يمكن التأكيد على أن الشبكات العصبية الاصطناعية تمثل أداة قوية وموثوقة في تحليل البيانات الزمنية والتنبؤ بأسعار النفط. لقد أثبتت النتائج التي توصلنا إليها أن الشبكة العصبية الاصطناعية التي تم تطويرها وتدريبها ضمن هذا البحث قادرة على التقاط الأنماط المعقدة وتقديم توقعات دقيقة تُظهر مدى التطور الذي شهدته تقنيات التعلم الآلي.

على الرغم من التحديات المرتبطة بتقلبات السوق والأحداث العالمية غير المتوقعة، فإن الشبكة الاصطناعية قدمت تنبؤات بمستوى عالٍ من الدقة، مما يدل على إمكانية تطبيق هذه التقنية في مجال الاقتصاد الكلي وصناعة الطاقة. كما يفتح هذا الباب أمام إمكانية استخدام الشبكات العصبية الاصطناعية كأداة دعم في اتخاذ القرارات الاقتصادية والاستراتيجية.

ومع ذلك، يجب التنويه إلى أهمية المتابعة المستمرة لأداء النموذج وإعادة تقييمه بصفة دورية لضمان بقاء دقة التنبؤات في أعلى مستوياتها. ولا يزال هناك مجال لإجراء المزيد من الأبحاث لتحسين النماذج الحالية وتطوير نماذج جديدة قادرة على التعامل مع التغيرات السريعة والمعقدة في سوق النفط العالمي.

تأمل هذه الدراسة أن تكون قد أسهمت في تعزيز فهم الإمكانيات الكبيرة التي تقدمها الشبكات العصبية الاصطناعية في تحليل السلسلة الزمنية وتنبؤ الأسعار، وتشجيع الباحثين والمختصين على استكشاف هذا المجال الواعد.

المراجع:

- [1] Alarjani, A., Alam, T., & Kineber, A. (2022). Modeling and Predicting Saudi Crude Oil Production Using Artificial Neural Networks (ANN) and Some Others Predictive Techniques. [DOI:10.1109/ISMODE56940.2022.10180990]
- [2] He, X., & Xu, S. (2010). Process Neural Networks: Theory and Applications. Berlin: Springer.
- [3] Medsker, L., & Liebowitz, J. (1994). Design and Development of Expert Systems and Neural Computing. New York: Macmillan College Publishing Company.
- [4] Michael, N. (2005). Michael N. (2005). Artificial Intelligence: A Guide to Intelligent Systems. Harlow, England: Addison-Wesley p. 166. Boston, Massachusetts, United States: Addison-Wesley.

- [5] Mohamed, N. A., & Messaadia, M. (2023). Artificial Intelligence Techniques for the Forecasting of Crude Oil Price: A Literature Review. [DOI:10.1109/CyMaEn57228.2023.10050945]
- [6] Nunes, S. I., Hernane, S. D., Andrade, F. R., Liboni, L., & dos Reis, A. S. (2017). Artificial Neural Networks: A Practical Course. Berlin: Springer.
- [7] Sivaprakash, J., & Manu, K. (2021). Forecasting Crude Oil price using Artificial Neural Network model. [DOI: 10.52711/2321-5763.2021.00049]
- [8] Yusof, S., & Samsudin, R. Comparison of Artificial Neural Network (ANN) and Autoregressive Integrated Moving Average (ARIMA) Models for WTI Crude Oil Price Forecasting.
- [9] ساهد عبد القادر ، مكيديش محمد، دراسة مقارنة بين الانحدار المبهم باستخدام البرمجة بالأهداف والشبكات العصبية الاصطناعية للتنبؤ بأسعار البترول، مجلة الباحث، المجلد 14، العدد 14، 2014.
- [10] سناء مرابطي، استخدام الشبكات العصبية الاصطناعية في التنبؤ بسعر البترول الخام برنت، مجلة الدراسات المالية والمحاسبية والإدارية، المجلد 06، العدد 04، ديسمبر 2019.