

## استعمال ادوات الذكاء الاصطناعي في التنبؤ بأسواق المال

ياسين أسد مهنا راجحي<sup>(1)</sup>

جامعة الحلة / كلية الإدارة والاقتصاد

[rajihy.yasen@hilla-unc.edu.iq](mailto:rajihy.yasen@hilla-unc.edu.iq)

حسنين عبد الامير عبد الحسن<sup>(2)</sup>

[hussainalsady44@gmail.com](mailto:hussainalsady44@gmail.com)

### الملخص:

تهدف هذه الدراسة إلى استكشاف الإسهام المحتمل للشبكات العصبية الاصطناعية في تعزيز دقة التنبؤات المالية وتقوية تدابير الأمن السيبراني في مواجهة الهجمات المتطورة. يمتد تأثير الشبكات العصبية الاصطناعية إلى الأسواق المالية، حيث استُعملت بنجاح في تحليل البيانات الضخمة والتنبؤ باتجاهات السوق بالاعتماد على أنماط معقدة تعجز الأساليب التحليلية التقليدية عن اكتشافها. كما تعتمد هذه الشبكات على التعلم العميق ومعالجة البيانات الزمنية لتحليل مؤشرات السوق، بما يسهم في اتخاذ قرارات استثمارية أكثر دقة. ومع ذلك، تواجه هذه المحاولات بعض القيود، من بينها حالة عدم اليقين الذي تمتاز به البيانات المالية الكبيرة وصعوبة التكيف مع الصدمات الاقتصادية غير المتوقعة.

تُعد خوارزمية الانتشار العكسي واحدة من أكثر خوارزميات تدريب الشبكات العصبية شيوعًا في التنبؤ بالسلاسل الزمنية المالية. وتتمثل إحدى أبرز الإشكاليات المرتبطة باستعمال هذه الخوارزمية في تحديد عدد الطبقات المخفية وعدد الخلايا في كل طبقة مخفية. يسعى هذا البحث إلى اقتراح أفضل نموذج للتنبؤ بسوق المال من خلال استعمال نماذج مختلفة من خوارزمية الانتشار العكسي، بالاعتماد على اختلاف عدد الخلايا في الطبقة المخفية. وقد تم اعتماد سوق دبي المالي مثالاً تطبيقيًا لتقييم أداء النماذج المختلفة. حيث تم جمع خمس سلاسل زمنية مالية خام تمثل على التوالي سعر الافتتاح اليومي، وأعلى سعر يومي، وأدنى سعر يومي، وسعر الإغلاق اليومي، وحجم التداول اليومي، وذلك خلال فترة أيام التداول في سوق دبي المالي (DFM) من 4 أبريل 2022 إلى 21 فبراير 2025 حيث تضم كل سلسلة زمنية 800 قراءة. وتُظهر النتائج التجريبية أن

النموذج المعماري المكوّن من طبقة إدخال واحدة تحتوي على  $N$  من الخلايا، وطبقة مخفية واحدة تضم  $\frac{2(N+1)}{3}$  خلية، وطبقة إخراج تحتوي على خلية واحدة، يتفوق على بقية النماذج المقترحة من حيث الأداء والدقة والوقت المستغرق.

**الكلمات المفتاحية:** الاسواق المالية، الذكاء الاصطناعي، الخلايا العصبية الاصطناعية، خوارزمية الانتشار العكسي، التنبؤ في سوق المال.

**Abstract.** This study seeks to explore the potential contribution of ANNs in enhancing financial prediction accuracy and bolstering cybersecurity measures in the face of sophisticated attacks. The influence of ANNs extends to financial markets where it has been successfully used in big data examination and market trend prediction based on complex patterns that classical analytical methods fail to detect. They leverage deep learning as well as temporal data processing for analysis of market indicators to help make more accurate investment decisions. Yet these approaches have their limitations, including data bias and difficulty adapting to unexpected economic shocks. Back Propagation (BP) algorithm is one of the most popular neural network training algorithms for financial time series prediction. One of the biggest problems regarding the use of BP algorithm is the number of hidden layers and the number of neurons in each hidden layer. In this paper we try to propose the best model of forecasting the stock market using different models of BP algorithm depending on the number of neurons in the hidden layer. Dubai Financial Market (DFM) from 4 April 2022 till 21 February 2025 every financial time series contains 300 data is used as an illustrative example to evaluate the performance of the different models. The experimental results show that the model of architecture consisting of an input layer with  $N$  neurons, one hidden layer with  $\frac{3}{2}(N+1)$  neurons and output layer with one neuron outperforms the other models.

**Key words:** Financial Markets, Artificial Intelligence, Artificial Neural Network, Back Propagation Algorithm, Financial Market Forecasting.

## 1. المقدمة

تلعب نظم دعم القرار الاستثماري دورًا محوريًا في الجانبين التطبيقي والنظري للاستثمار، ولا سيما في ظل التقدم المتسارع في أتمتة التداول في أسواق رأس المال، وما رافق ذلك من تطور في أدوات التحليل المالي واتخاذ القرار (الهيتمي، 2010؛ شحاتة، 2015). ويُعد سوق رأس المال نظامًا معقدًا وديناميكيًا يتغير بمرور الزمن، ويتأثر بعدد كبير من العوامل الاقتصادية والمالية والنفسية، كما تتسم تقلباته غالبًا بخصائص لا خطية قوية تعكس طبيعة التفاعل بين هذه العوامل (السامرائي، 2012). وتُعد عملية التنبؤ بسوق الأسهم إحدى المشكلات الرئيسية في اتخاذ القرار ضمن العملية الاستثمارية، وقد شكّلت على الدوام

أحد أكبر التحديات التي واجهت المجتمع العلمي، نظرًا لما تتسم به الأسواق المالية من تقلبات وعدم استقرار (عبد المجيد، 2014). ويتطلب التنبؤ بحركة سوق الأسهم تحسينًا مستمرًا لنماذج التنبؤ المستخدمة، سواء التقليدية أو الحديثة، من أجل زيادة قدرتها على التعامل مع البيانات المعقدة والمتغيرة بمرور الزمن (النجار، 2016). وبناءً عليه، يُنظر إلى التنبؤ بسوق الأسهم على أنه مهمة صعبة في إطار التنبؤ بالسلاسل الزمنية المالية، ويُعزى ذلك أساسًا إلى حالة عدم اليقين والغموض التي تحكم حركة الأسواق المالية، إضافة إلى تأثير العوامل غير الكمية والأحداث المفاجئة على سلوك المستثمرين واتجاهات السوق (العلي، 2018). على الرغم من استعمال تقنيات تقليدية متعددة، مثل التحليل الإحصائي والتحليل الأساسي والتحليل الفني، للتنبؤ بحركة سوق الأسهم بغرض تحقيق الأرباح، إلا أن تنفيذ هذه الأساليب يتميز بالتعقيد ويستلزم إجراءات مطولة. ومع ذلك، فإن هذه التقنيات لا توفر تحليلًا معمقًا بما يكفي، وبالتالي فإن فعاليتها في التنبؤ بأسواق الأسهم محدودة. وبالنظر إلى ذلك، فإن هذه الفئة من الحلول التقليدية لم تعد صالحة لتلبية متطلبات التنبؤ الحديثة في الأسواق المالية. تُعد الشبكات العصبية الاصطناعية فرعًا من فروع الذكاء الاصطناعي، وتمثل نظامًا ديناميكيًا واسع النطاق وغير خطي، يتميز بقدرات على إجراء العمليات غير الخطية المعقدة، والتعلم الذاتي، والتنظيم الذاتي (الهيبي، 2010؛ عبد المجيد، 2014). وتُعد هذه الشبكات أكثر ملاءمة للتنبؤ بحركة سوق الأسهم مقارنة بالأساليب التقليدية، حيث تمتلك القدرة على التعلم واكتشاف الأنماط أو العلاقات من البيانات نفسها (النجار، 2016؛ العلي، 2018). في التطبيقات العملية، عادةً تستخدم ما يسمى بالشبكات العصبية الأمامية (Feed-Forward Neural Network) في عمليات التنبؤ. تعد خوارزمية الانتشار العكسي من أكثر خوارزميات الشبكات العصبية استعمالًا في التنبؤ بالسلاسل الزمنية المالية، حيث تتميز بقدرة قوية على حل المشكلات المعقدة (شحاتة، 2015؛ الهيبي، 2010). وقد تم تطوير هذه الخوارزمية لتدريب شبكة تنبؤية متعددة الطبقات، حيث يُعتبر استعمال الشبكة العصبية الأمامية ذات الثلاث طبقات مناسبًا للتنبؤ بالسلاسل الزمنية نظرًا لقدرتها على تقريب أي دالة مستمرة معقدة. ويواجه الباحث عند استعمال خوارزميات الشبكات العصبية الاصطناعية مشكلتين رئيسيتين: الأولى تتعلق باختيار عدد الطبقات المخفية، والثانية تتعلق بتحديد عدد الخلايا في كل طبقة مخفية (عبد المجيد، 2014؛ النجار، 2016).

في التطبيقات العملية، لا توجد حاجة لاستعمال أكثر من طبقة مخفية واحدة في التنبؤ بالسلاسل الزمنية المالية. علاوة على ذلك، يجب اختيار عدد الخلايا في الطبقة المخفية بعناية فائقة. والسؤال الرئيس عند استعمال الشبكات العصبية في التنبؤ يتمحور حول: كم عدد الخلايا التي يجب استعمالها في الطبقة المخفية؟ إن استعمال عدد قليل جدًا من الخلايا في الطبقة المخفية يؤدي إلى مشكلة **نقص الملاءمة**، في حين أن استعمال عدد كبير جدًا من الخلايا قد يؤدي إلى عدة مشكلات، منها **الإفراط في الملاءمة** وزيادة الوقت اللازم لتدريب الشبكة، وغيرها من المشكلات. بشكل عام، يعتمد اختيار عدد الخلايا في الطبقة المخفية على أسلوب التجربة والخطأ.

وتتمثل القواعد الثلاثة الأساسية لاختيار العدد المناسب من الخلايا في الطبقة المخفية فيما يلي:

#### 1. قاعدة الحد الأعلى والحد الأدنى للخلايا:

يجب أن يكون عدد الخلايا في الطبقة المخفية أكبر من عدد الخلايا في طبقة الإدخال وأقل من ضعف عدد الخلايا في طبقة الإدخال، لضمان قدرة الشبكة على التعميم دون الإفراط في الملاءمة (الهيبي، 2010).

## 2. قاعدة التجربة والخطأ:

غالبًا ما يتم تحديد العدد الأمثل للخلايا من خلال التجربة والخطأ، حيث يتم تعديل العدد تدريجيًا ومراقبة أداء الشبكة حتى الوصول إلى أفضل نتيجة للتنبؤ (شحاتة، 2015).

## 3. قاعدة استعمال الدوال التقريبية:

يوصى باختيار عدد خلايا يسمح للشبكة بتقريب أي دالة مستمرة معقدة دون زيادة التعقيد غير الضروري للنموذج، ما يساعد على تحقيق توازن بين الدقة والفعالية الحسابية (النجار، 2016)

لقد أجريت كثير من الدراسات حول التنبؤ بأسواق الأسهم باستعمال تقنيات الشبكات العصبية الاصطناعية خلال العقود الثلاثة الماضية، والتي تناولت استعمال هذه الشبكات في التنبؤ بالسلاسل الزمنية المالية وتحليل البيانات المعقدة (الهيبي، 2010؛ شحاتة، 2015؛ عبد المجيد، 2014). في هذا البحث، نسعى إلى تقديم أفضل نموذج للتنبؤ بسوق الأسهم باستعمال نماذج مختلفة من خوارزمية الانتشار العكسي، مع مراعاة تأثير عدد الخلايا في الطبقة المخفية على أداء النموذج. ولتقييم أداء النماذج المقترحة، واستعملت سوق دبي المالي مثالاً تطبيقياً وتُظهر النتائج التجريبية أن النموذج المعماري المكوّن من طبقة إدخال تحتوي على  $N$  من الخلايا، وطبقة مخفية واحدة تضم  $\frac{2(N+1)}{3}$  خلايا، وطبقة إخراج تحتوي على خلية واحدة فقط، يتميز بدقة أعلى وأخطاء أقل مقارنة بالنماذج الأخرى. وبعبارة أخرى، يُعد هذا النموذج الأكثر كفاءة ويمتلك أفضل أداء في التنبؤ بحركة سوق الأسهم.

## 2. منهجية البحث

تُعد خوارزمية الانتشار العكسي (Back Propagation) واحدة من أكثر خوارزميات تدريب الشبكات العصبية استعمالاً في مجال التنبؤ بالسلاسل الزمنية المالية. وتتميز هذه الخوارزمية بألية انتشار الخطأ العكسي، كما تُصنّف ضمن فئة الشبكات العصبية الأمامية متعددة الطبقات (Kao L. J., 2012)، (Lee, 2009)، (Lu, 2010). وتتم عملية تدريب الشبكة العصبية المعتمدة على خوارزمية الانتشار العكسي وفق الخطوات التالية (Liu, 2011):

ليكن  $Inp(n)$  و  $Out(n)$  يمثلان قيمة الإدخال وقيمة الإخراج للخلية العصبية  $n$  على التوالي حيث ان :

$$Inp(n) = \sum_m w_{mn} Out(m) \quad (1)$$

$$Out(n) = f[Inp(n) + \beta(n)] \quad (2)$$

حيث ان  $w_{mn}$  تمثل مقدار الاوزان الواصلة من الخلية  $m$  في الطبقة السابقة الى العقدة  $n$  في الطبقة الحالية وان:

$$f(net) = (2/1 - e^{-2net}) - 1 \quad (3)$$

هي دالة التفعيل للعقد، بينما  $\beta(n)$  تمثل حد الانحياز المدخل الى الخلية  $n$  وان خطأ الإخراج يحسب بالشكل التالي:

$$E = \frac{1}{2N} \sum_N \sum_o \sqrt{[P(No) - Out(No)]^2} \quad (4)$$

حيث ان  $N$  و  $o$  ترمزان الى عدد الخلايا في مجموعة التدريب وعدد الخلايا في طبقة الاخراج على التوالي. بينما  $P(No)$  و  $Out(No)$  ترمز الى قيم الهدف والايخراج على التوالي. التدريب ينتهي عندما يكون مقدار الخطأ  $E$  مادون مستوى العتبة او حد التسامح. الخطأ في طبقة الاخراج  $e(o)$  والخطأ في الطبقة المخفية  $e(n)$  يحسب بالشكل التالي:

$$e(o) = \lambda [P(o) - Out(o)] f'(Out(o)) \quad (5)$$

$$e(n) = \lambda \sum_m e(o) w_{nm} f'(Out(n)) \quad (6)$$

حيث  $P(o)$ ،  $Out(o)$ ،  $Out(n)$  و  $\lambda$  تمثل قيمة المخرجات المتوقعة لخلية الاخراج ذات الترتيب  $o$ ، قيمة الاخراج الحقيقي في طبقة الاخراج، قيمة الاخراج الحقيقي في الطبقة المخفية و المتغير القابل للضبط في دالة التفعيل على التوالي. لاحظ ان  $f'$  ترمز الى المشتقة الاولى للدالة  $f$ . يتم تحديث الأوزان وحدود الانحياز في كل من طبقتي الإخراج والطبقة المخفية باستعمال خطأ الانتشار العكسي. الأوزان  $w_{nm}$  وحدود الانحياز  $\beta(m)$  تضبط حسب المعادلات التالية:

$$w_{nm}(k+1) = w_{nm}(k) + \gamma e(o) Out(m) \quad (7)$$

$$\beta(m)(k+1) = \beta(m)(k) + \gamma e(m) \quad (8)$$

حيث ان  $k$  ترمز الى عدد دورات التدريب و  $\gamma$  الى نسبة التعلم على التوالي.

#### 4. الدراسة التطبيقية

في مجال التنبؤ بسوق الأسهم، تُستعمل عادةً البيانات التاريخية لآخر يوم تداول، والتي تشمل سعر الافتتاح اليومي، وأعلى سعر يومي، وأدنى سعر يومي، وسعر الإغلاق اليومي، وحجم التداول اليومي، للتنبؤ بسعر إغلاق السهم في يوم التداول التالي. ويمكن اعتماد هذه المؤشرات التاريخية بوصفها مدخلات لخوارزمية الانتشار العكسي (BP)، في حين تمثل المخرجات سعر إغلاق سوق الأسهم لليوم التالي. في هذه الدراسة، وبالاعتماد على الأنماط الثلاثة المختلفة المذكورة سابقاً، تم تطبيق خوارزمية BP ذات التغذية الأمامية ثلاثية الطبقات على ثلاثة نماذج معمارية مختلفة، وذلك بالاعتماد على عدد الخلايا في الطبقة المخفية كما يأتي:

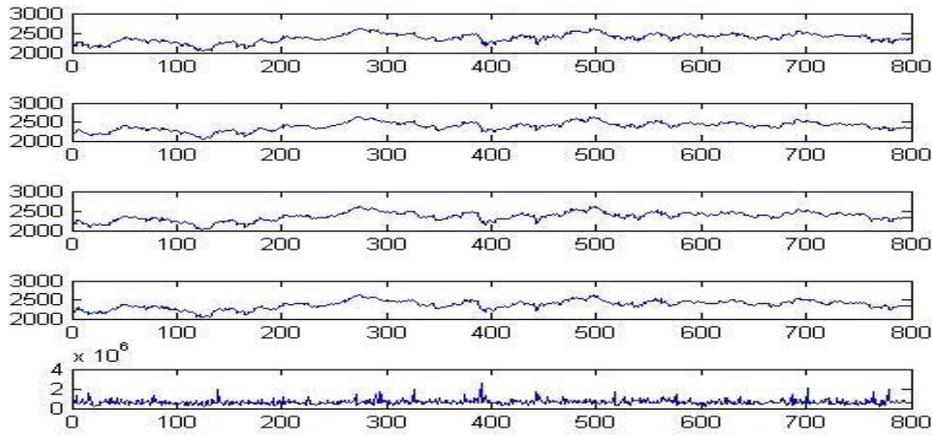
**النموذج الأول:** يتكوّن من  $N$  من الخلايا في طبقة الإدخال، خليتين في الطبقة المخفية، و خلية واحدة في طبقة الإخراج.

**النموذج الثاني:** يتكوّن من  $N$  من الخلايا في طبقة الإدخال،  $\frac{2(N+1)}{3}$  من الخلايا في الطبقة المخفية، و خلية واحدة في طبقة

الإخراج.

**النموذج الثالث:** يتكوّن من  $N$  من الخلايا في طبقة الإدخال،  $2N - 1$  من الخلايا في الطبقة المخفية، و خلية واحدة في طبقة الإخراج.

لتقييم أداء خوارزمية الانتشار العكسي (BP) وفقاً للنماذج المختلفة المذكورة سابقاً، تم جمع خمس سلاسل زمنية مالية خام تمثل على التوالي سعر الافتتاح اليومي، وأعلى سعر يومي، وأدنى سعر يومي، وسعر الإغلاق اليومي، وحجم التداول اليومي، وذلك خلال فترة أيام التداول في سوق دبي المالي (DFM) من 4 أبريل 2022 إلى 21 فبراير 2025، حيث تتكون كل سلسلة من 800 قراءة (الشكل 1). وقد استُخدمت أول 500 قراءة من إجمالي العينة كعينة تدريب، في حين استُخدمت ال 300 قراءة المتبقية كعينة اختبار.



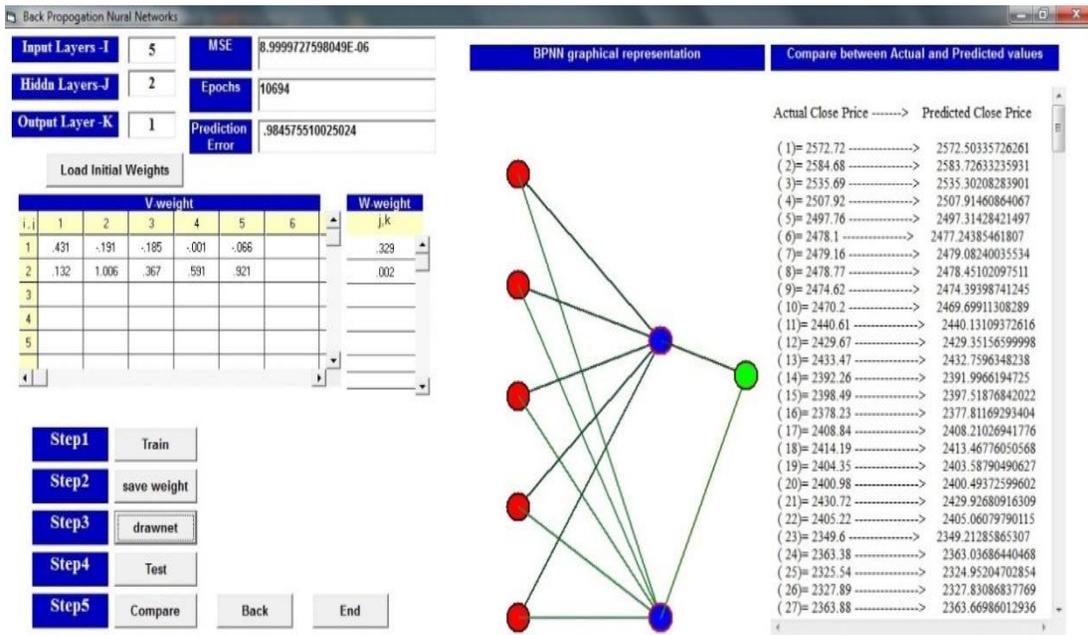
الشكل 1: خمس مجموعات بيانات خام لسلاسل زمنية مالية تغطي فترة التداول في سوق دبي المالي (DFM) من 4 أبريل 2022 إلى 21 فبراير 2025.

المصدر: اعداد شخصي

للتحقق من كفاءة أداء النموذج المقترح، تم استعمال المعايير الإحصائية الآتية: متوسط مربع الخطأ (MSE)، وخطأ التنبؤ (PE)، ومتوسط مربع الخطأ المعياري (NMSE)، ومتوسط الخطأ المطلق (MAE)، ومتوسط نسبة الخطأ المطلق (MAPE)، إضافةً إلى عدد الدورات التدريبية (Epochs). وتمثل المقاييس MSE، PE، NMSE، MAE و MAPE مقدار الانحراف بين القيم الفعلية والقيم المتنبأ بها، ويمكن اعتمادها لتقييم خطأ التنبؤ، في حين يعبر عدد الدورات التدريبية عن عدد التكرارات اللازمة للوصول إلى قيمة الخطأ المستهدفة. ويتم حساب كل من MSE، PE و عدد الدورات التدريبية (Epochs) تلقائياً بواسطة خوارزمية BP، بينما يتم حساب المعايير الأخرى يدوياً باستعمال برنامج Microsoft Excel 2020. وتشير القيم الأصغر لكل من MSE و NMSE و MAE و MAPE و PE و عدد العصور التدريبية إلى أفضل أداء لنموذج التنبؤ. وقد استُخدمت مجموعة البيانات السابقة في ثلاث تجارب مختلفة، تمثل كل تجربة منها نموذجاً واحداً، وذلك على النحو الآتي:

**التجربة الأولى:** تم تطبيق خوارزمية الانتشار العكسي (BP) باستعمال بنية النموذج الأول (Model I) على البيانات المذكورة أعلاه. يوضح الشكل (2) نتائج تطبيق خوارزمية BP على مجموعة البيانات باستعمال بنية النموذج الأول، حيث يبين أن البنية مكونة من ثلاث طبقات قد استُخدمت، تضم خمس خلايا في طبقة الإدخال، وخليتين في الطبقة المخفية، وخلية واحدة في طبقة الإخراج. كما يوضح الشكل أيضاً قيم متوسط مربع الخطأ (MSR)، وعدد الدورات (Epochs)، وخطأ التنبؤ (PE)، إلى جانب القيم الفعلية والمنتبئ بها لأسعار الإغلاق في مجموعة بيانات الاختبار الخاصة بالنموذج الأول.

الشكل 2: تطبيق خوارزمية الانتشار العكسي على البيانات في النموذج الاول



المصدر: اعداد شخصي

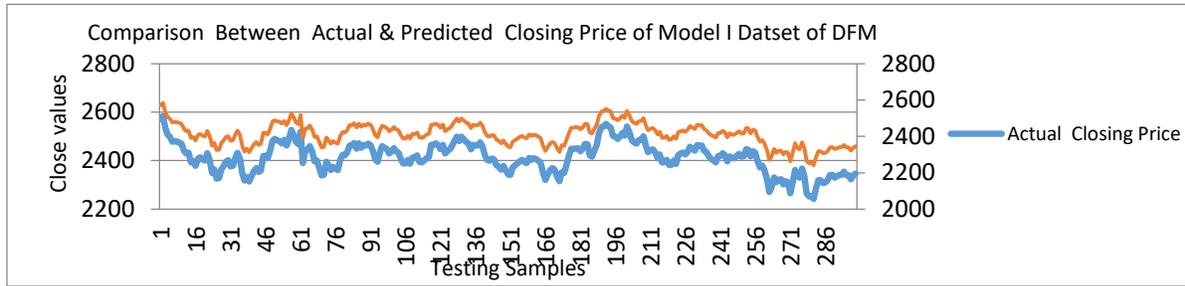
لتقييم أداء النموذج الأول، تم قياس مقدار الانحراف بين القيم الفعلية والمنتبئ بها لأسعار الإغلاق في مجموعة بيانات الاختبار باستعمال المعايير الإحصائية المذكورة أعلاه. يوضح الجدول (1) نتائج التنبؤ التي تبيّن المقارنة بين القيم الفعلية والمنتبئ بها لأسعار الإغلاق في مجموعة بيانات الاختبار الخاصة بالنموذج الأول.

الجدول (1): نتائج التنبؤ بأسعار الإغلاق لمجموعة بيانات الاختبار في النموذج الأول لسوق دبي المالي .

Model No	Epoch No	PE	MSE	MAE	NMSE	MAP E
Model I	10694	0.984 555	8.99997 E-06	0.518 952	9.283E -05	0.000 215

المصدر: اعداد شخصي

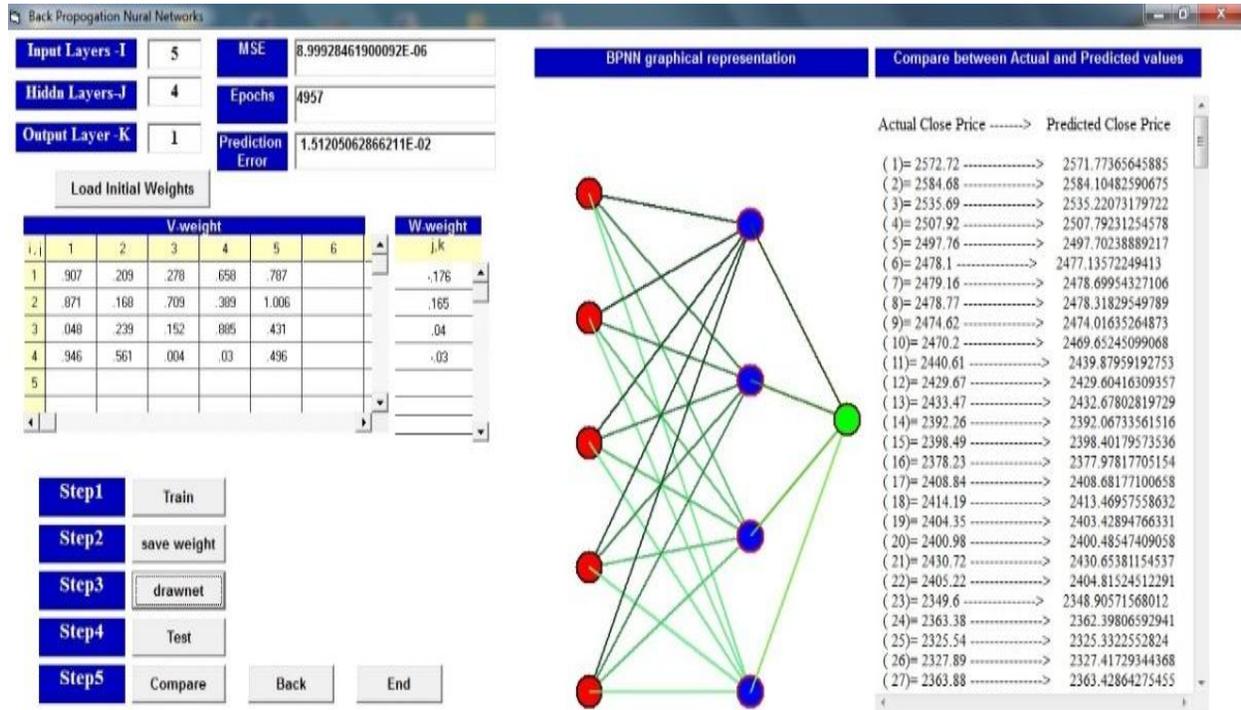
يوضح الشكل (3) المقارنة بين أسعار الإغلاق الفعلية والمتنبأ بها لمجموعة بيانات الاختبار في النموذج الأول لسوق دبي المالي خلال الفترة الممتدة من 4 نيسان/أبريل 2022 إلى 21 شباط/فبراير 2025. ويبيّن الشكل أن أسعار الإغلاق المتنبأ بها تقترب، إلى حدّ ما، من أسعار الإغلاق الفعلية.



الشكل (3): مقارنة بين أسعار الإغلاق الفعلية والمتنبأ بها لمجموعة بيانات الاختبار للنموذج الأول في سوق دبي المالي.

المصدر: اعداد شخصي

**التجربة الثانية:** تم تطبيق الإجراء نفسه المستخدم في التجربة الأولى على مجموعة بيانات النموذج الثاني وتم الحصول على النتائج المبينة في الشكل (4) والجدول (2) والشكل (5) على التوالي. وقد استُخدمت بنية مكونة من خمس خلايا في طبقة الإدخال، وأربع خلايا في الطبقة المخفية، وخلية واحدة في طبقة الإخراج.



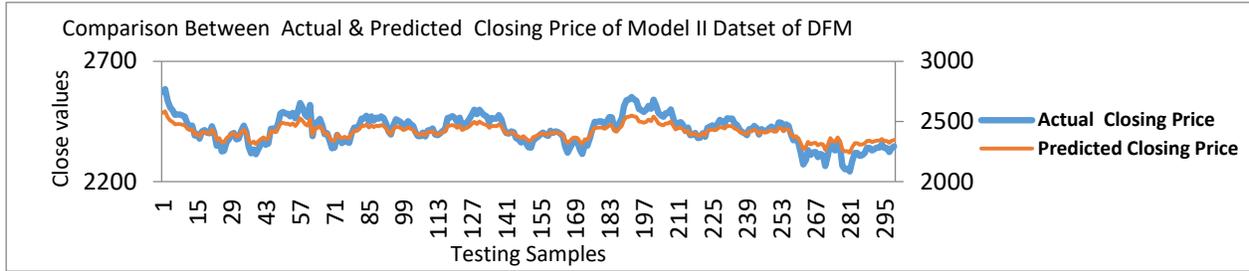
الشكل (4): خطوات تطبيق خوارزمية الانتشار العكسي على مجموعة بيانات النموذج الثاني.

المصدر: اعداد شخصي

الجدول (2): نتائج التنبؤ بأسعار الإغلاق لمجموعة بيانات الاختبار في النموذج الثاني.

Model No	Epoch No	PE	MSE	MAE	NMS E	MAP E
Model II	4957	1.512051	8.999285E-06	0.417958	6.63E-05	0.000173

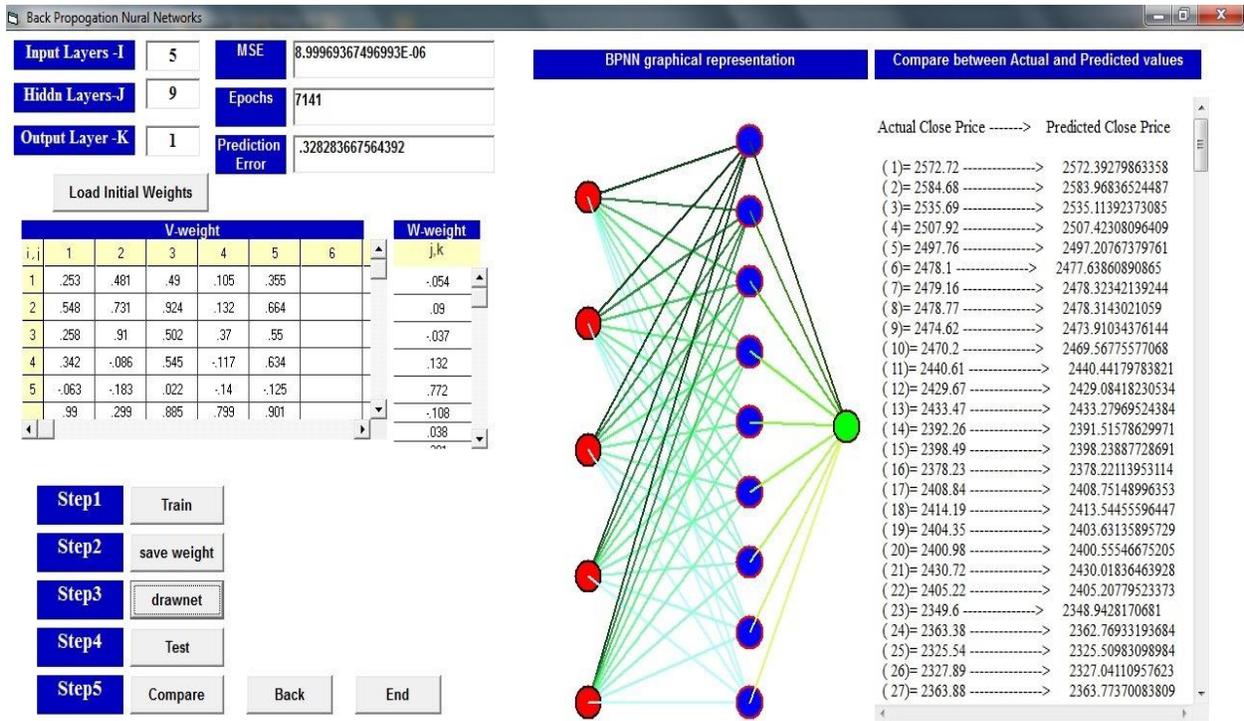
المصدر: اعداد شخصي



الشكل (5): مقارنة بين أسعار الإغلاق الفعلية والمنتبأ بها لمجموعة بيانات الاختبار في النموذج الثاني لسوق دبي المالي.

المصدر: اعداد شخصي

التجربة الثالثة: تم تطبيق بنية خوارزمية الانتشار العكسي باستعمال البيانات المذكورة أعلاه، حيث تتكوّن هذه البنية من خمس خلايا في طبقة الإدخال، وتسع خلايا في الطبقة المخفية، وخلية واحدة في طبقة الإخراج. نتائج هذه التجربة موضحة في الشكل (6) والجدول (3) والشكل (7) على التوالي.



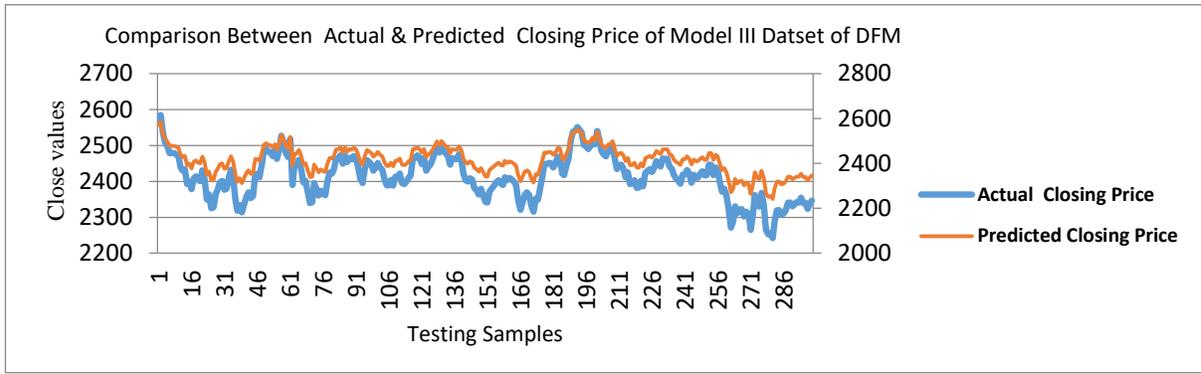
الشكل (6): خطوات تطبيق خوارزمية الانتشار العكسي على مجموعة البيانات في النموذج الثالث.

المصدر: اعداد شخصي

الجدول (3): نتائج التنبؤ بأسعار الإغلاق لمجموعة بيانات الاختبار في النموذج الثالث.

Model No	Epoch No	PE	MSE	MAE	NMSE	MAP E
Model III	7141	0.3282 84	8.999694 E-05	0.489 827	8.33E- 05	0.000 203

المصدر: اعداد شخصي



الشكل (7): مقارنة بين أسعار الإغلاق الفعلية والمتنبأ بها لمجموعة بيانات الاختبار في النموذج الثالث لسوق دبي المالي.

المصدر: اعداد شخصي

يوضح الجدول (4) المقارنة الشاملة بين التجارب الثلاث المختلفة المذكورة أعلاه وفقاً لتطبيق خوارزمية الانتشار العكسي والمعايير الإحصائية المعتمدة؛ حيث يعرض النتائج الإجمالية لهذه التجارب الثلاثة.

الجدول (4): النتائج الإجمالية للتنبؤ بأسعار الإغلاق خلال المدة الممتدة من 4 نيسان/أبريل 2022 إلى 21 شباط/فبراير 2025 لسوق دبي المالي.

Criteria	Model I	Model II	Model III
Epoch No	10694	4957	7141
PE	0.984555	0.015120	0.328284
MSE	8.99997E-06	8.999285E-06	8.999694E-05

MAE	0.518952	0.417958	0.489827
NMSE	9.283E-05	6.63E-05	8.33E-05
MAPE	0.000215	0.000173	0.000203

المصدر: اعداد شخصي

استناداً إلى النتائج الموضحة في الجدول (4)، يتضح أن النموذج الثاني يحقق قيمة أقل للأخطاء وعدداً أقل من دورات المعالجة مقارنةً بالنماذج الأخرى، مما يدل على أن النموذج الثاني يتمتع بأفضل أداء ويُعدّ الأكثر دقة في التنبؤ والاقصر من ناحية التنفيذ بحركة سوق المال.

#### الاستنتاجات والتوصيات

مع تسارع التحول الرقمي على مستوى العالم، أصبح الذكاء الاصطناعي، ولا سيما الشبكات العصبية الاصطناعية، عنصراً أساسياً في التنبؤ بالأسواق المالية وحماية البيانات من الهجمات السيبرانية. هدفت هذه الدراسة إلى استكشاف الدور المحتمل للشبكات العصبية الاصطناعية في تعزيز دقة التنبؤات المالية وتقوية إجراءات الأمن السيبراني في مواجهة الهجمات المتطورة. ويؤدي دعم عملية اتخاذ القرار دوراً محورياً في الجانبين العملي والنظري للاستثمار، ولا سيما في ظل التقدم المتسارع في أتمتة التداول في أسواق رأس المال. ويُعدّ التنبؤ بحركة سوق الأسهم من أكبر التحديات التي تواجه المجتمع العلمي، إذ تُظهر الشبكات العصبية الاصطناعية كفاءة أعلى في هذا المجال مقارنةً بالتقنيات التقليدية الأخرى. كما تُعدّ خوارزمية الانتشار العكسي من أكثر خوارزميات تدريب الشبكات العصبية شيوعاً في التنبؤ بالسلاسل الزمنية المالية، إلا أن من أبرز التحديات المرتبطة باستعمالها هو تحديد العدد الأمثل للطبقات المخفية وعدد الخلايا في كل طبقة مخفية.

في هذه الدراسة، تم اعتماد سوق دبي المالي مثلاً توضيحياً لتقييم أداء ثلاثة نماذج مختلفة، حيث جرى استعمال خوارزمية الانتشار العكسي ذات التغذية الأمامية والمكوّنة من ثلاث طبقات. واستناداً إلى النتائج التجريبية، يمكن استخلاص ما يأتي:

- لا توجد ضرورة لاستعمال أكثر من طبقة مخفية واحدة في التنبؤ بالسلاسل الزمنية المالية.
- إن استعمال عدد قليل جداً من الخلايا في الطبقة المخفية يؤدي إلى مشكلات نقص التكيّف.
- إن استعمال عدد كبير جداً من الخلايا في الطبقة المخفية قد يسبب عدة مشكلات، مثل فرط التكيّف وزيادة الزمن اللازم لتدريب الشبكة، وغيرها.
- إن البنية الطوبولوجية لخوارزمية الانتشار العكسي ذات التغذية الأمامية والمكوّنة من ثلاث طبقات، والتي تضم  $N$  خلية في طبقة الإدخال،  $\frac{2(N+1)}{3}$  خلية في الطبقة المخفية، وخلية واحدة في طبقة الإخراج، تحقق أخطاء أقل ودقة أعلى في التنبؤ بسوق الأسهم، وبالتالي تتفوق على نماذج التنبؤ ذات البنى الأخرى.

## المصادر

- السامرائي، باسم محمد. (2012). الأسواق المالية: المفاهيم والآليات. عمان: دار اليازوري العلمية.
- العلي، أحمد محمود. (2018). إدارة المخاطر المالية والتنبؤ بالأسواق. عمان: دار المسيرة.
- النجار، فؤاد علي. (2016). السلاسل الزمنية وتطبيقاتها في العلوم المالية. عمان: دار صفاء للنشر.
- الهيتي، خليل إبراهيم. (2010). إدارة الاستثمارات والأسواق المالية. عمان: دار المسيرة للنشر والتوزيع.
- شحاتة، حسين حسين. (2015). الاستثمار في الأوراق المالية وإدارة المحافظ. الإسكندرية: الدار الجامعية.
- عبد المجيد، محمد عبد الله. (2014). التحليل المالي واتخاذ القرارات الاستثمارية. القاهرة: دار الفكر الجامعي.
- Kao L. J., C. C. (2012). Integration of nonlinear independent component analysis and support vector regression for stock price forecasting. *Neurocomputing*.
- Lee, C. J. (2009). Financial time series forecasting using independent component analysis and support vector regression. *Decision Support Systems*, 47 (2), 115-125.
- Lu, C. J. (2010). Integrating independent component analysis-based denoising scheme with neural network for stock price prediction. *Expert Systems with Applications*, 37(10), 7056-7064.
- Liu H., W. J. (2011). Integrating Independent Component Analysis and Principal Component Analysis with Neural Network to Predict Chinese Stock Market. *Vol. 2011*, 15.