

# التنبؤ بأداء الأسواق المالية الناشئة باستخدام الشبكات العصبية NARX-NAR

غسان ساكت\*، أحمد تميم مارديني\*\*

\*أستاذ في قسم الإحصاء ونظم المعلومات، كلية الاقتصاد، جامعة حلب

\*\* طالب دراسات عليا (دكتوراه)، قسم الإحصاء ونظم المعلومات، كلية الاقتصاد، جامعة حلب

## المخلص

إن من أكبر التحديات التي تواجه المستثمرين على المستوى الدولي هي قياس أداء عملياتهم الاستثمارية ضمن هيكلية محفظة استثمارية دولية من خلال التنبؤ بالأداء المستقبلي للمؤشر المعياري لها. قمنا في هذا البحث بدراسة وتحليل الأسعار المكونة للمؤشر الدولي للأسواق المالية الناشئة MSCI Emerging (Open-Max-Min-Close) كسلسلة زمنية بناءً على اختبار عدة طرق لنمذجة سعر الإغلاق بالاعتماد على الشبكات العصبية الاصطناعية للانحدار الذاتي غير الخطي NAR وNARX والمقارنة فيما بينها، وذلك من أجل إيجاد نموذج عصبي ذو دقة عالية قادراً على الاستجابة السريعة للتغيرات السعرية بشكل ديناميكي من خلال التنبؤ بسعر الإغلاق المستقبلي للمؤشر العام والذي يمثل محفظة السوق المعيارية لدعم عملية اتخاذ قرارات التداول في الأسواق الناشئة. وتوصلت الدراسة إلى إمكانية بناء نموذج للتنبؤ بالسعر المستقبلي للمؤشر العام للأسواق المالية الناشئة بالاعتماد على عدة متغيرات تتعلق بالأسعار المكونة له كسلسلة زمنية باستخدام شبكة NARX العصبية حيث كانت النتائج أدق من نتائج النموذج الذي تم بناؤه بالاعتماد على متغير وحيد هو سعر الإغلاق (Close) كسلسلة زمنية باستخدام شبكة NAR العصبية، حيث تم بناء النماذج بالاعتماد على برنامج Matlab وتم التأكد من فعالية النماذج وقابليتها للتعميم بالاعتماد على متوسط مربع الخطأ MSE بين القيم الفعلية والمتوقعة لسعر الإغلاق، إذ بلغت قيمة MSE لنموذج شبكة NARX 0.00012653 وقيمة MSE لنموذج شبكة NAR 0.00015258.

الكلمات المفتاحية: الأسواق المالية الناشئة، الشبكات العصبية الاصطناعية، شبكة NAR-NARX العصبية.

## Predicting The Performance of Emerging Financial Markets Using NARX-NAR Neural Network

Ghassan Saket\*, Ahmad Tamim mardini\*\*

\*Prof. in Dept. of Statistics and Information Systems, Faculty of Economic, University of Aleppo

\*\*Postgraduate student (PhD), Dept. of Statistics and Information Systems, Faculty of Economic,  
University of Aleppo

### Abstract

One of the biggest challenges facing investors at the international level is measuring the performance of their investment operations within the structure of an international investment portfolio by predicting the future performance of its standard index.

In this research, we studied and analyzed the component prices of the MSCI Emerging International Index (Open-Max-Min-Close) as a time series based on testing several methods for modeling the closing price and comparing them with each other based on artificial neural networks for non-linear autoregressive NAR and NARX. In order to create a highly accurate neural model capable of responding quickly to price changes dynamically by predicting the future closing price of the general index, which represents the standard market portfolio, to support the process of making trading decisions in emerging markets.

The study concluded that it is possible to build a model to predict the future price of the general index for emerging financial markets based on several variables related to its component prices as a time series using the NARX neural network, with more accurate results than the model that was built based on a single variable, which is the closing price, as a time series using a network. Neural NAR, where the models were built based on the Matlab program, and the models' effectiveness and generalizability were confirmed based on the mean square error (MSE) between the actual and expected values of the closing price, as the MSE value for the NARX network model was 0.00012653 and the MSE value for the NAR network model was 0.00015258.

Keywords: Emerging Financial Markets, Artificial Neural Networks, NARX and NAR Neural Network.

## 1. المقدمة:

إن عملية توظيف أدوات الذكاء الصناعي في العديد من المجالات الاقتصادية والادارية وخاصةً في الأسواق المالية وربطها بتكنولوجيا المعلومات ساهمت في تطوير أداء العمليات الاستثمارية على المستوى الدولي، وذلك من خلال بناء عدة نماذج ذكية قابلة للتطبيق العملي على جميع مؤشرات الأسواق المالية بهدف دعم عملية اتخاذ القرار الاستثماري في الوقت المناسب.

لذلك سيتم في هذا البحث تسليط الضوء على الأسواق المالية الناشئة لأهميتها الاستثمارية بين الأسواق المالية الدولية ومجالاً واسعاً للبحث عن أفضل الأساليب العلمية للتنبؤ باستخدام أدوات الذكاء الاصطناعي للوصول إلى قاعدة علمية تصبح ركيزة للعمليات الاستثمارية الدولية، كما سيتم توضيح مفهوم الشبكات العصبية الاصطناعية التي تعتبر من أهم طرق الذكاء الصناعي والتي أثبتت فعاليتها في حل العديد من القضايا المالية المعقدة، ثم دراسة حالة تطبيقية على المؤشر العام للأسواق الناشئة MSCI Emerging بالاعتماد على بيانات السلسلة الزمنية للأسعار المكونة له (Open, Max, Min, Close) للتنبؤ بسعر الإغلاق المستقبلي بمستوى زمني شهري اعتماداً على بيانات تاريخية يومية.

سوف نستخدم في هذا البحث شبكة الـ NARX وشبكة الـ NAR ذات الطبيعة الديناميكية في تحليل السلاسل الزمنية، وذلك لبناء نموذج قادراً على الاستجابة السريعة للتغيرات الآتية لأسعار إغلاق مؤشر الأسواق الناشئة، بحيث يمكننا الاعتماد على النموذج في الأسواق الناشئة كأساس علمي وفعال لدعم عملية اتخاذ القرار الاستثماري السليم في تلك الأسواق، وأخيراً سيتم عرض أهم النتائج والتوصيات التي توصل إليها البحث.

## 2. مشكلة البحث:

تعد عملية التنبؤ بأسعار المؤشر العام للأسواق المالية الناشئة من أكثر العمليات صعوبةً وتعقيداً لكثرة العوامل التي تؤثر على تقلبات أسعاره كونه يعكس أداء جميع الأسواق المالية الناشئة وخاصةً إذا كانت عملية التنبؤ بمستوى زمني شهري بناءً على بيانات يومية، إضافةً إلى أن حركة أسعار المؤشر التاريخية هي حركة عشوائية لا تتبع لتوزيع معين في أغلب الأحيان لذلك يصعب على الأساليب الاحصائية تحديد مدى انحراف القيم المتنبئ عن الواقع الفعلي بشكل ديناميكي مما يجعل عملية التنبؤ صعبة وغير دقيقة، ومن هنا يمكن صياغة التساؤلات الآتية:

- ماهي الأساليب العلمية والتقنية التي تساعد على التنبؤ بأداء مؤشر الأسواق المالية الناشئة MSCI Emerging؟

- هل يمكن التنبؤ بسعر الإغلاق المستقبلي للمؤشر العام بمستوى زمني شهري بناءً بيانات يومية للأسعار المكونة له (Open-Max-Min-Close) كسلسلة زمنية؟

- هل يمكن استخدام الشبكات العصبية الاصطناعية الديناميكية في تحليل السلاسل الزمنية من خلال نموذج عصبوني يحاكي البيئة المعقدة لتقلبات أسعار المؤشر اليومية من أجل التنبؤ بسعر الإغلاق المستقبلي بدقة؟

### 3. أهداف البحث:

يهدف البحث إلى:

- بناء نموذج عصبي لدعم العمليات الاستثمارية على المستوى الدولي في الأسواق المالية الناشئة باستخدام شبكة NARX و NAR العصبية بالاعتماد على البيانات التاريخية للمؤشر العام كسلسلة زمنية للتنبؤ بسعر الإغلاق المستقبلي.

- تقييم مدى دقة نتائج النموذج وصلته بالواقع الفعلي ومدى ملائمة النموذج مع تقلبات أسعاره.

### 4. أهمية البحث:

تكمن أهمية البحث في النقاط التالية:

- استخدام النموذج المقترح للتنبؤ الشهري بسعر الإغلاق المستقبلي للمؤشر العام للأسواق المالية الناشئة من أجل زيادة مستوى التأكد لدى المستثمرين عند أداء عملياتهم الاستثمارية في تلك الأسواق.

- تقديم اقتراحات عملية للمستثمرين بناءً على تقييم واقع الاستثمار في الأسواق المالية الناشئة بهدف تقليل نسبة المخاطرة عند بناء محافظهم الدولية في الأسواق الناشئة قدر الإمكان من خلال نموذج عصبي يحقق دقة في عملية التنبؤ بسعر الإغلاق المستقبلي للمؤشر.

### 5. منهجية البحث:

يعتمد البحث على المنهج التحليلي، حيث سيتم تحليل مجموعة من البيانات التاريخية للأسعار المكونة للمؤشر وهي (Open-Max-Min-Close) كسلسلة زمنية ونمذجة دالة الهدف بالاعتماد على عدة مؤشرات للتحليل الفني باستخدام برنامج Matlab في بناء عدة نماذج للتنبؤ بسعر الإغلاق المستقبلي (Close) عن طريق شبكتي NARX و NAR واختيار النموذج الذي يحقق أدنى نسبة لمتوسط مربع الخطأ كمقياس لانحراف القيم المتوقعة عن القيم الملحوظة للأسعار التاريخية، فكلما كانت القيم أقرب للصفر كان

النموذج أدق.

## 6. الدراسات السابقة:

### 1.6. دراسة Shamsaliniya وآخرون [1]، 2024

بحث بعنوان: التنبؤ بمرنة أسعار الأسهم باستخدام شبكة NAR-NARX للشركات المدرجة في بورصة طهران.

هدفت الدراسة إلى التنبؤ بمتوسط مرونة أسعار الأسهم المدرجة في بورصة طهران من الفترة 2009 حتى 2019 بناءً على متغير وحيد وهو متوسط معامل مرونة السعر باستخدام الشبكة العصبونية NAR، أما شبكة NARX بناءً على متغير مستقل هو سعر الإغلاق والمتغير التابع متوسط معامل مرونة السعر بهدف بناء نموذجين والمقارنة فيما بينهما مع نماذج الأساليب الإحصائية AR-ARMAX اعتماداً على مقياس متوسط مربع الخطاء MSE، حيث شملت عينة الدراسة البيانات التاريخية لأسهم الشركات بمدى زمني يومي، وأهم النتائج التي توصلت إليها الدراسة أن نموذج NARX كان ذات نتائج أدق من نموذج NAR ونماذج الأساليب الإحصائية للتنبؤ بمتوسط مرونة السعر المستقبلي حيث بلغت قيمة MSE لنموذج مؤشر بورصة طهران لشبكة NAR 0.35 و 0.12 لخوارزمية NARX ونموذج AR 2.25 و ARMAX 1.98، وبالتالي إمكانية الاعتماد على شبكة NARX العصبونية في عملية التنبؤ بمتوسط مرونة الأسعار في الأسواق المالية.

### 2.6. دراسة Sagaceta وآخرون [2]، 2024

بحث بعنوان: نهج ذكي للتنبؤ بتحركات سوق الأسهم في الأسواق الناشئة باستخدام المؤشرات الفنية والشبكات العصبية.

هدفت الدراسة إلى التنبؤ باتجاه حركة الصناديق الاستثمارية الدولية المتداولة في الأسواق الناشئة بمستوى زمني يومي بناءً على تحديد أبرز مؤشرات التحليل الفني والتي بلغت 13 مؤشر كمتغيرات مستقلة ذات التأثير الأعلى على عملية تحليل السلاسل الزمنية باستخدام شبكة التعلم MLP متعددة الطبقات التي تأخذ عدة متغيرات مستقلة كصفات تصنيفية، وشملت عينة الدراسة البيانات التاريخية لأسعار الصناديق من تاريخ 2009/12/12 حتى 2020/1/1، وخلصت الدراسة أن النموذج المبني باستخدام شبكة MLP ذو دقة تنبؤية عالية، حيث بلغت نسبة التصنيف الصحيح 80.27% وبالتالي إمكانية الاعتماد على النموذج للتنبؤ باتجاه حركة أسعار الإغلاق للصناديق الدولية بالاعتماد على مؤشرات التحليل الفني.

### 3.6. دراسة Sonkavde وآخرون [3]، 2023

بحث بعنوان: التنبؤ بأسعار سوق الأسهم باستخدام نماذج التعلم الآلي والتعلم العميق: مراجعة

منهجية وتحليل الأداء ومناقشة الآثار المترتبة.

هدفت الدراسة للتنبؤ بأسعار سهمي TAINIWALCHM و AGROPHO بناءً على الأسعار المكون للسهمين (Open-Max-Min-Close) كمتغيرات الدراسة وإجراء تحليل مقارن مع نماذج التعلم الآلي والتعلم العميق وهي (MLPR-KNN-SVM-Random Forest-LSTM-GX Boost)، وذلك من خلال دمج ثلاثة خوارزميات (LSTM+ Random Forest+ GX Boost) في نموذج تنبؤي تصنيفي واحد بهدف تحسين نسبة التنبؤ مقارنةً مع النسب التنبؤية لكل خوارزمية على حدة، حيث شملت عينة الدراسة البيانات التاريخية من عام 2014 حتى 2023 بمستوى زمني يومي، وخلصت الدراسة إلى أن النموذج المدمج حقق أعلى دقة تنبؤية بلغت قيمة RMSE جذر متوسط مربع الخطأ له 2.02 مقارنةً مع نموذج LSTM 5.62 و KNN 4.42 و SVM 4.52 و MLPR 2.58 و Random Forest 87.88 و XG Boost 2.06.

إن أهم ما يميز هذه الدراسة عن الدراسات السابقة هي تقديم نموذج للتنبؤ بسعر الإغلاق المستقبلي لمؤشر العام للأسواق المالية الناشئة، وذلك بإدخال سلسلة الأسعار التاريخية لمكونات سعر إغلاق المؤشر (Open-Max-Min-Close) كمتغيرات مستقلة بمستوى زمني يومي للتنبؤ بسعر الإغلاق بمستوى زمني شهر وفق نمذجة متعددة لمؤشرات التحليل الفني تختلف عن باقي الأبحاث، بحيث تصبح عملية التنبؤ أكثر ديناميكية مع حركة الأسعار اليومية للمؤشر.

## 7. الأسواق المالية الناشئة Emerging Financial Market:

### 1.7. مفهوم الأسواق المالية الناشئة:

كان أول استخدام للفظ للأسواق المالية الناشئة من قبل خبراء مؤسسات التمويل الدولية (IFC) أثناء دراساتهم لنمو الأسواق المالية في مناطق العالم الأقل تقدماً، فقد اعتمدت هذه المؤسسات على عدة معايير اقتصادية وكمية وجغرافية في تصنيفاتها للأسواق المالية لتطلق مصطلح "الناشئة" على الأسواق التي حجمها أو نشاطها في نمو متزايد[4]، الأمر الذي ساعد على جذب اهتمام العديد من المؤسسات والشركات المالية لتوفر أدوات تدعم القرار الاستثماري على المستوى العالمي عبر تصنيف أسواق الأوراق المالية وتقييم أدائها، تعتبر مؤسسة مورغان ستانلي Morgan Stanley Capital International (MSCI) للأبحاث الاستثمارية من أهم مؤسسات تحليل المالية التي صنفت الأسواق المالية على نطاق دولي حيث اشتهرت هذه المؤسسة بمؤشراتها القياسية كمييار دولي للحكم على أداء الأسواق المالية من خلال تغطية 35000 ورقة مالية عالمياً

بمختلف أنواعها (أسهم شركات صغيرة ومتوسطة وكبيرة) والتي يمكن للأسواق المالية العالمية استخدامها كمعيار للحكم على أدائها [5].

## 2.7. معايير تصنيف الأسواق المالية الدولية:

تم تصنيف الأسواق المالية لمعظم دول العالم ضمن ثلاثة تصنيفات عالمية وهي أسواق مالية متقدمة وناشئة وحدودية، حيث أنه لكل تصنيف من التصنيفات الثلاثة السابقة مؤشر يعكس نشاطها ويعمل كمعيار لتقييم وقياس أداء عوائد المحافظ الدولية وصناديق الاستثمار العالمية ETFs [6]. عملية تصنيف الأسواق بحسب MSCI تتم بناءً على ثلاثة معايير أساسية هي التنمية الاقتصادية وحجم وسهولة تلك الأسواق وإمكانية الوصول إليها وهي كما يلي [7]:

- استدامة التنمية الاقتصادية أو النمو الاقتصادي.
- متطلبات الحجم والسيولة للشركات التي تستوفي معايير المؤشر القياسي.
- معايير الوصول للسوق كالانفتاح على الملكية الأجنبية وسهولة التدفقات المالية.

## 8. الشبكات العصبية الاصطناعية (ANN) Artificial Neural Network:

### 1.8. مفهوم الشبكات العصبية الاصطناعية:

تعتبر الشبكات العصبية الاصطناعية من أكثر تقنيات الذكاء الاصطناعي استخداماً في الدراسات الاقتصادية والاحصائية وسميت بهذا الاسم كونها مؤلفة من وحدات اتصال داخلية ويرمز لها اختصاراً بـ ANN أي Artificial Neural Network [8]، حيث عرّف العالم Nilsson الشبكات العصبية على أنها نظام حسابي مؤلف من مجموعة وحدات للمعالجة والمتراطة مع بعضها البعض بشكل متوازي لمعالجة البيانات الداخلة إليها، وبذلك تعتبر نظام لمعالجة البيانات مكوّن من مجموعة وحدات للمعالجة الحسابية تسمى عقد أو عصبونات Neurons مترابطة فيما بينها بمجموعة من الوصلات تسمى الأوزان Weights والتي تعد الوسيلة الأساسية لذاكرة الشبكة، بهذا الشكل تصبح للشبكة العصبية الاصطناعية القدرة على التعلم الذاتي وتمييز الأنماط من خلال عمليات التدريب وذلك بهدف التحليل أو التصنيف أو التنبؤ [9].

### 2.8. مفهوم شبكة NARX (Nonlinear Autoregressive Exogenous):

تعد شبكة NARX للانحدار الذاتي غير الخطي بمدخلات خارجية إحدى أنواع الشبكات لنمذجة الأنظمة الديناميكية غير الخطية والتنبؤ بالسلاسل الزمنية بتأخر زمني Delay Time والتي تصنف على أساس شبكات عصبية متعددة الطبقات ذات التغذية الأمامية Feedforward مع انتشار عكسي للخطأ،

حيث يعتمد نموذج NARX على نموذج ARX الخطي لنمذجة السلاسل الزمنية والذي يعرف من المعادلة التالية [10]:

$$Y(t) = f[Y(t-1), Y(t-2), \dots, Y(t-d), X(t-1), X(t-2), \dots, X(t-d)]$$

حيث:

$f$ : هي دالة غير خطية Nonlinear Function.

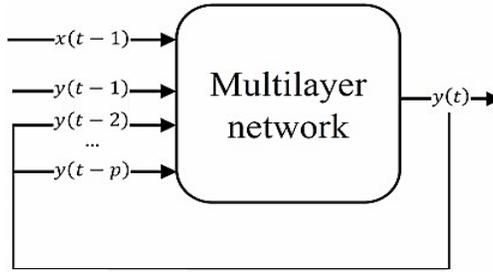
$Y(t)$ : هي الناتج المتوقع من شبكة NARX عند الزمن  $t$ .

$d$ : تمثل زمن التأخير Delay Time للمدخلات والمخرجات ( $y - x$ ) والتي تبدأ من مشاهدتين [0:1-1:2] مع إمكانية تغيير عدد المشاهدات بحسب بيانات الدراسة.

$Y(t-1), Y(t-2), \dots, Y(t-d)$ : هي القيم الحقيقية السابقة لقيم خرج الشبكة.

$X(t-1), X(t-2), \dots, X(t-d)$ : هي قيم مدخلات الشبكة.

والشكل رقم (1) يوضح البنية العامة لشبكة NARX العصبية وهي كما يلي:



الشكل رقم (1) يوضح البنية العامة لشبكة NARX العصبية.

Source: Ruiz, L. G. B., et al., 2016., **An application of non-linear autoregressive neural networks to predict energy consumption in public buildings.** Energies.

لوحظ من الشكل رقم (1) أن بنية شبكة NARX متعددة الطبقات مكونة من ثلاثة طبقات: طبقة المدخلات والطبقة المخفية وطبقة المخرجات، حيث ترتبط الطبقات فيما بينها ارتباطاً أمامياً Feedforward والمخرجات الناتجة عن طبقة Output Layer هي مدخلات للطبقة المخفية كتغذية عكسية Feedback لتصحيح الأخطاء بالاعتماد على إحدى خوارزميات الانتشار الخلفي Backpropagation والتي تساعد على سرعة استقرار الشبكة والوصول إلى أفضل نموذج يتحقق عنده أقل قيمة لمتوسط مربع الخطأ MSE بين القيم المتوقعة والقيم الفعلية [11].

تعد شبكة NAR العصبية للانحدار الذاتي غير الخطي من الشبكات الديناميكية متعددة الطبقات

ذات التغذية الأمامية للتنبؤ بالسلاسل الزمنية بمدخل وحيد والتي تعرف بالصيغة الرياضية التالية [12]:

$$Y_t = \alpha_0 + \sum_{j=1}^K \alpha_j \phi \left( \sum_{i=1}^{\alpha} \beta_{ij} Y_{t-1} + \beta_{0j} \right) + \varepsilon_t$$

حيث:

$Y_t$ : الناتج المتوقع للشبكة في اللحظة  $t$ .

$Y_{t-1}$ : تمثل تأخيرات التغذية الراجعة بحسب زمن التأخير  $d$ .

$\alpha$ : تمثل عدد مدخلات الشبكة.

$K$ : عدد الطبقات المخفية

$\Phi$ : دالة التنشيط.

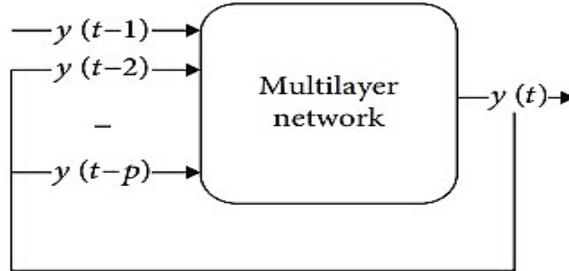
$\alpha_j$ : هي وزن الاتصال بين الوحدة المخفية  $j$  ووحدة الإخراج.

$\beta_{0j}, \alpha_0$ : تمثل الثوابت المتدفقة على التوالي إلى الوحدة المخفية  $j$  ووحدة الإخراج.

$\beta_{ij}$ : تمثل المعلمة المقابلة لوزن الاتصال بين وحدة الإدخال  $i$  والوحدة المخفية  $j$ .

$\varepsilon_t$ : يشير إلى خطأ تقريب السلسلة  $y$  عند اللحظة  $t$ .

والشكل رقم (2) يوضح بنية أو معمارية شبكة NAR وهو كما يلي:



الشكل رقم (2) يوضح بنية شبكة NAR العصبية.

Source: Benrhmach, G., et al., 2020., **Nonlinear Autoregressive Neural Network and Extended Kalman Filters for Prediction of Financial Time Series**. Journal of Applied Mathematics.

من الشكل رقم (2) لوحظ التشابه بين بنية شبكة NAR وبنية شبكة NARX، إلا أن شبكة NARX تتميز بمدخلات خارجية وهذا يعني أن النموذج يربط القيمة الحالية للسلسلة الزمنية بكل من القيم السابقة لنفس السلسلة والقيم الحالية والسابقة للسلسلة الخارجية فكلما كانت الارتباطات المتقاطعة بين المدخلات والمخرجات كبيرة فيكون أداء الشبكة أفضل [13].

## 9. بناء النموذج:

إن عملية بناء نموذج للشبكات العصبية الاصطناعية تتبع لعدة خطوات أساسية والتي تعبر عن الهيكل العام للنموذج من خلال تسلسل عدة عمليات للمعالجة وفق الترتيب التالي:

1. تهيئة وتجهيز البيانات وهيكلتها.
2. اختيار بنية ومعمارية الشبكة العصبونية.
3. تدريب الشبكة العصبونية.
4. الاختبار والتحقق من صحة نتائج الشبكة.
5. التنبؤ وتقييم النتائج.

### 11.9. تهيئة وتجهيز البيانات وهيكلتها لشبكة الـ NAR

إن البيانات التاريخية لمؤشر الأسواق المالية الناشئة MSCI EM تمثل الأسعار المكونة له إذ كل سجل يعبر عن (Open-Max-Min-Close) بمستوى زمني يومي، حيث بلغت عدد السجلات الخام لمؤشر الأسواق المالية الناشئة 2376 سجلاً تبدأ من تاريخ 2015/01/01م حتى تاريخ 2023/12/31م والتي تم الحصول عليها من منصة Investing، أما بالنسبة لتجهيز البيانات الخاص لمرحلة التدريب والاختبار والتحقق من الصحة لتتناسب مع شبكة NAR كون هذه الشبكة تأخذ متغير واحد كسلسلة زمنية للتنبؤ بالقيم المستقبلية، بحيث تصبح قاعدة البيانات مكونة من متغير مسنقل Input وهو الزمن Time ومتغير تابع دالة الهدف Target وهو سعر الإغلاق المستقبلي الذي تم نمذجته بالاعتماد على مؤشرات التحليل الفني. والجدول رقم (1) يوضح آلية نمذجة دالة الهدف (متغير التابع) لسعر الإغلاق وفق مؤشرات التحليل الفني.

الجدول رقم (1) آلية نمذجة دالة الهدف (متغير التابع) لسعر الإغلاق وفق مؤشرات التحليل الفني.

Formula	Parameters	Index
$SMA_N = \frac{(C_T + C_{T+1} + C_{T+2} + \dots + C_{T+N})}{N}$	22	SMA
$WMA_N = \frac{(C_T * 1) + (C_{T+1} * 2) + (C_{T+2} * 3) + \dots + (C_{T+N} * 22)}{N}$		WMA
$EMA_N = (C_T * a) + (EMA_{T+1} * (a - 1))$ $a=2/(1+N)$		EMA
$\Delta C = \frac{(C_{T+22} - C_T)}{C_T}$		$\Delta C$

المصدر: من إعداد الباحث.

لوحظ من الجدول رقم (1) أنه تم نمذجة دالة الهدف بعدة طرق بحسب مؤشرات التحليل الفني (المتوسط المتحرك البسيط، المتوسط المتحرك المرجح، المتوسط المتحرك الأسّي، نسبة التغير السعري)، ليصبح لدينا سلسلة زمنية لكل متغير تابع يعبر فيه كل سجل من سجلاته عن الحالة المستقبلية لسعر الإغلاق بعد 22 يوم فترة تداول خلال الشهر وبالتالي سنقوم ببناء أربعة نماذج تنبؤية باستخدام شبكة NAR العصبية بحسب نمذجة دالة الهدف (متغير التابع) لسعر الإغلاق وفق مؤشرات التحليل الفني بهدف المفاضلة فيما بينها للوصول إلى متغير الهدف الذي حقق نموذج أدنى قيمة لمتوسط مربع الخطأ MSE مقارنةً مع باقي النماذج.

والشكل رقم (3) يوضح جزء من قاعد البيانات نموذج SMA كإحدى القواعد التي سوف تستخدم لبناء نموذج شبكة NAR بعد إفراغها وتهيتها داخل برنامج Matlab وهي كما يلي:

	A	B	C	D	E	F	G	H	I	J	K
	Target										
	Number	Number	Number	Number	Number	Number	Number	Number	Number	Number	Number
1	Date	1/1/2015	1/2/2015	1/3/2015	1/4/2015	1/5/2015	1/6/2015	1/7/2015	1/8/2015	1/9/2015	1/10/2015
2	SMA	964.11	964.44	965.17	966.05	967.39	968.80	970.01	970.64	971.01	971.19

الشكل رقم (3) جزء من قاعد البيانات نموذج SMA كإحدى القواعد التي سوف تستخدم لبناء نموذج شبكة NAR.

المصدر: الإعداد بالاعتماد على برنامج Matlab.

لوحظ من الشكل رقم (3) والذي يمثل جزء من قاعد بيانات بناء نموذج NAR والمؤلفة من سطرين، السطر الأول Date وهو تاريخ السلسلة الزمنية بشكل يومي تبدأ من 2015/1/1 وحتى 2015/1/10 والسطر الثاني متوسط أسعار الإغلاق اليومية SMA خلال شهر أي فترة (22 يوم) بحسب بارامترات المؤشرات الفنية لمؤشر الأسواق المالية الناشئة، أي أنه في يوم 2015/1/10 بلغت قيمة متوسط سعر الإغلاق المستقبلي 971.19 دولار أمريكي.

### 2.1.9. تحديد بنية ومعمارية شبكة NAR العصبونية

بشكل عام لا توجد معايير وقواعد محددة عند تصميم الشبكات العصبية الاصطناعية، ولكن من أهم مراحل تصميم أي شبكة هي تحديد عدد الطبقات المخفية والعصبونات ضمن تلك الطبقات بشكل أساسي والتي تعتمد على مبدأ التجربة والخطأ للوصول لنموذج ذو دقة عالية تكون فيه نسبة متوسط مربع الخطأ MSE أقل ما يمكن بما تتناسب مع معطيات الدراسة [14].

والجدول رقم (2) يوضح نتائج عدة محاولات تم القيام بها مع اختبار دقة كل محاولة كما يلي:

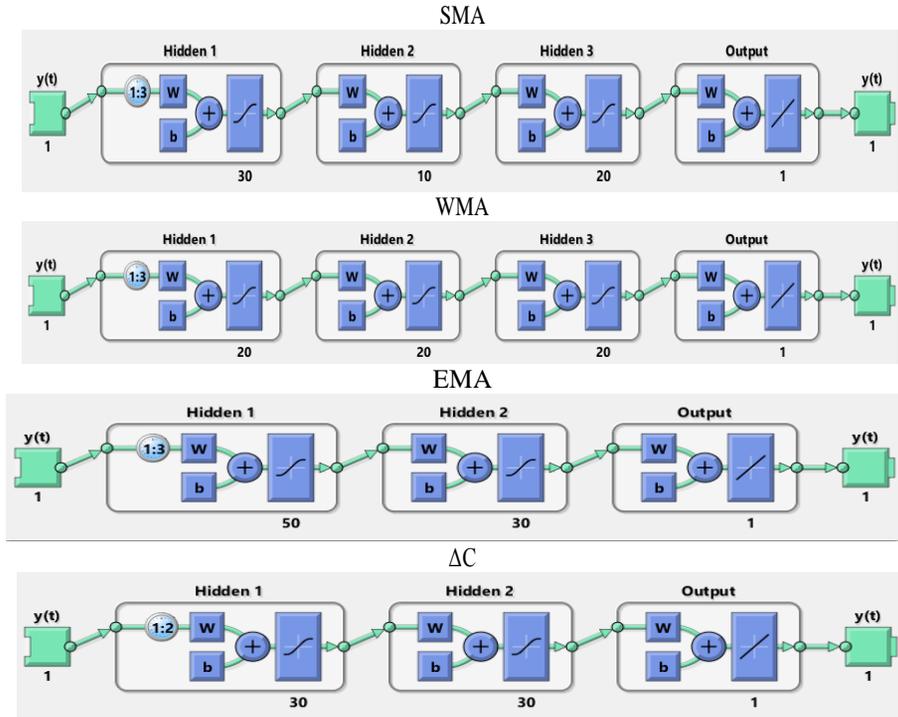
الجدول رقم (2) يبين نتائج العديد من المحاولات مع الاختبارات الخاصة بها للوصول إلى بنية شبكة NAR.

SMA				
Hidden Layers	Number of layers	NAR Architecture	(Mean Squared Error)	Regression R
			MSE Validation	
1	3	(1-10-1)	0.42964	0.999
1	3	(1-30-1)	0.40673	0.999
2	4	(1-30-10-1)	0.38785	0.999
2	4	(1-30-50-1)	0.46868	0.999
<b>3</b>	<b>5</b>	<b>(1-30-10-20-1)</b>	<b>0.35009</b>	<b>0.999</b>
WMA				
1	3	(1-10-1)	0.78439	0.999
1	3	(1-20-1)	0.67427	0.999
2	4	(1-20-50-1)	0.88133	0.999
3	5	(1-20-20-10-1)	0.70821	0.999
<b>3</b>	<b>5</b>	<b>(1-20-20-20-1)</b>	<b>0.64665</b>	<b>0.999</b>
EMA				
1	3	(1-30-1)	0.75144	0.999
1	3	(1-50-1)	0.69459	0.999
2	4	(1-50-10-1)	0.88995	0.999
<b>2</b>	<b>4</b>	<b>(1-50-30-1)</b>	<b>0.64776</b>	<b>0.999</b>
3	5	(1-50-30-10-1)	0.67297	0.999
$\Delta C$				
1	3	(1-20-1)	0.00021847	0.96308
1	3	(1-30-1)	0.00017059	0.9656
2	4	(1-30-20-1)	0.00025681	0.9622
<b>2</b>	<b>4</b>	<b>(1-30-30-1)</b>	<b>0.00015258</b>	<b>0.97327</b>
2	4	(1-30-40-1)	0.00018415	0.96425

المصدر: إعداد الباحث بالاعتماد على برنامج EXCEL.

لوحظ من الجدول رقم (2) أن أفضل معمارية لنموذج شبكة NAR العصبونية للتنبؤ بمتوسط سعر الإغلاق SMA خلال 22 يوم هي (1-30-10-30-1) التي تحقق عندها أدنى قيمة لمتوسط مربع الخطأ MSE والمؤلفة من طبقة مدخلات واحدة والتي تمثل الزمن Time بمستوى زمني يومي ومن ثلاثة طبقات مخفية الأولى بـ 30 عنصر معالجة وهو عدد عصبونات الطبقة الخفية بمعدل تأخير [3-1] حدّد بثلاثة

مشاهدات لطبقة المخرجات والثانية بـ 10 عناصر والثالثة بـ 20 عنصر معالجة وطبقة مخرجات واحدة تمثل دالة الهدف Target بـ 2376 مشاهدة يومية لمتوسط أسعار الإغلاق المستقبلية خلال 22 يوم للمؤشر MSCI EM، أما بالنسبة للتنبؤ بمتوسط المتحرك المرجح لسعر الإغلاق WMA فإن أفضل معمارية له هي (1-20-20-20-1) و لنموذج EMA هي (1-50-30-1) بمعدل تأخير [3-1] حدّد بثلاثة مشاهدات لمخرجات الشبكة للنماذج الثلاثة، أما بالنسبة لنموذج نسبة التغير السعري  $\Delta C$  فإن أفضل معمارية له هي (1-30-30-1) بمعدل تأخير [2-1] لمخرجات الشبكة التي تحقق عندها أدنى قيمة لمتوسط مربع الخطأ MSE مقارنةً مع باقي النماذج وبالتالي يعد نموذج شبكة NAR الأفضل للتنبؤ بنسبة التغير السعري لأسعار الإغلاق المستقبلية لمؤشر الأسواق المالية الناشئة MSCI EM كونه حقق أعلى دقة تنبؤيه، حيث استخدم دالة تنشيط Sigmoid غير الخطية في الطبقة الخفية ودالة تنشيط Liner الخطية في طبقة المخرجات، إضافةً لذلك نجد أن جميع نتائج الاختبار حققت درجة ارتباط قريبة من الواحد وبنسب مختلفة لمتوسط مربع الخطأ. والشكل رقم (4) يبين بنية أو معمارية شبكة NAR لكل نموذج وهي كما يلي:

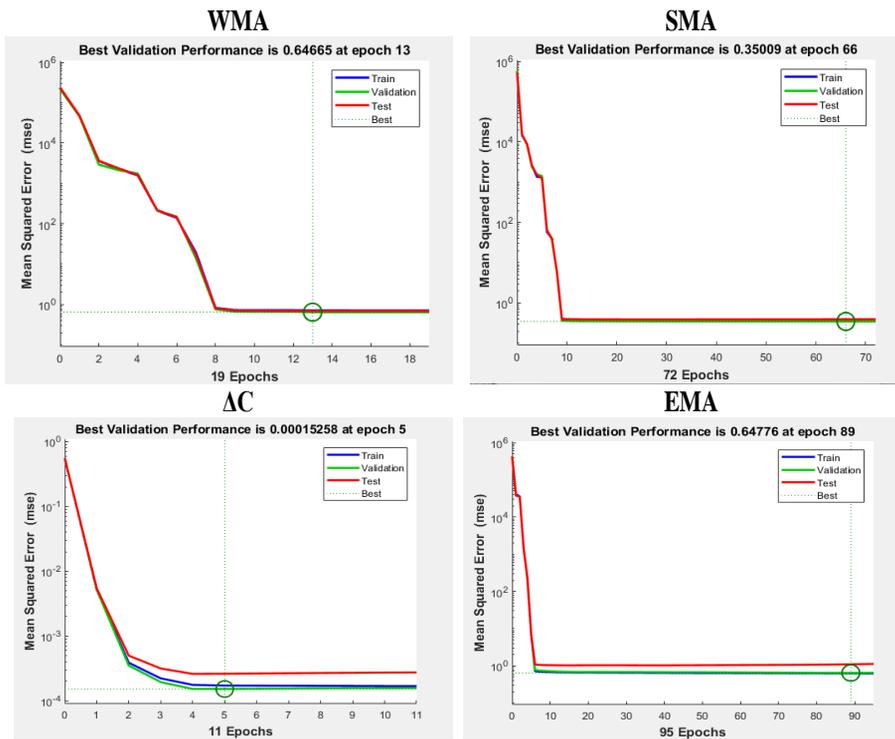


الشكل رقم (4) يوضح بنية أو معمارية شبكة NAR لكل نموذج.

المصدر: إعداد الباحث بالاعتماد على برنامج Matlab.

### 3.1.9. تدريب واختبار شبكة NAR العصبونية

في هذه المرحلة يتم تحديد خيارات عملية التدريب وتعليم الشبكة، حيث قمنا باستخدام تابع التدريب TRAINLM لتحليل وتدريب الشبكة والذي يعمل على تصغير متوسط مربع الخطأ MSE أصغر ما يمكن وهو إحدى خوارزميات الانتشار العكسي Backpropagation لتصحيح الأخطاء، وتم تقسيم بيانات الدراسة إلى 80% لمرحلة التدريب تضم 1900 مشاهدة و10% لمرحلة الاختبار تضم 238 مشاهدة و10% لمرحلة التحقق من الصحة تضم 238 مشاهدة. والشكل رقم (5) يبين نتائج عملية التدريب والاختبار والتحقق من الصحة للشبكة NAR للنماذج الأربعة وهي كما يلي:

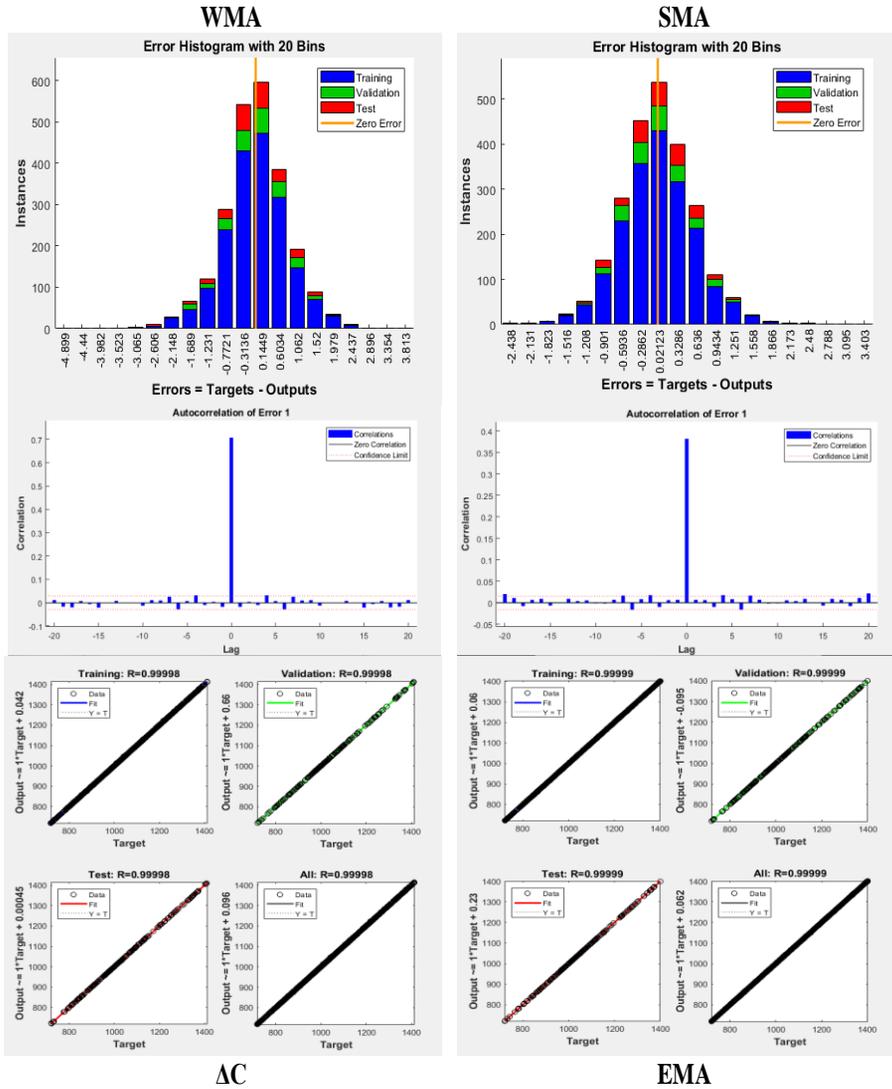


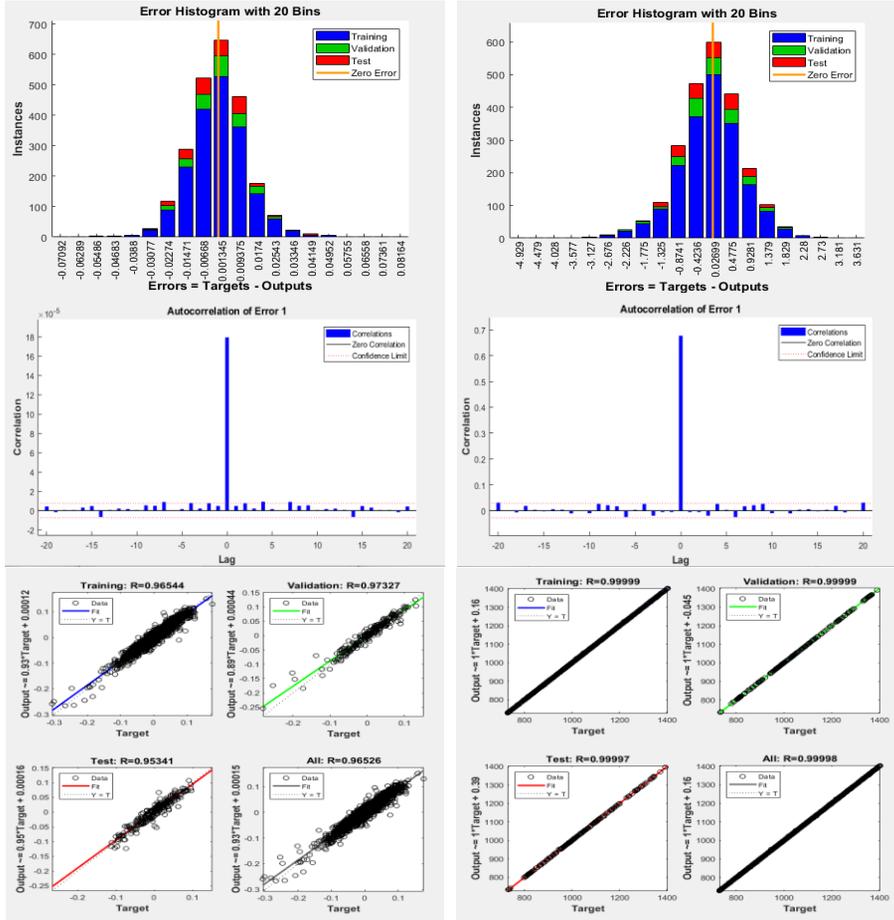
الشكل رقم (5) يوضح نتائج عملية التدريب والاختبار والتحقق من الصحة للشبكة NAR للنماذج الأربعة.

المصدر: الإعداد بالاعتماد على برنامج Matlab.

لنلاحظ من الشكل رقم (5) أن قيم متوسط مربع الخطأ لكل من عينة التدريب والاختبار والتحقق من الصحة للنماذج الأربعة متقاربة مما يدل على كفاءة النماذج وقدرتها على التنبؤ بالقيم المستقبلية بحسب كل دالة هدف أثناء عملية التدريب نفسها، حيث بلغت قيمة MSE عند الدورة 66 لعينة التحقق من الصحة لنموذج SMA (0.35) ولنموذج WMA عند الدورة 13 (0.646) ولنموذج WMA عند الدورة 89 (0.647)

ولنموذج  $\Delta C$  عند الدورة 5 (0.000152) وهي أقرب قيمة للصفر من باقي القيم، ولتقييم كفاءة تدريب الشبكة تم الاعتماد على معامل الارتباط R الذي يعكس القيمة المقاسة للعلاقة بين المخرجات والهدف، فكلما كنت هذه القيمة قريبة من الواحد الصحيح كانت العلاقة قوية، إضافة إلى المدرج التكراري للأخطاء ودالة الارتباط الذاتي للأخطاء التي تعكس مدى ملائمة الشبكة لعملية التدريب. والشكل رقم (6) يبين المدرج التكراري للأخطاء ودالة الارتباط الذاتي للأخطاء لتقييم مدى ملائمة الشبكة لعملية التدريب للنماذج الأربعة:





الشكل رقم (6) يوضح المدرج التكراري للأخطاء ودالة الارتباط الذاتي للخطاء لنموذج الأربعة.

المصدر: الإعداد بالاعتماد على برنامج Matlab.

لوحظ من الشكل رقم (6) أن المدرج التكراري للأخطاء لنموذج SMA والذي يعبر عن بواقي الأخطاء بين القيم المستهدفة والقيم المتوقعة خلال مرحلة التدريب والاختبار والتحقق من الصحة التي تتناقص مع زيادة تدريب الشبكة وهي متناظرة بالنسبة للمحور الصفري أي أن الأخطاء تتبع التوزيع الطبيعي وبالتالي الشبكة مدربة بشكل ملائم، حيث تتراوح قيم بواقي الخطأ الإجمالية بين (3.403، -2.438) موزعة على 20 شريط عامودي (Bins)، إذ يمثل كل شريط عمودي عدد العينات التي تخضع لعملية التدريب والاختبار والتحقق من الصحة بحسب نسبة التقسيم (10-10-80) من مجموعة بيانات الدراسة في المحور Y، وأيضاً دالة الارتباط الذاتي للخطاء تؤكد لنا ذلك بأن جميع الأخطاء غير مترابطة فيما بينها والتي تقع ضمن مجال الثقة 95% حول الصفر مما يدل على جودة تعلم الشبكة وقدرتها على التنبؤ بمتوسط أسعار الإغلاق

المستقبلية لمؤشر الأسواق المالية الناشئة MSCI EM بمستوى زمني شهري بناءً على سلسلة زمنية يومية وهذا ما تؤكد قيمة معامل الارتباط القريبة من الواحد، وبالتالي نجد من خلال المقارنة بين النماذج أن نموذج  $\Delta C$  متوسط نسبة التغير لسعر الإغلاق حقق أدنى قيمة لمتوسط مربع الخطأ MSE والتي بلغت قيمتها 0.00015 وقيمة معامل الارتباط R 0.97 قريبة من الواحد.

أجل تحسين دقة تنبؤ النموذج للوصول إلى أدنى قيمة لمتوسط مربع الخطأ قمنا ببناء نموذج باستخدام شبكة NARX العصبية بالاعتماد على تحليل سلسلة الأسعار التاريخية المكونة للمؤشر العام للأسواق المالية الناشئة (Open-Max-Min-Close) كمتغيرات مستقلة من أجل معرفة مدى تأثير تلك الأسعار على أداء العملية التنبؤية لنسبة تغير أسعار الإغلاق المستقبلية  $\Delta C$  وهذا ما ستوضحه الفقرات التالية.

### 12.9. تهيئة وتجهيز البيانات وهيكلتها لشبكة الـ NARX.

بعد إفراغ البيانات الخام وترتيبها ضمن برنامج Matlab أصبح لدينا قاعدة بيانات خاصة بالقيم التاريخية لأسعار المؤشر وهي عبارة عن جدولين، الجدول الأول يحتوى 2376 مشاهدة يتكون من أربعة متغيرات مستقلة Input وهي (Open-Max-Min-Close) سعر الافتتاح وأعلى سعر وأدنى سعر وسعر الإغلاق بمستوى زمني يومي T، والجدول الثاني يضم 2376 سجلاً يتكون من متغير تابع Target وهو نسبة التغير السعري بمستوى زمني T+22، ليصبح لدينا قاعدة البيانات الخاص لمرحلة التدريب والاختبار والتحقق من الصحة لنتناسب مع شبكة NARX. والشكل رقم (7) يبين جزء من قاعدة بيانات التي سوف تستخدم لبناء نموذج شبكة NARX بعد إفراغها وهيئةها داخل برنامج Matlab وهي كما يلي:

input					target	
2376x4 double					2376x1 double	
	1	2	3	4	1	
1	956.6700	956.7900	956.2800	956.2800	0.0297	
2	956.1000	959.4700	952.0500	953.7200	0.0204	
3	956.1000	959.4700	952.0500	953.7200	0.0083	
4	956.1000	959.4700	952.0500	953.7200	0.0106	
5	952.2300	952.2800	939.5300	940.6900	0.0381	
6	938.8300	939.2000	929.2700	934.7300	0.0493	
7	933.0300	942.4800	932.1000	941.1800	0.0436	
8	943.4500	960.1800	943.4000	958.8300	0.0206	
9	961.0400	967.2200	959.8600	961.3700	0.0119	
10	961.4300	963.6700	954.8300	955.5300	0.0118	
11	954.6600	962.7300	953.5400	959.8900	0.0014	
12	960.6000	962.1900	954.3200	955.7300	0.0162	
13	956.2500	965.5300	954.7600	959.9700	0.0278	

الشكل رقم (7) جزء من قاعدة البيانات التي سوف تستخدم لبناء نموذج شبكة NARX

المصدر: الإعداد بالاعتماد على برنامج Matlab.

## 2.2.9. تدريب واختبار شبكة NARX وتحديد بنيتها

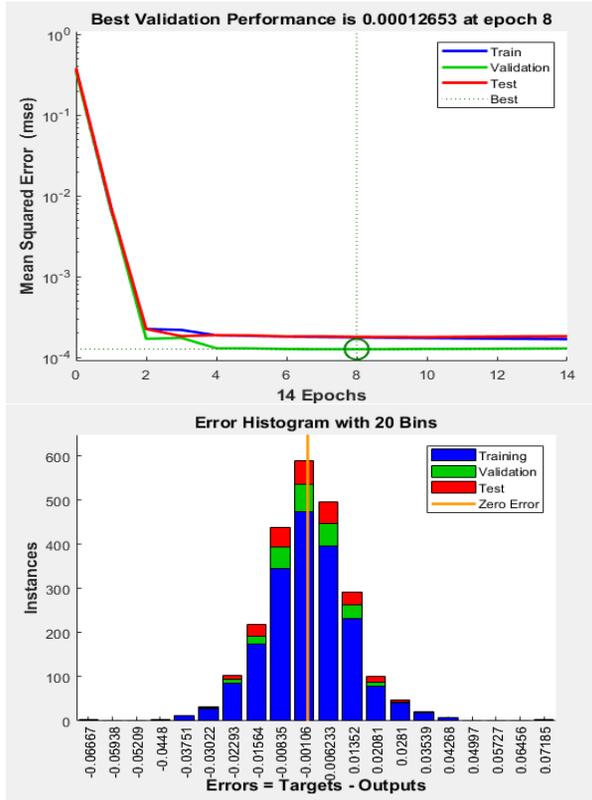
تم تحديد بنية ومعمارية شبكة NARX العصبونية بناءً على التجربة والخطأ بنفس أسلوب شبكة NAR العصبونية من خلال اختبار عدت شبكات عصبونية تختلف بعدد طبقاتها المخفية وعدد العصبونات لكل طبقة حتى الوصول إلى المعمارية التي تحقق عندها أدنى قيمة لمتوسط مربع الخطأ MSE بما يتناسب مع بيانات الدراسة. والجدول رقم (3) يبين نتائج عدة محاولات تم القيام بها مع اختبار دقة كل محاولة.

الجدول رقم (3) يبين نتائج العديد من المحاولات مع الاختبارات الخاصة بها للوصول إلى بنية شبكة NARX.

Hidden Layers	Number of layers	NARX Architecture	MSE (Mean Squared Error)	Regression R
			Validation	
1	3	(1-10-1)	0.00021444	0.96217
1	3	(1-20-1)	0.00015832	0.96886
1	3	(1-30-1)	0.00014186	0.96249
1	3	(1-40-1)	0.00019242	0.966645
1	3	(1-30-10-1)	0.000201	0.95558
2	4	<b>(1-30-20-1)</b>	<b>0.00012653</b>	<b>0.97512</b>
2	4	(1-30-40-1)	0.00014399	0.97204
2	4	(1-30-20-10-1)	0.00016954	0.96782

المصدر: إعداد الباحث بالاعتماد على برنامج EXCEL.

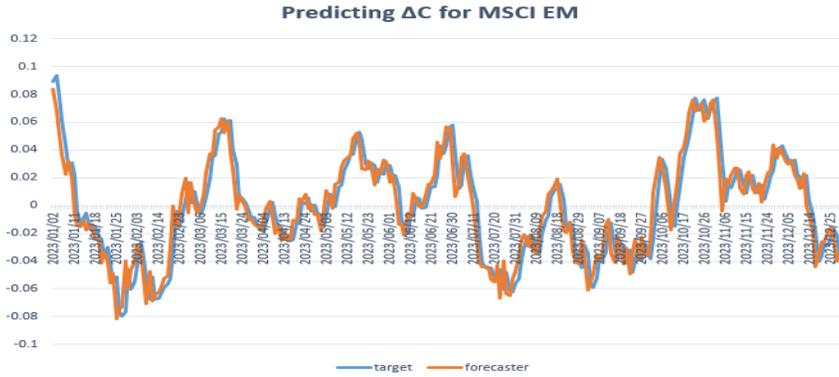
لوحظ من الجدول رقم (3) أن أفضل معمارية لشبكة NARX للتنبؤ بنسبة التغير السعري خلال 22 يوم هي (1-30-20-1) والتي تحقق عندها أدنى قيمة لمتوسط مربع الخطأ MSE والمؤلفة من طبقة مدخلات واحدة تتكون من أربعة متغيرات مستقلة وهي الأسعار المكونة للمؤشر MSCI EM بمستوى زمني يومي ومن ثلاثة طبقات مخفية الأولى بـ 30 عنصر معالجة وهو عدد عصبونات الطبقة الخفية وبمعدل تأخير [0-1] مشاهدة لمدخلات الشبكة ومعدل تأخير مشاهدين [1-2] لمخرجات الشبكة والثانية بـ 20 عنصر وطبقة مخرجات واحدة تمثل دالة الهدف Target بـ 2376 مشاهدة يومية لنسبة تغير أسعار الإغلاق المستقبلية خلال 22 يوم، حيث استخدم دالة تنشيط Sigmoid غير الخطية في الطبقة الخفية ودالة تنشيط Liner الخطية في طبقة المخرجات. والشكل رقم (8) يبين نتائج عملية التدريب والاختبار والتحقق من الصحة للشبكة NARX وهي كما يلي:



الشكل رقم (8) يوضح نتائج عملية التدريب والاختبار والتحقق من الصحة للشبكة NARX المصدر: الإعداد بالاعتماد على برنامج Matlab.

من الشكل رقم (8) نجد أن قيمة متوسط مربع الخطأ MSE لعينة التحقق من الصحة للنموذج تساوي 0.00012653 وهي قيمة قريبة جداً من الصفر، مما يدل على كفاءة وقدرة النموذج على التنبؤ الدقيق بالقيم المستقبلية لنسبة التغير السعري، وقد بلغت قيمة معامل الارتباط للنموذج 0.97512 وهي أيضاً قيمة قريبة جداً من الواحد مما يدل على كفاءة تدريب وتعليم الشبكة وعلى قوة العلاقة بين المخرجات والهدف، وبالتالي أن النموذج المبني باستخدام شبكة NARX العصبية حقق نتائج أفضل من النموذج المبني باستخدام شبكة NAR العصبية في عملية التنبؤ بنسبة التغير لأسعار الإغلاق المستقبلية للمؤشر العام للأسواق المالية الناشئة MSCI EM مما يدل على أن سلسلة الأسعار الزمنية المكونة للمؤشر لها تأثير ودلالة أكبر على تقلبات نسبة تغير الأسعار المستقبلية وعلى العملية التنبؤية من خلال زيادة دقة النموذج بناءً على تخفيض نسبة الخطأ قدر الإمكان. والشكل رقم (9) يبين نتائج نموذج شبكة NARX للتنبؤ بنسبة تغير

أسعار الإغلاق للمؤشر من الفترة 02/01/2023 حتى 01/01/2024 كمثال توضيحي عن كامل الفترة الزمنية المدروسة.



والشكل رقم (9) يبين نتائج نموذج شبكة NARX للتنبؤ بنسبة تغير أسعار الإغلاق للمؤشر من الفترة 02/01/2023 حتى 01/01/2024 كمثال توضيحي عن كامل الفترة الزمنية المدروسة. المصدر: من إعداد الباحث بالاعتماد على برنامج EXCL.

من الشكل السابق يتضح أن القيم المتنبئ بها بناءً على مخرجات نموذج NARX تحاكي القيم الواقعية لمؤشر الأسواق المالية الناشئة MSCI EM من خلال التقارب الكبير للمنحنيين وبالتالي إمكانية الاعتماد على النموذج (في حال وجود أربعة متغيرات تمثل الأسعار المكونة للمؤشر كسلسلة زمنية) للتنبؤ بنسبة التغير لأسعار الإغلاق للمؤشر.

## 10. النتائج

- أظهرت نتائج النماذج المبنية باستخدام شبكة NAR العصبية بحسب المؤشرات الفنية (SMA-WMA-EMA) لنمذجة دالة الهدف دقة منخفضة في عملية التنبؤ بالقيم المستقبلية لأسعار الإغلاق بمستوى زمني شهري.

- أظهرت نتائج النموذج المبني باستخدام شبكة NAR دقة في عملية التنبؤ بأسعار إغلاق مؤشر الأسواق المالية الناشئة بالاعتماد على متغير وحيد (نسبة تغير أسعار الإغلاق) كسلسلة زمنية، حيث بلغت قيمة متوسط مربع الخطأ MSE للنموذج 0.0001526 وهي قيمة قريب من الصفر وقيمة معامل الارتباط R 0.97327 وهي قيمة قريبة من الواحد وبالتالي امكانية الاعتماد على النموذج في أسواق الأوراق المالية لدعم العمليات الاستثمارية في حال وجود متغير وحيد للتنبؤ بسعر الإغلاق المستقبلي بمستوى شهري.

- أظهرت نتائج النماذج المبنية باستخدام شبكة NARX دقة أعلى من النموذج السابق في عملية التنبؤ بسعر الإغلاق المستقبلي للمؤشر العام للأسواق الناشئة في حال الاعتماد على سلسلة الأسعار الزمنية المكونة للأسهم (Open-Max-Min-Close) كمتغيرات مستقلة، حيث كانت قيمة متوسط مربع الخطأ MSE 0.00012 قريبة من الصفر وقيم معامل الارتباط R 0.975 قريبة من الواحد مما يدل كفاءتها وإمكانية الاعتماد على النموذج في عملية التنبؤ بسعر الإغلاق المستقبلي بمستوى شهري.

## 11. التوصيات

1. نوصي المستثمرين في الأسواق المالية الناشئة بدعم عملياتهم الاستثمارية بالاعتماد على النموذج المبنى باستخدام شبكة NARX كون النموذج ذو كفاءة ودقة عالية في عملية التنبؤ بنسبة تغير سعر الإغلاق المستقبلي لمؤشرها العام بمستوى زمني شهري والذي يعتبر من أكثر المؤشرات الرئيسية تقيلاً.
2. تطبيق خوارزمية التعلم العميق LSTM لتحليل السلاسل الزمنية أو شبكات عصبونية مختلفة واستخدام طرق نمذجة جديدة لدالة الهدف في بناء نماذج تنبؤية أكثر دقةً من نموذج شبكة NARX العصبونية لأسعار الإغلاق المستقبلية للمؤشر العام للأسواق المالية الناشئة بمستوى زمنية مختلفة.

## المراجع

- 1- Shamsaliniya, S., Safa, M., Chavoshi, S. K., & Jahangirnia, H. (2024). **Prediction of Stock Price Resilience, using Artificial Neural Networks (MLP) in companies listed on the Stock Exchange.** International Journal of Finance & Managerial Accounting, 9(34), 95-117.
- 2- Sagaceta Mejía, A. R., Sánchez-Gutiérrez, M. E., & Fresán-Figueroa, J. A. (2024). **An Intelligent Approach for Predicting Stock Market Movements in Emerging Markets Using Optimized Technical Indicators and Neural Networks.** Economics, 18(1).
- 3- Sonkavde, G., Dharrao, D. S., Bongale, A. M., Deokate, S. T., Doreswamy, D., & Bhat, S. K. (2023). **Forecasting stock market prices using machine learning and deep learning models: A systematic review, performance analysis and discussion of implications.** International Journal of Financial Studies, 11(3), 94.
- 4- غبولى فايزة، 2019، دور الأسواق المالية الناشئة في تحقيق التنمية الاقتصادية دراسة حالة البحرين وماليزيا، رسالة ماجستير، جامعة محمد البشير الإبراهيمي، كلية العلوم الاقتصادية، الجزائر، ص 11.
- 5- Ahmed, R. R., Vveinhardt, J., Streimikiene, D., & Fayyaz, M. (2017). **Multivariate Granger causality between macro variables and KSE 100 index: evidence from**

- 
- Johansen cointegration and Toda & Yamamoto causality.** Economic research-  
Ekonomiska istraživanja, 30(1), 1497-1521.
- 6- Burnham, T. C., Gakidis, H., & Wurgler, J. (2018). **Investing in the presence of massive flows: The case of MSCI country reclassifications.** Financial Analysts Journal, 74(1), 77-87.
  - 7- MSCI Global Market, 2022, **CLASSIFICATION FRAMEWORK**, MSCI Inc., p (2).
  - 8- Krenker., A., et al., 211., **Introduction to the artificial neural networks.**, Artificial Neural Networks: Methodological Advances and Biomedical Applications.
  - 9- Graupe, D., 2013., **Principles of artificial neural networks.**, Vol (7) World Scientific.
  - 10- Pham, H. T., & Yang, B. S., 2010., **A hybrid of nonlinear autoregressive model with exogenous input and autoregressive moving average model for long-term machine state forecasting.**, Expert Systems with Applications.
  - 11- Boussaada, Z., et al., 2018., **A nonlinear autoregressive exogenous (NARX) neural network model for the prediction of the daily direct solar radiation.**, Energies., Université de Tunis El Manar., Vol (11).
  - 12- Ruiz, L. G. B., et al., 2016., **An application of non-linear autoregressive neural networks to predict energy consumption in public buildings.** Energies., Université de Tunis El Manar., Vol (9).
  - 13- Taqvi, S. A., et al., 2020., **Fault detection in distillation column using NARX neural network.**, Neural Computing and Applications.
  - 14- Ding, S., et al., 2013., **Evolutionary artificial neural networks: a review.** Artificial Intelligence Review, Vol (39).