

التنبؤ باستخدام الدمج بين الشبكات العصبية الاصطناعية ونماذج بوكس وجينكينز (دراسة تطبيقية)

الدكتور

البيومي عوض عوض طافية
أستاذ الإحصاء المساعد
كلية التجارة - جامعة المنصورة

الباحثة

الشيماء إبراهيم السيد الوصيفي
معيدة بقسم الإحصاء التطبيقي
كلية التجارة بدمنياط - جامعة المنصورة

ملخص:

استهدفت تلك الدراسة الوصول إلى نموذج مناسب للتنبؤ بمؤشر البورصة EGX30، ولذلك تناولت الدراسة تطبيق الأساليب التالية في التنبؤ:

- ١- الشبكات العصبية.
- ٢- تحليل السلسل الزمنية باستخدام بوكس وجينكينز.
- ٣- الدمج بين الشبكات العصبية وتحليل السلسل الزمنية باستخدام البوافي السابقة والقيم المقدرة من نموذج ARIMA.

وقد تمت المقارنة بين تلك الأساليب باستخدام معايير قياس دقة التنبؤ، واتضح من خلالها أن أسلوب التنبؤ بمؤشر البورصة EGX30 هو أسلوب الدمج باستخدام البوافي السابقة والقيم المقدرة من نموذج ARIMA.

Abstract:

The main objective of this study is to reach an appropriate model to forecast the stock market index, so the study examined the application of the following methods to forecast:

- 1- Neural networks.
- 2- Time series analysis using Box and Jenkins.
- 3- Combination of neural networks and time series analysis using previous residuals and estimated values of the ARIMA model.

At the end of the study, A comparison between these methods using the criteria for measuring the forecast accuracy, it became clear that the most appropriate method to forecast the index of stock market is method of Combination using previous residuals and estimated values of the ARIMA model.

١- مقدمة

إن التنبؤ بالمستقبل هو أحد أهم القضايا الأساسية المستخدمة في العديد من المجالات ويعتبر تحليل السلسل الزمنية من الأساليب الإحصائية الشائعة المستخدمة في التنبؤ والتي تستخدم على نطاق واسع في الكثير من التطبيقات الإحصائية والاقتصادية حيث يتم التنبؤ بسلوك المتغير التابع استناداً على سلوك هذا المتغير في الماضي.

ومن ناحية أخرى فان هناك طريقة حديثة أكثر دقة وفعالية للتنبؤ يمكنها استخدام المنطق في عملياتها بدلاً من فكرة العلاقة الثابتة بين الرموز وردود الأفعال وهي الشبكات العصبية الاصطناعية Artificial Neural Networks حيث تعتبر الشبكات العصبية الاصطناعية أحد فروع علم الذكاء الاصطناعي، ذلك الفرع من علوم الحاسوب الذي يمكن بواسطته تصميم برامج للحواسيب تحاكي أسلوب الذكاء الإنساني لكي يتمكن الحاسوب من أداء بعض المهام بدلاً من الإنسان والتي تتطلب التفكير والفهم والسمع والكلام والحركة (الشرقاوي، ١٩٩٦).

والشبكات العصبية الاصطناعية هي طريقة مناسبة في تمثيل العلاقات بين المتغيرات بشكل مختلف عن الطرق التقليدية، فهي نظام حسابي يتكون من مجموعة من العناصر البسيطة والمرتبطة مع بعضها البعض لتشغيل البيانات على نحو ديناميكي كاستجابة لمدخلات خارجية، لذا تعتبر الشبكات العصبية الاصطناعية نظام معالجة للمعلومات له مميزات أداء معينة بأسلوب يحاكي الشبكات العصبية الحيوية (عيسى، ٢٠٠٠). وقد وجد الباحثون أن طرق المعالجة في الشبكات العصبية الاصطناعية بدأت تقترب من طرق المعالجة في الشبكات الحيوية وبذلك تم استخدامها في مجالات عديدة منها مجال الطب والتحكم والأعمال وغيرها ويمكنها ان تعالج العديد من البيانات كالبيانات الخطية Linear، وغير الخطية Non-Linear، بالإضافة إلى البيانات الناقصة Incomplete والمشوشة Noisy .

ومع الحاجة المستمرة لتنبؤات أكثر دقة للظواهر المختلفة فإن الباحثين يحاولون إيجاد نماذج تجمع بين نماذجين بدلاً من استخدام نموذج واحد للتنبؤ، حيث أن أحدهما يعوض النقص الموجود بالأخر، ويعتبر الدمج بين الشبكات العصبية والسلالس الزمنية من النماذج التي تعطي نتائج أدق مما لو استخدم كل منها على حده، وعلى ذلك فإن البحث يقوم على الدمج بين الشبكات العصبية الاصطناعية ونماذج تحليل السلالس الزمنية، وبذلك يتم الجمع بين مرونة السلالس الزمنية وقوه الشبكات العصبية الاصطناعية، وتهدف عملية الدمج إلى تقليل الفشل من استخدام نموذج غير مناسب حيث يعوض نموذج النقص الموجود في نموذج آخر، كما أن نموذج واحد قد يكون غير كافٍ لفهم السلوك الكامل عن السلسلة الزمنية لظاهرة معينة (Kashei and Bijari, 2010).

وقد تعرض كلا من (Faruk 2009) و (Zhang 2003) لأسلوب الدمج بين الشبكات العصبية الاصطناعية وتحليل السلالس الزمنية وذلك باستخدام الباقي الناتجة من نموذج ARIMA.

وتعرض (Tseng et al. 2002) إلى نموذج الدمج باستخدام المشاهدات والباقي السابقة والقيم المقدرة الناتجين من نموذج ARIMA، ونموذج الدمج باستخدام القيم المقدرة والمشاهدات السابقة الناتجين من نموذج ARIMA، ونموذج الدمج باستخدام الباقي السابقة و القيم المقدرة الناتجين من نموذج ARIMA، ونموذج الدمج باستخدام القيم المقدرة الناتجة من نموذج ARIMA.

وفي هذه الدراسة تتعرض إلى نموذج الدمج باستخدام الباقي السابقة و القيم المقدرة الناتجين من نموذج ARIMA.

وعلى ذلك يكون هناك عدد من أساليب التنبؤ المختلفة هي أسلوب الشبكات العصبية الاصطناعية وأسلوب بوكس وجينكينز وأسلوب الدمج بينهما باستخدام الباقي السابقة و القيم المقدرة الناتجين من نموذج ARIMA، وتكون المشكلة في اختيار النموذج المناسب الخاص بالظاهرة والذي يمكن استخدامه في التنبؤ بالقيم المستقبلية لها.

٢- النماذج المستخدمة

- ١- الشبكات العصبية الاصطناعية.
- ٢- تحليل السلاسل الزمنية باستخدام بوكس وجينكينز.
- ٣- الدمج بين الشبكات العصبية الاصطناعية و تحليل السلاسل الزمنية باستخدام البراقي السابقة والقيم المقدرة من نموذج ARIMA.

١- الشبكات العصبية الاصطناعية

Artificial Neural Networks (ANN)

يحاول العلماء إيجاد طريقة يستطيعون من خلالها محاكاة تحدث في العقل البشري وبدأت المحاولات لبناء تصميم نظام يفكر، و تمضي هذه المحاولات عن ابتكار الشبكات العصبية لمحاولة محاكاة شكل و ترتيب و طريقة عمل الخلايا في الجهاز العصبي للإنسان. تتكون الشبكات العصبية الاصطناعية من عدد من العناصر المترابطة والتي يطلق عليها **النيورونات Neurons** والتي تعمل في انسجام لحل مشكلة معينة.

وتبيّن الخطوات التالية مكونات الشبكة العصبية الاصطناعية وكيفية معالجتها للمعلومات:

١. تتم معالجة المعلومات في عناصر معالجة بسيطة تسمى **النيورونات Neurons**.
٢. تمر الإشارات بين النيورونات عبر خطوط ربط.
٣. يرفق كل خط ربط بوزن معين والذي يضرب مع الإشارات الداخلة إلى النيورون.

٤. يطبق كل نبورون دالة تحفيز معينة -عادة غير خطية- على إجمالي مدخلاته (مجموع الإشارات الداخلة الموزونة) ليحدد إشارة المخرجات الناجمة منه.

٢-٢ نماذج بوكس وجينكينز

Box- Jenkins Models

يعتبر أسلوب تحليل السلسل الزمنية من الأساليب الإحصائية الهامة في التنبؤ، وقد تم استخدام هذا الأسلوب على نطاق واسع في الكثير من التطبيقات الإحصائية والاقتصادية ، حيث يتم التنبؤ بالتغيرات المستقبلية للمتغير بالاعتماد فقط على سلوك هذا المتغير في الماضي . أو بعبارة أخرى فإن نموذج السلسل الزمنية يأخذ في الاعتبار أنماط التغيرات في الماضي لمتغير معين ويستخدم هذه المعلومات للتنبؤ بالتغيرات المستقبلية لذلك المتغير مما يجعل نموذج السلسل الزمنية طريقة متقدمة ووسيلة فعالة في التنبؤ .

ويعد أسلوب التحليل الحديث للسلسل الزمنية الذي قدمه العالمان بوكس وجينكينز في كتابهما الصادر عام (١٩٧٠) أحد الأدوات الإحصائية التي يمكن الاعتماد عليها في تحليل السلسل الزمنية، وهو أسلوب يختلف عن العديد من أساليب التنبؤ الأخرى . حيث يتميز هذا الأسلوب بما يلي (شعراوي، ٢٠٠٤):

١. أنه نظام نمذجة وتنبؤ منظم وشامل وموثوق به، ويعني هذا أنه يقدم حلولاً شاملة لجميع مراحل تحليل السلسل الزمنية بدءاً من اختيار النموذج المبدئي الملائم ومروراً بتقدير معالم هذا النموذج وتشخيصه وانتهاءً بالتنبؤ بالمشاهدات المستقبلية.
٢. أنه لا يفترض الاستقلال بين مشاهدات السلسلة بل يستغل أنماط الارتباط الكامنة في البيانات من خلال نماذج ARMA التي تتميز

بقوتها وقدرتها على عكس أنماط الكثير من السلسل الزمنية التي نصادفها في التطبيقات العملية، ويؤدي ذلك في النهاية إلى تنبؤات موثوقة بها ومتسقة إحصائيا.

٣. أنه يعطي تنبؤات أدق من تلك التي نحصل عليها باستخدام أي أسلوب آخر خاصة إذا توافرت البيانات الكافية لتغطيتها.

٤. أنها تعطي فترات ثقة ملائمة للمشاهدات المستقبلية للبيانات الموسمية وغير الموسمية بينما تفشل طرق أخرى في ذلك.

ويتم بناء نموذج للتنبؤ باستخدام أسلوب بوكس وجينكнер على أربع مراحل هي :

١. التعرف على النموذج Identification Model

٢. تقدير النموذج Model Estimation

٣. تشخيص واختبار النموذج Model Diagnostic

٤. التنبؤ Forecasting

٣-٢ الدمج بين الشبكات العصبية الاصطناعية ونماذج بوكس وجينكز

Combination of Neural networks and Box- Jenkins Models

إن فكرة الدمج بين نماذج ARIMA الخطية ونماذج ANN غير الخطية للتنبؤ بالسلسل الزمنية تقوم على حقيقة أنه لا يوجد نموذج جيد بمفرده في معظم الحالات، فإذا تم استخدام خصائص النماذج معاً فإنه سيكون هناك نموذج دمج ملائم جداً للبيانات حيث يعتبر أسلوب الدمج بين عدة نماذج طريقة فعالة لتحسين أداء كل نموذج، حيث إن تقنيات الدمج المختلفة تعوض النقص الموجود في كل نموذج على حده، بمعنى أنها تقلل نسبة الخطأ الناشئ من استخدام نموذج غير مناسب وبالتالي الحصول على دقة أكثر نسبياً، وفي الحقيقة من الصعب معرفة كل خصائص بيانات السلسلة الزمنية المتباينة في المشاكل الواقعية، لذا يُفضل الدمج بين

النماذج المختلفة، ومن أساليب التي يمكن استخدامها للدمج بين الشبكات العصبية الاصطناعية ونماذج بوكس وجينكنز، والذي سيعتمد عليه البحث أسلوب الدمج باستخدام البوافي السابقة والقيم المقدرة من نموذج ARIMA (Tseng. et al, 2002)، وتتمثل خطوات هذا الأسلوب فيما يلي:

١. بناء نموذج ARIMA لبيانات السلسلة الزمنية y_t بدءاً من مرحلة التعرف وصولاً إلى التنبؤ.

$$\hat{y}_t = \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=1}^q \theta_j e_{t-j} + e_t$$

$e_{t-j} = y_{t-i} - \hat{y}_{t-j}$ حيث:

e_t : البوافي الناتجة من الجزء الخطى.

٢. بناء نموذج ANN بالاعتماد على البوافي السابقة والقيم المقدرة من نموذج ARIMA الذي تم بناؤه في الخطوة الأولى، ويأخذ نموذج الدمج الصورة التالية.

$$\hat{y}_t = h(e_{t-1}, \dots, e_{t-q}, \hat{L}_t)$$

حيث \hat{L}_t : القيم المقدرة من نموذج ARIMA.

٣- تطبيق النماذج على البيانات الفعلية

تركز مجال البحث على التنبؤ بقيمة مؤشر البورصة 30 EGX، وحدود البحث الزمنية تتحصر في الفترة من شهر أكتوبر ٢٠٠٩، وحتى نهاية شهر أكتوبر ٢٠١٠، أما الحدود المكانية فهى جمهورية مصر العربية.

١-٣ تطبيق أسلوب الشبكات العصبية

ت تكون الشبكة العصبية المستخدمة من ثلاثة طبقات، الطبقة الأولى وهي طبقة المدخلات وتمثل في قيم المؤشر EGX30 السابقة y_{t-1} ، الطبقة الثانية وهي الطبقة الخفية وتكون من ٦ عناصر تشغيل، وأخيراً

طبقة المخرجات وتمثل في قيم المؤشر الحالية y_t ، ويصبح النموذج $.ANN(1:6:1)$.

ويعرض الجدول التالي نتائج التنبؤ باستخدام الشبكات العصبية، والقيم الفعلية للمؤشر $EGX30$ $EGX30$ ، وكذلك متوسط مربعات الخطأ MSE الخاصة بكل قيمة MSE .

جدول رقم (١)

القيم المتتبأ بها من الشبكات العصبية والقيم الفعلية للمؤشر $EGX30$

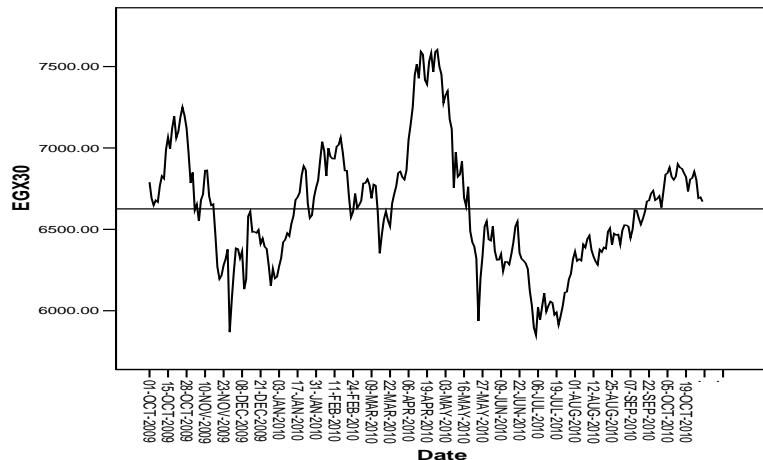
Date	Observed values	Forecast values	MSE
1-11-2010	6612.27	6626.86	.00954
2-11-2010	6654.76	6655.63	.00935
3-11-2010	6713.99	6660.31	.00932
4-11-2010	6764.61	6655.91	.00942
7-11-2010	6829.34	6632.11	.00902
8-11-2010	6837.19	6701.92	.00629

يلاحظ من الجدول رقم (١) اقتراب القيم الفعلية و القيم المتتبأ بها من الشبكات العصبية وخاصة في الثلاثة أيام الأولى، أما التنبؤات في الأيام الثلاث الأخيرة فهي ليست جيدة حيث نلاحظ وجود فرق كبير بين القيم الفعلية و القيم المتتبأ بها، لكن بصفة عامة فإنه بإجراء اختبار χ^2 لاختبار عدم وجود فرق معنوي بين القيم الفعلية و القيم المتتبأ بها، وجد أن قيمة χ^2 المحسوبة تساوي $(10,84)$ ، وعند درجات حرية 5 ومستوى معنوية 5% فإن قيمة χ^2 الجدولية تساوي $(11,07)$ ، وبذلك تكون القيمة المحسوبة أقل من القيمة الجدولية مما يؤيد عدم وجود فرق معنوي بين القيم الفعلية و القيم المتتبأ بها.

٢-٣ تطبيق أسلوب بوكس وجينكينز

المرحلة الأولى: التعرف على النموذج

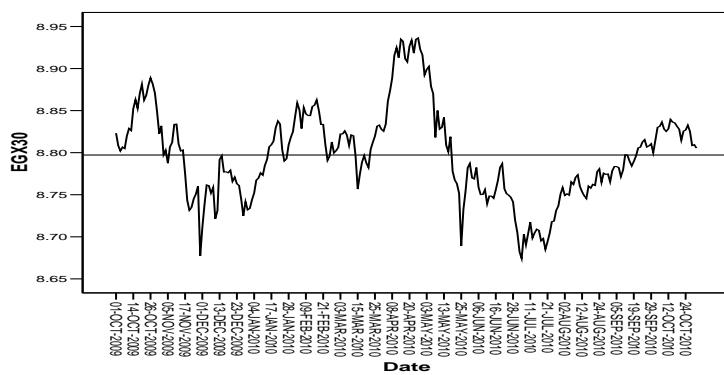
تهدف هذه المرحلة إلى التعرف على نموذج أو أكثر من نماذج ARIMA، وتمثل أولى خطوات تلك المرحلة في تحديد مدى سكون السلسلة من عدمه. ولمعرفة ذلك يتم فحص التوقيع البياني لسلسلة مؤشر البورصة EGX30 شكل (٧) من حيث ثبات التباين و الوسط الحسابي.



شكل (٧)

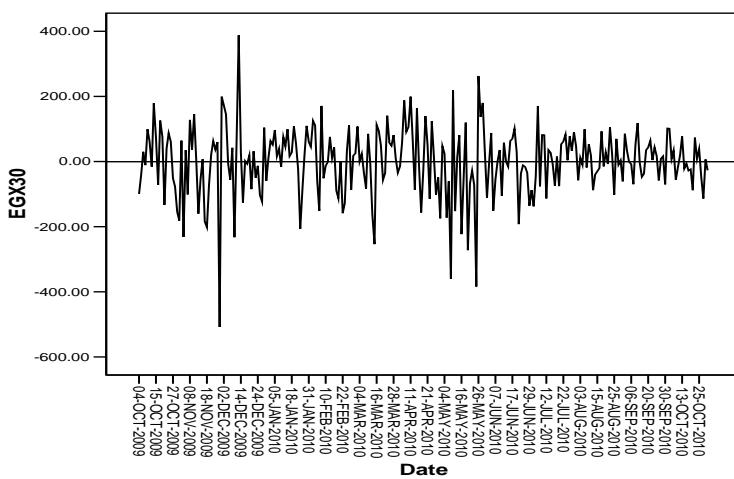
التوقيع البياني لسلسلة البيانات

يوضح شكل رقم (٧) وجود اتجاه عام نحو الانخفاض لذا سيتم أخذ الفروق الأولى لثبت التحويلة اللوغاريتمية، وكذلك عدم ثبات التباين؛ مما يلزم أخذ تحويلة مناسبة، ويعرض شكل (٨) التحويلة اللوغاريتمية لسلسة البيانات، ويوضح أن التحويلة اللوغاريتمية أحدثت تغيراً طفيفاً في السلسلة وبالتالي لا داعي لأخذ التحويلة اللوغاريتمية لثبت التباين.



شكل (٨)

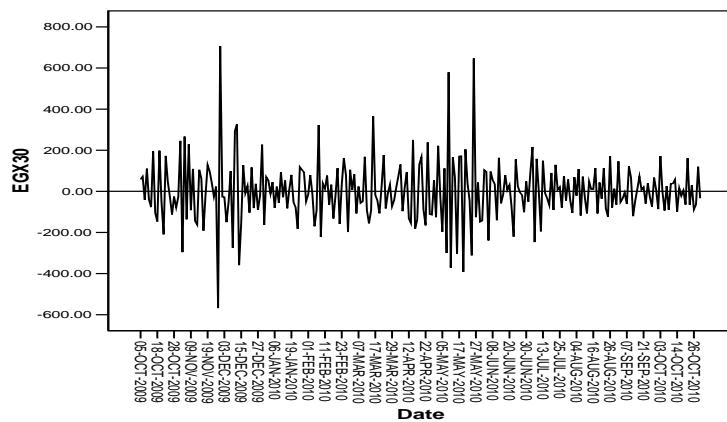
التحويلة اللوغاريتمية لسلسلة البيانات



شكل (٩)

الفروق الأولى لسلسلة الزمنية

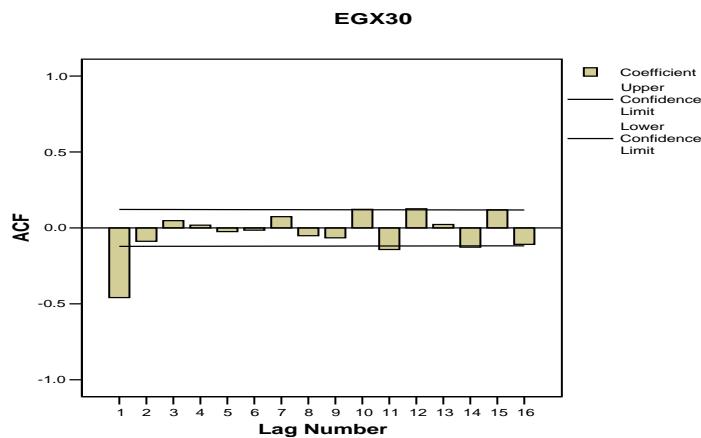
يعرض الشكل رقم (٩) الفروق الأولى للسلسلة الزمنية، ونلاحظ انه ما زال يوجد اتجاه عام طفيف؛ لذلك سيتمأخذ الفروق من الدرجة الثانية. ويوضح شكل (١٠) الفروق الثانية لسلسة البيانات، ويلاحظ انه تم تثبيت الوسط الحسابي.



شكل (١٠)

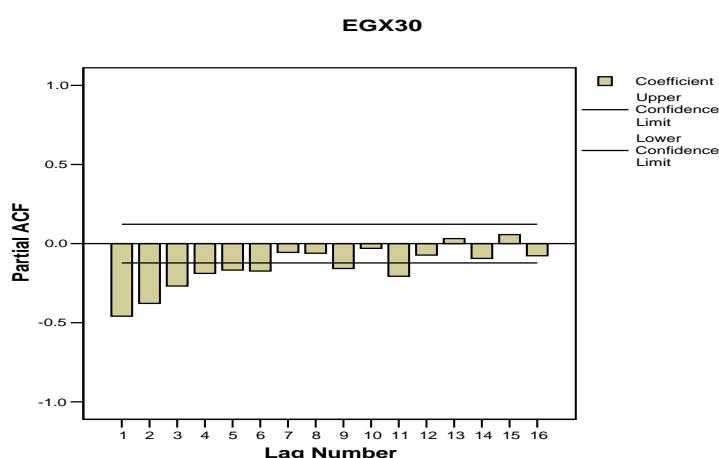
الفروق من الدرجة الثانية للسلسلة الزمنية

تنتمي الخطوة الثانية في مرحلة التعرف في فحص دالة الارتباط الذاتي **PACF ACF** شكل رقم (١١)، ودالة الارتباط الذاتي الجزئي **ACF ACF** لسلسلة البيانات شكل (١٢).



شكل (١١)

دالة الارتباط الذاتي لسلسلة البيانات



شكل (١٢)

دالة الارتباط الذاتي الجزئي PACF لسلسلة البيانات

يلاحظ من شكل رقم (١١) أن دالة الارتباط الذاتي ACF ACF تقطع بعد الفجوة الزمنية الثانية مما يوجه الانتباه إلى وجود معلمتين

لنموذج المتوسطات متحركة وبالتالي يمكن ترشيح النموذج ARIMA(0,2,2) لتمثيل البيانات، كما يمكن اقتراح بعض النماذج الأخرى مثل: ARIMA(0,2,1)، ARIMA(0,2,3).

المرحلة الثانية: التقدير

وفي هذه المرحلة يتم تقدير معالم النماذج المقترحة لملازمة البيانات اليومية للسلسة الزمنية، ويوضح الجدول رقم (٢) تقديرات النقطة لمعامل كل نموذج (Estimate)، والخطأ المعياري للتقدير (St.error)، والنسبة t-tatio (t-Error)، معنوية كل معلومة عند مستوى معنوية ٥٪، ومتوسط مربعات الباقي (MSE).

جدول (٢)

تقديرات معالم النماذج المقترحة

Model	Estimate	St. error	t – ratio
ARIMA(0,2,1)	$\theta_1 = .9999$	2.76	.36
ARIMA(0,2,2) ARIMA(0,2,2)	$\theta_1 = .8017$.061	13.25
	$\theta_2 = .1769$.059	2.98
ARIMA(0,2,3)	$\theta_1 = .8276$.078	10.62
	$\theta_2 = .1962$.073	2.67

	$\theta_3 = -0.0279$.062	-.45
--	----------------------	------	------

من الجدول رقم (٢) نلاحظ ما يلي:

١. بالنسبة للنموذج الأول يتضح عدم معنوية معلمة المتواسطات المتحركة حيث قيمة t المحسوبة صغيرة جدا (٠,٣٦).
٢. بالنسبة للنموذج الثاني يتضح معنوية معالمه حيث قيمة t المحسوبة لكل منهم (١٣,٢٥)، (٢,٩٨) على الترتيب.
٣. بالنسبة للنموذج الثالث يتضح عدم معنوية معلمة المتواسطات المتحركة الثالثة حيث قيمة t المحسوبة الخاصة بها صغيرة جدا (٠,٤٥).

وبالتالي فإن أفضل النماذج هو النموذج الثاني.

المرحلة الثالثة: الفحوص التشخيصية

أولاً: بحث السكون والانعكاس

من الجدول رقم (٢) نلاحظ أن معالم النموذج الثاني يحققان شرط الانعكاس حيث قيمة معلمة المتواسطات المتحركة أقل من الواحد الصحيح.

ثانياً: المعايير الاحصائية

وهذا نهتم بالنموذج الثاني حيث يوضح جدول رقم (٣) أهم المعايير الاحصائية الخاصة بالنموذج المقدر.

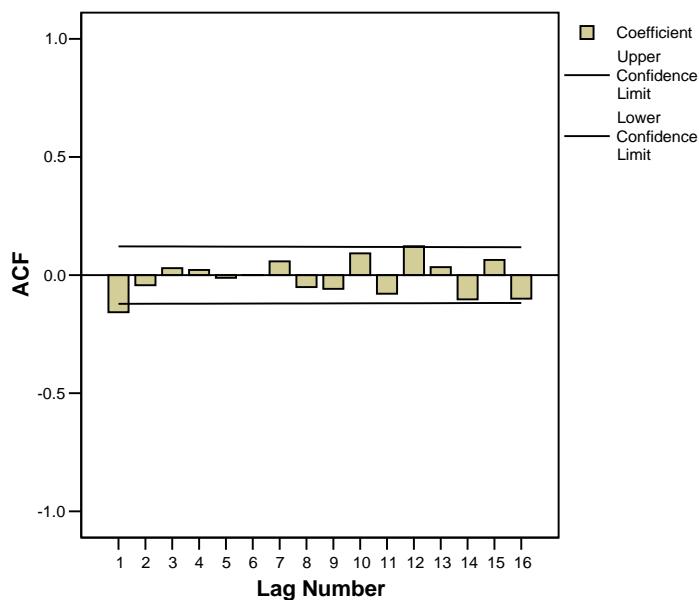
جدول (٣-٥)

المعايير الاحصائية لنموذج ARIMA(0,2,2) المقدر

Model	Standard error	AIC	SBC
ARIMA(0,2,2) ARIMA(0,2,2)	106.52	3267.8	3274.99

ثالثاً: تحليل الباقي

يتم اختبار بواقي النموذج ARIMA(0,2,2) وذلك برسم دالة الارتباط الذاتي للبواقي للتأكد من أنها تغيرات عشوائية بحثة أم لا. ويعرض الشكل (١٣) دالة الارتباط الذاتي لبواقي النموذج، ومن الشكل نلاحظ أن جميع معاملات الارتباط الذاتي تقع داخل حدود الثقة، مما يعني أن البواقي عبارة عن تغيرات عشوائية بحثة، وبالتالي فإن النموذج ARIMA(0,2,2) ملائم للبيانات ويمكن استخدامه في عملية التنبؤ بمؤشر البورصة EGX30.



شكل (١٣)

دالة الارتباط الذاتي لبواقي النموذج ARIMA(0,2,2)

يتضح من الشكل (١٣) عدم معنوية معاملات الارتباط الذاتي، فجميعها تقع داخل حدود الثقة ما عدا عند الفجوة الاولى، ولكن يمكن إهمال ذلك حيث من المتوقع عملياً وجود نسبة من المعاملات خارج حدود الثقة.

المرحلة الرابعة: التنبؤ

بعد تقدير النموذج ARIMA(0,2,2) وفحصه للتأكد من ملائمتة لسلسلة بيانات مؤشر البورصة EGX30 ، فإنه تم استخدام هذا النموذج في التنبؤ بالقيم المستقبلية لمؤشر البورصة EGX30، ويكون شكل النموذج كما يلي:

$$y_t = 2y_{t-1} - y_{t-2} + e_t - .8017e_{t-1} - .1769e_{t-2}$$

ويعرض جدول (٤) القيم المتنبأ بها باستخدام نموذج ARIMA(0,2,2) وكذلك القيم الفعلية للمؤشر EGX30 والذي يتضح من خلاله وجود تقارب بين القيمتين خلال فترة المقارنة.

جدول (٤)

القيم المتنبأ بها من نموذج ARIMA(0,2,2) والقيم الفعلية للمؤشر EGX30

Date	Observed values	Forecast values
1-11-2010	6612.27	6665.77
2-11-2010	6654.76	6667.12
3-11-2010	6713.99	6668.47
4-11-2010	6764.61	6669.82
7-11-2010	6829.34	6673.87

8-11-2010	6837.19	6675.22
-----------	---------	---------

نلاحظ من الجدول رقم (٤) اقتراب القيم الفعلية و القيم المتتبأ بها من الشبكات العصبية وخاصة في الثلاثة أيام الأولى، أما التنبؤات في الأيام الثلاث الأخيرة فهي ليست جيدة حيث نلاحظ وجود فرق كبير بين القيم الفعلية و القيم المتتبأ بها، وبإجراء اختبار χ^2 لاختبار عدم وجود فرق معنوي بين القيم المتتبأ بها والقيم الفعلية، حيث ان قيمة χ^2 المحسوبة تساوي (٩,٦٦)، وعند درجات حرية ٥ ومستوى معنوية ٥٪ فإن قيمة χ^2 الجدولية (١١,٠٧)، وبذلك تكون القيمة المحسوبة أقل من القيمة الجدولية مما يؤكد عدم وجود فرق معنوي بين القيم الفعلية و القيم المتتبأ بها، مما يؤكد ملائمة النموذج ARIMA(0,2,2) للتنبؤ بالمؤشر EGX30.

لكن بالمقارنة مع القيم المتتبأ بها من الشبكات العصبية من خلال جدول رقم (١) نلاحظ أن تنبؤات الشبكات العصبية أكثر دقة من السلاسل الزمنية وخاصة في القيم الأولى والثانية والخامسة والسادسة.

٣-٣ الدمج بين الشبكات العصبية ونموذج بوكس وجينكينز باستخدام ARIMA البواقي السابقة والقيم المقدرة من نموذج ARIMA

أولاً: تحديد هيكل الشبكة

- بناء نموذج ARIMA لبيانات السلسلة الزمنية y_t وكان أفضل النماذج ARIMA(0,2,2) حيث

$$y_t = 2y_{t-1} - y_{t-2} + e_t - .8017e_{t-1} - .1769e_{t-2}$$

٢- بناء نموذج ANN اعتماداً على القيم المقدرة من نموذج

.ARIMA(0,2,2)

$$\hat{y}_t = h(e_{t-1}, e_{t-2}, \hat{L}_t)$$

وبالتالي فإن الشبكة العصبية المستخدمة تتكون من ثلاثة طبقات، الطبقة الأولى وهي طبقة المدخلات وتمثل في الباقي السابقة e_{t-1} ، e_{t-2} ، وقيم المؤشر المقدرة \hat{L}_t الناتجين من نموذج ARIMA الطبقة الثانية وهي الطبقة الخفية وتتكون من ٦ عناصر تشغيل، وأخيراً طبقة المخرجات وتمثل في قيم المؤشر الحالية y_t ، ويصبح النموذج .ARIMA-ANN(0,2,2)(3:6:1)ARIMA-ANN(0,2,2)(3:6:1)

ويعرض الجدول التالي القيم المتتبأ بها باستخدام نموذج الدمج باستخدام الباقي السابقة والقيم المقدرة من نموذج ARIMA، والقيم الفعلية للمؤشر EGX30 EGX30، وكذلك متوسط مربعات الخطأ MSE MSE الخاصة بكل قيمة.

جدول (٥)

القيم المتتبأ بها من نموذج الدمج باستخدام الباقي السابقة والقيم المقدرة من نموذج ARIMA، والقيم الفعلية للمؤشر EGX30

Date	Observed values	Forecast values	MSE
1-11-2010	6612.27	6601.77	.012
2-11-2010	6654.76	6628.94	.017
3-11-2010	6713.99	6681.85	.020
4-11-2010	6764.61	6730.5	.028
7-11-2010	6829.34	6720.9	.041
8-11-2010	6837.19	6698.77	.044

نلاحظ من الجدول رقم (٥) اقتراب القيم الفعلية والقيم المتنبأ بها من نموذج الدمج، وبإجراء اختبار χ^2 لاختبار عدم وجود فرق معنوي بين القيم المتنبأ بها والقيم الفعلية، حيث أن قيمة χ^2 المحسوبة تساوي (٤,٨٩)، وعند درجات حرية ٥ ومستوى معنوية ٥% فإن قيمة χ^2 الجدولية (١١,٠٧)، وبذلك تكون القيمة المحسوبة أقل من القيمة الجدولية مما يؤيد عدم وجود فرق معنوي بين القيم الفعلية والقيم المتنبأ بها، مما يؤكد ملائمة النموذج للتتبؤ بالمؤشر EGX30، ويوضح أيضاً من الجدول أن التنبؤات بالقيمة الأولى والثالثة والرابعة أكثر دقة من نظيرتها الناتجة من نموذج الشبكات العصبية ونموذج السلسلة الزمنية.

٤- المقارنة والاختيار بين أساليب التنبؤ

تم المقارنة بين أساليب التتبؤ التي استخدمت في بناء نماذج للتتبؤ بمؤشر البورصة EGX30، وقد تم استخدام المعايير (الجذر التربيعي لخطأ التتبؤ MSRE، والمتوسط المطلق النسبي لخطأ التتبؤ MAPE)، ويعرض جدول (١٦) تقديرات معايير المفاضلة بين النماذج المقدرة.

جدول (١٦)
تقديرات معايير المفاضلة بين النماذج المقدرة

MODEL	MAPE	MSRE
ARIMA(0,2,2)	.0129	.000230
ANN(1,6,1)	.0125	.000229

نموذج الدمج	.0086	.000121
-------------	-------	---------

يتضح من الجدول رقم (١٦) ما يلي:

١. انخفاض قيمة المعايير $MSRE$ و $MAPE$ الخاصة بنموذج الشبكات العصبية $ANN(1:6)$ عن نموذج $ARIMA(0,2,2)$.
٢. أن نموذج الدمج بين الشبكات العصبية والسلسلة الزمنية قد أعطى تنبؤات أكثر دقة عن نموذج السلسلة الزمنية ونموذج الشبكات العصبية كل على حده، وذلك وفقاً للمعايير $MSRE$ $MAPE$ ، وهذا ما تؤكده الدراسات السابقة.

٥- التوصيات

١. إن الفروق غير الكافية تؤدي إلى نماذج غير مرضية، حيث أنها تخلق سلوك مصطنع في بيانات السلسلة الزمنية، وبالتالي يجبأخذ الفروق عند وجود شك في سكون السلسلة الزمنية مع مراعاة عدم الإفراط فيأخذ الفروق لأن زيادة الفروق قد تعطي أيضا نتائج غير مرضية.
٢. أن يتم اجراء الدراسة بالنسبة لجميع مؤشرات السوق وأيضا اسعار الأسهم المتداولة حتى يستفيد جميع المستثمرين بالسوق.

٣. للتنبؤ بفترة مستقبلية يجب النظر إلى فترة تاريخية كافية من البيانات للحصول على نتائج أكثر دقة، حيث عدد قليل من البيانات يعطي نتائج غير مرضية ولذا يفضل استخدام ٦٠ مشاهدة على الأقل للحصول على دقة في النتائج.
٤. يجب مراعاة الدقة عند بناء نماذج السلسل الزمنية لما لها تأثير على تصميم نموذج الدمج بين الشبكات العصبية والسلسل الزمنية، فكلما كان نموذج السلسل الزمنية دقيق كلما كان نموذج الدمج أكثر دقة في عملية التنبؤ.
٥. أثبتت نموذج الدمج بين الشبكات العصبية والسلسل الزمنية باستخدام الباقي السابقة والقيم المقدرة من نموذج ARIMA أفضليتها عن نموذج الشبكات العصبية ونموذج السلسل الزمنية كل على حده، لذا نوصي باستخدام هذا النموذج في التنبؤ.

المراجع

أولاً: المراجع العربية

١. الشرقاوي، محمد على. (١٩٩٦). "الذكاء الاصطناعي والشبكات العصبية"، مركز الذكاء الاصطناعي للحسابات - القاهرة.
٢. شعراوي، سمير مصطفى. (٢٠٠٤). "مقدمة في التحليل الحديث للسلسل الزمنية"، مركز النشر العلمي - جامعة الملك عبد العزيز.

٣. عيسى، علام زكي. (٢٠٠٠). "الشبكات العصبية البنية الهندسية، الخوارزميات، التطبيقات"، شعاع للنشر والعلوم.

ثانياً: المراجع الأجنبية

1. Ajoy, K. (2005)." Computational Intelligence in Time Series Forecasting Theory and Engineering Applications". Springer.
2. Faruk, D. O. (2009). "A hybrid neural network and ARIMA model for water quality time series prediction". Engineering Application of Artificial Intelligence.
3. Khashei, M. and bijari, M. (2010). "An artificial nural network (p,d,q) model for time series forecasting". Expert Systems with Applications, (479-489).
4. Shankar,T. N .(2008). "Neural Networks". UNIVERSITY SCIENCE PRESS.
5. Smith, A. K and Gupta, N. D. (2000). " Neural Networks in Business Techniques and Applications". Idea Group, Information Science Publishing.
6. Tseng, F. et al. (2002). "An artificial neural network (p, d, q) model for timeseries forecasting". Technological Forecasting and Social Change. Volume 69, Issue 1, (71–87).
7. Zhang, G.P. (2003). "Time Series Forecasting Using A Hybrid ARIMA and Neural Network Model". Neurocomputing, Volume 50, (159 – 175).