



نموذج مقترح لتحسين منهجية بوكس - جينكنز اعتماداً على أسلوب الشبكات العصبية (دراسة تطبيقية)

بحث مُستل من رسالة ماجستير في الإحصاء التطبيقي

إعداد

د. محمد محمود نصر أبو ريا

أستاذ الإحصاء الرياضي

كلية التجارة - جامعة دمياط

أ.سوزان الإمام محمد الإمام

معيدة بقسم الإحصاء التطبيقي والتأمين

كلية التجارة - جامعة دمياط

د. محمد إبراهيم محمد

أستاذ الإحصاء الرياضي المساعد

كلية التجارة - جامعة دمياط

المجلة العلمية للدراسات والبحوث المالية والتجارية

كلية التجارة - جامعة دمياط

المجلد السادس - العدد الأول - الجزء الرابع - يناير ٢٠٢٥

التوثيق المقترح وفقاً لنظام APA:

الإمام، سوزان الإمام محمد؛ أبو ريا، محمد محمود نصر؛ محمد، محمد إبراهيم (٢٠٢٥). نموذج مقترح لتحسين منهجية بوكس - جينكنز اعتماداً على أسلوب الشبكات العصبية (دراسة تطبيقية)، *المجلة العلمية للدراسات والبحوث المالية والتجارية*، كلية التجارة، جامعة دمياط، ٦(١)٤، ٣١١-٣٣٨.

رابط المجلة: <https://cfdj.journals.ekb.eg/>

نموذج مقترح لتحسين منهجية بوكس - جينكنز اعتماداً

على أسلوب الشبكات العصبية (دراسة تطبيقية)

أ.سوزان الإمام محمد الإمام؛ د. محمد محمود نصر أبو ريا؛ د. محمد إبراهيم محمد

المستخلص

يهدف البحث الي الوصول الي أفضل نموذج للتنبؤ بالبيانات اليومية لسعر صرف الجنية المصري مقابل اليورو وذلك بالمفاضلة بين عدة أساليب مختلفة للتنبؤ تتمثل في تحليل السلاسل الزمنية باستخدام منهجية بوكس - جينكنز والشبكات العصبية الاصطناعية وأخيراً الجمع بين تحليل السلاسل الزمنية والشبكات العصبية بهدف تحسين التنبؤ.

تم في هذا البحث استخدام المخرجات الناتجة من نموذج بوكس وجينكنز كمدخلات عند استخدام أسلوب الشبكات العصبية لبناء نموذج يجمع بين أسلوب تحليل السلاسل الزمنية والشبكات العصبية للحصول على تنبؤات أكثر دقة بسعر صرف الجنية المصري مقابل اليورو. وقد تم استخدام بيانات يومية تغطي الفترة من ٢٠٢٠/١/١ الى ٢٠٢٣/٨/٢٢ وتتكون من ٩٥٠ مشاهدة هي فترة التقدير للنماذج المختلفة المقترحة، أما الفترة من ٢٠٢٣/٨/٢٣ الى ٢٠٢٣/٩/٢٠ فهي فترة التنبؤ وتتكون من ٢١ مفردة؛ وتجدر هنا الإشارة الى أن أسبوع العمل في البنوك يتكون من خمسة أيام.

وقد أظهرت نتائج الدراسة أن الجمع بين تحليل السلاسل الزمنية باستخدام منهجية بوكس - جينكنز والشبكات العصبية الاصطناعية قد أدى الى تحسين دقة التنبؤ. تم تقدير عدة نماذج تجمع بين تحليل السلاسل الزمنية والشبكات العصبية الاصطناعية وقد أظهرت النتائج أن نموذج الجمع بالاعتماد على القيم المقدرة والبقايا المتحصل عليها من نموذج $ARIMA(1,2,1)$ كمدخلات عند بناء الشبكة العصبية يعد الأفضل للتنبؤ بسعر صرف الجنيه المصري مقابل اليورو مقارنة بالنماذج الأخرى.

الكلمات المفتاحية:

تحليل السلاسل الزمنية، منهجية بوكس - جينكنز، الشبكات العصبية الاصطناعية، سعر صرف الجنية المصري مقابل اليورو، Autoregressive integrated Moving Average Models، تحسين التنبؤ.

١ - المقدمة

تتعدد الأساليب الاحصائية التي يمكن الاعتماد عليها في دراسة الظواهر والمتغيرات المختلفة ومن ثم التنبؤ بالقيم المستقبلية لها، ويبقى اقتراح الأسلوب المناسب للتنبؤ من أهم أهداف الدارسين في مجال البحث العلمي خاصة في مجال الدراسات الاحصائية. وقد أخذ تصميم الشبكات العصبية للتنبؤ بالسلاسل الزمنية أهمية بالغة في مجالات التطبيق المختلفة ومنها المالية والاقتصادية.

ومن أوائل الدراسات في هذا المجال دراسة (Iebeling & Milton 1996) التي استخدمت تصميم الشبكات العصبية للتنبؤ بالسلاسل الزمنية المالية والاقتصادية، واستعرضت بعض المشاكل الشائعة عند تصميم الشبكات واهتمت الدراسة بإعطاء صورة واضحة خطوة بخطوة عن أسلوب تصميم الشبكة العصبية وقدمت شرحاً مفصلاً لبناء الشبكة العصبية ذات الانتشار العكسي (BP) Back propagation Neural Networks حيث أوضحت الدراسة أن هذا النوع قادر على حل قطاع كبير من المشاكل وأنه أكثر الأنواع استخداماً في التنبؤ بالسلاسل الزمنية.

دراسة (Cabarkapa et al. 2010) حيث استخدمت الشبكات العصبية الاصطناعية في التنبؤ بالسلاسل الزمنية المالية والتنبؤ بالخطر المالي. ودراسة (Turk 2011) التي عرضت العديد من نماذج الشبكات العصبية وفاضلت فيما بينها للتنبؤ بالأزمات في تركيا.

كذلك قدمت دراسة (Juan et al. 2011) وصفاً للنماذج الأساسية في الشبكات العصبية الاصطناعية (ANN) والمقارنة فيما بينها كما قدمت الإجراءات المتبعة للتطبيق العملي لهذه النماذج بالتطبيق على بيانات الاستهلاك الشهري للطاقة الالكترونية في جزر البليار بفرنسا، وتم التوصل الى نتائج مقتضاها أن نماذج الشبكات العصبية تقدم توفيقاً قريباً من البيانات وقدرة كبيرة على التنبؤ.

كذلك يعتبر أسلوب تحليل السلاسل الزمنية من البدائل الهامة للوصول لتنبؤات جيدة من خلال نموذج يعتمد فقط على دراسة سلوك المتغير نفسه في الماضي وأنماط التغيرات السابقة في السلسلة الزمنية واستخدام هذه المعلومات للتنبؤ بالتغيرات المستقبلية لذلك المتغير، وتعتبر منهجية بوكس وجينكنز هي الأكثر تطوراً واستخداماً في تحليل وبناء نماذج السلاسل الزمنية.

وقد اهتمت العديد من الدراسات بتقديم الأطروحات التي تتضمن دمج لأسلوبين أو أكثر من أساليب التحليل الاحصائي بهدف تحسين المنهجية المستخدمة والاستفادة من مميزات كل أسلوب للوصول لتقديرات جيدة وتنبؤات أكثر دقة. كما تتضمن الدراسات في هذا الشأن توضيحاً للطرق الممكنة للدمج وشروط تطبيقه ونوعية المتغيرات والبيانات التي يمكن التعامل معها في كل حالة. ومن أوائل الكتابات في هذا الشأن دراسة (Clemen, R. T. 1989) الذي قدم مراجعة وسرد انتقادي موجز للكتابات المتعلقة بموضوع دمج التنبؤات، حيث أوضح أن دقة التنبؤ يمكن أن تزداد من خلال دمج العديد من التنبؤات المنفردة. كما أوضح أيضاً ان فكرة دمج التنبؤات تفترض ضمناً ان القائم بعملية التنبؤ لا يستطيع توصيف العملية التي تتولد منها البيانات موضع الاهتمام لذلك فان مثل هذه النماذج المختلفة للتنبؤ والتي يضمها نموذج الدمج سوف تكون قادره على التحكم في الاوجه المختلفة للمعلومات المتاحة حول عملية التنبؤ.

وخلال العقدين الأخيرين توالى الدراسات ومنها دراسة (Tseng et al. 2002) حيث اقترحت نموذج هجين للتنبؤ يقوم على دمج نموذج تحليل السلاسل الزمنية الموسمية (Seasonal Autoregressive integrated Moving Average (SARIMA) Models والشبكات العصبية بطريقة نماذج الانتشار الخلفي (BP). وقد تم استخدام النموذج الهجين للتنبؤ بقيمة الانتاج الكلي الصناعي في تايوان وكذلك بقيمة الانتاج الكلي من المشروبات الغازية، وأوضحت نتائج الدراسة أن النموذج الهجين يُعطي أفضل القيم فيما يخص معايير دقة التنبؤ وأن النموذج الهجين قادراً على التنبؤ بنقاط التحول المعنوية التي تحدث في السلسلة الزمنية.

دراسة (Nakamura (2005) وقد استخدمت الدراسة كلاً من نماذج الانحدار الذاتي univariate autoregressive models والشبكات العصبية على بيانات التضخم الاقتصادي في الولايات المتحدة. وقد تفوقت التنبؤات قصيرة الأجل المتحصل عليها باستخدام الشبكات العصبية على تلك المتحصل عليها باستخدام نماذج الانحدار الذاتي. كذلك دراسة (Dhamija and Bhalla (2011) والتي هدفت الى اجراء مقارنة بين الشبكات العصبية ونماذج Autoregressive Conditional Heteroscedasticity (ARCH) model للتنبؤ بالسلاسل الزمنية المالية.

دراسة حامد (٢٠١١) التي تناولت استخدام نماذج بوكس- جنكنز ونماذج الشبكات العصبية الاصطناعية للتنبؤ في السلاسل الزمنية الاقتصادية، وتم التطبيق على بيانات القطاع الزراعي السوداني ممثلة في السلاسل الزمنية لإنتاجية القمح، الذرة، والسمسم. وهدفت الدراسة لإبراز العلاقة بين الأساليب المستخدمة للتنبؤ في السلاسل الزمنية ودقة التنبؤات المتحصل عليها، ومدى تأثير التغيرات التي تطرأ على السلاسل الزمنية ودرجة العشوائية واللا خطية في البيانات على أداء هذه الأساليب.

دراسة (Aladag et al., (2012) حيث تم اقتراح نموذج هجين يجمع بين نموذج الانحدار الذاتي والمتوسطات المتحركة التكاملية الكسرية (ARFIMA) والشبكات العصبية أمامية التغذية (FNN) لتحليل السلاسل الزمنية ذات الذاكرة الطويلة. ولقد تم تطبيق هذا الأسلوب المختلط المقترح على بيانات خاصة بالسياحة في تركيا، وتم مقارنة هذا النموذج الهجين مع الأساليب الأخرى وتبين أن الأسلوب المختلط المقترح لديه أفضل دقة للتنبؤ.

دراسة دربال (٢٠١٤) وقد هدفت هذه الدراسة إلى مقارنة نماذج التنبؤ الخطية وغير الخطية بقصد التنبؤ بمؤشر سوق دبي المالي وذلك بالاعتماد على سلسلة بيانات يومية وتوصلت الدراسة إلى أن نموذج الشبكات العصبية الاصطناعية ANN لديه قدرة أكبر على التنبؤ مقارنة بنموذج الانحدار الذاتي المشروط بعدم تجانس الأخطاء المعمم GARCH.

كما تناولت دراسة حمدان (٢٠١٥) استخدام نماذج هجينة تتكون من خلال الدمج بين نماذج الانحدار الذاتي والمتوسطات المتحركة التكاملية (ARIMA) ونماذج الشبكات العصبية متعددة الطبقات (MLP) بالتطبيق على السلسلة الشهرية لسعر صرف الدولار مقابل الشيك.

كذلك دراسة رياض (٢٠١٧) التي اهتمت بالتنبؤ بمبيعات الكهرباء لشركة سونلغاز الجزائرية، وقد تم المفاضلة بين نموذج ARIMA ونموذج الشبكات العصبية الاصطناعية. دراسة الطويل (٢٠١٩) حيث تناولت المقارنة بين نماذج الانحدار الذاتي والمتوسطات التكاملية الكسرية ARFIMA، والشبكات العصبية الاصطناعية، والدمج بينهما وذلك بالتطبيق على البيانات الشهرية لأسعار القمح العالمية.

ولاتزال الدراسات تتواصل للاستفادة من تطبيق الشبكات العصبية الاصطناعية في المجالات المختلفة، ومنها دراسة أبو رغيف (2021) حيث تم استخدام ثلاث أنواع من تقنيات الشبكات العصبية لإجراء تحليل باستخدام بيانات شهرية عن سعر صرف اليورو مقابل الدولار الأمريكي. ودراسة البلتاجي (2024) حول أثر التطور في استخدام الشبكات العصبية على فعالية البيانات الضخمة في دعم نظام معلومات المحاسبة الإدارية وترشيد القرار الإداري.

وتهتم الدراسة الحالية بتوضيح استخدام تحليل السلاسل الزمنية بأسلوب بوكس - جينكنز واستخدام الشبكات العصبية والدمج بينهما بهدف تحسين التنبؤ. ومما ينبغي التأكيد عليه أن لهذه المحاولات في تحسين التنبؤات أهميته؛ فالتخطيط الجيد يجب أن يبنى على دراسات وافية والتي تحتاج بدورها لعمل تنبؤات مستقبلية دقيقة بالمتغيرات الاقتصادية محل الاهتمام. إن إيجاد تنبؤ دقيق بالبيانات اليومية لسعر صرف الجنية المصري مقابل اليورو له أهميته في رسم السياسات النقدية والاقتصادية المستقبلية؛ كما يعتبر هدفاً للكثير من الاقتصاديين الذين يهتمون بدراسة التغير في سعر صرف العملة المحلية مقابل العملات الأخرى وتأثير ذلك على النشاط الاقتصادي ككل حيث يعكس قوة اقتصاد الدولة. ان التغير في أسعار الصرف له آثاره القوية على المتغيرات الاقتصادية كافة خاصة مع وجود النظام التجاري المفتوح واتفاقية التجارة العالمية.

وفي إطار قيام الدولة المصرية باتباع سياسات للإصلاح الاقتصادي فقد قامت بتخفيض سعر صرف الجنيه المصري عدة مرات خلال السنوات الأخيرة بهدف القضاء على المضاربات على العملات الأجنبية المختلفة مثل الدولار واليورو وغيرها. ومن أهم ما اتخذته الدولة المصرية في الآونة الأخيرة هو التعامل بالعملات الأخرى وأهمها اليورو للتخلص من هيمنة الدولار على الاقتصاد الوطني. مما سبق تتضح أهمية الدراسات الاحصائية التي تساعد في عمل تنبؤات جيدة للعديد من المتغيرات والظواهر في الواقع العملي؛ ومن هنا تتضح أهمية الدراسة الحالية من الناحية النظرية وكذلك التطبيقية.

تم تنظيم الفصول التالية من هذا البحث على النحو التالي، الفصل الثاني يشمل عرضاً لمنهجية بوكس - جينكنز (Box-Jenkins Approach (BJ في تحليل السلاسل الزمنية وتوضيح الخطوات التي يمر بها لبناء نموذج السلاسل الزمنية. ويتناول الفصل الثالث أسلوب الشبكات العصبية الاصطناعية Artificial Neural Network (ANN من حيث تعريفها وتكوينها وأنواعها ومجالات استخدامها وآلية عملها. تم تخصيص الفصل الرابع لعرض الدراسة التطبيقية والتي تم تنظيمها في ثلاث فصول فرعية؛ الأول يتضمن تطبيق أسلوب تحليل السلاسل الزمنية باستخدام منهجية بوكس وجينكنز، والثاني يتضمن تطبيق الشبكات العصبية الاصطناعية، والثالث والأخير يتضمن تطبيق بعض الطرق المقترحة للجمع بين تحليل السلاسل الزمنية والشبكات العصبية الاصطناعية. كما يتضمن الفصل الرابع كذلك المقاضلة بين النماذج المختلفة التي تم الحصول عليها باستخدام العديد من المعايير ومقاييس دقة التنبؤ لتحديد الأفضل للتنبؤ بسعر صرف الجنيه المصري مقابل اليورو. وأخيراً تم عرض نتائج الدراسة في الفصل الخامس الذي يتضمن كذلك بعض التوصيات التي يمكن أن تفيد في مجال البحث.

٢- منهجية بوكس - جينكنز في تحليل السلاسل الزمنية

يعد أسلوب تحليل السلاسل الزمنية من أهم الأساليب الإحصائية التي تستخدم بغرض التنبؤ. ولقد أخذ هذا الأسلوب أهميته من كونه يتنبأ بالتغيرات المستقبلية للظاهرة بالاعتماد فقط على دراسة أنماط التغيرات الخاصة بها في الماضي، أي بالاعتماد فقط على سلوك الظاهرة محل الاهتمام في الماضي. وتعتبر المنهجية التي وضعها بوكس وجينكنز في تحليل السلاسل الزمنية من أهم ما يمكن استخدامه في هذا المجال؛ حيث تتضمن هذه المنهجية خطوات ومراحل محددة يتم على أساسها بناء النموذج الذي يمكن أن يستخدم في التنبؤ. وتتكون منهجية بوكس وجينكنز في تحليل السلاسل الزمنية من أربعة مراحل تتمثل

في مرحلة التعرف على النموذج، ومرحلة تقدير النموذج، ومرحلة اجراء الفحوص التشخيصية للنموذج، وأخيراً مرحلة التنبؤ (Box and Jenkins, 1976).

(١-٢) التعرف على النموذج Model Identification

تمر مرحلة التعرف على النموذج المناسب باستخدام منهجية بوكس وجينكنز بعدد من الخطوات سوف نستعرضها فيما يلي:

(١-١-٢) التأكد من سكون السلسلة الزمنية:

يقال إن السلسلة الزمنية ساكنة Stationary إذا كانت تتسم بخصائص إحصائية ثابتة عبر الزمن. ويمكن وصف الخصائص الإحصائية للسلسلة بشكل كامل من خلال دالة الاحتمال التراكمي. فإذا كان توزيع الاحتمال التراكمي المشترك $F(y_{t+1}, \dots, y_{t+m})$ لأي مجموعة جزئية مكونة من m من المتغيرات المتتالية من المتغيرات التي تتكون منها السلسلة الزمنية ثابت ولا يتأثر بالإزاحة إلى الأمام أو إلى الخلف فإنه يقال أن السلسلة ساكنة سكوناً تاماً أو قوياً. إلا أنه في أغلب الحالات يكون معرفة دالة الاحتمال التراكمي المشترك أو على الأقل تقديرها يعد من الأمور شديدة الصعوبة، وحيث أنه في مجال السلاسل الزمنية نجد أن العزوم الأولى والثانية غالباً ما تعكس الملامح الأساسية للعملية العشوائية التي يفترض أنها خطية والتي تتولد عنها قيم السلسلة، فإن هذه المؤشرات تكون كافية لتوصيف خصائص التوزيع الاحتمالي للعملية العشوائية خاصة إذا افترضنا أنها عملية جاوس. ولذلك يفرق الإحصائيون بين نوعين من السكون؛ السكون التام (أو القوي) والسكون الضعيف. وهكذا تكون السلسلة الزمنية ساكنة سكوناً ضعيفاً؛ ويسمى أحياناً السكون في الوسط الحسابي والتباين وأيضاً سكون التباين، إذا توافرت بالسلسلة الزمنية ثلاث شروط نذكرها فيما يلي. يتمثل أول شروط السكون في ثبات قيمة الوسط الحسابي للسلسلة وعدم تغيره مع الزمن؛ فإذا كان هناك اتجاهًا واضحاً نحو التزايد أو التناقص مع الزمن فإن هذا يعني أن الاتجاه العام هو أحد مكونات هذه السلسلة. ويمكن التعبير احصائياً عن هذا الشرط في الصورة التالية:

$$E(y_t) = \mu , \quad t = 1, 2, \dots, n$$

ويمكن عادة تحويل السلسلة الزمنية غير الساكنة في الوسط إلى سلسلة زمنية ساكنة عن طريق أخذ الفروق المتتالية للملاحظات "differencing the data"؛ ويتم ذلك عن طريق طرح قيم مشاهدات السلسلة من بعضها البعض في ترتيب زمني محدد.

ويتمثل الشرط الثاني للسكون في ثبات التباين؛ ويعبر التباين عن درجة التشتت حول الوسط الحسابي الذي يفترض ثباته فالتباين بالتالي يعطينا مقياساً لعدم التأكد حول هذا الوسط الحسابي. ويمكن التعبير عن شرط ثبات التباين كما يلي:

$$Var(y_t) = E[(Y_t - \mu)^2] = \sigma^2$$

ولتثبيت التباين فإنه يتم تحويل البيانات باستخدام العديد من الطرق؛ وتعتبر التحويلة اللوغاريتمية وتحويلة الجذر التربيعي من أكثر التحويلات استخداماً في هذا الشأن.

أما الشرط الثالث والأخير للسكون فهو خاص بالتغاير؛ فينبغي لكي تكون السلسلة ساكنة ان يكون التغاير بين أي متغيرين y_t ، y_L يعتمد فقط على الفجوة الزمنية lag التي تفصل بينهما بغض النظر عن موقع المتغيرين في السلسلة. يمكن توضيح نفس هذا الشرط في السكون باستخدام الارتباط الذاتي Autocorrelation والذي يعبر عن الارتباط بين المشاهدات عند فترات زمنية مختلفة، كالارتباط بين المشاهدة في الفترة الزمنية t والمشاهدة في الفترة الزمنية L على سبيل المثال. حيث يشترط الا يعتمد أي معامل ارتباط ذاتي على جزء السلسلة الذي استخدم في حسابه. ويتم التعبير عن هذا الشرط في السكون كما يلي:

$$E[(Y_t - \mu)(Y_L - \mu)]/\sigma^2 = \rho_{t-L}$$

(٢-١-٢) نماذج بوكس وجينكنز:

بعد أن يتم الحصول على السلسلة الزمنية الساكنة فإنه يتعين أن نحدد شكل النموذج الذي يوصف خصائص السلسلة المشاهدة بشكل جيد. وتعتمد منهجية بوكس وجينكنز في هذا الصدد على مقارنة معاملات الارتباط الذاتي (ACF) ومعاملات الارتباط الذاتي الجزئي (PACF) لبيانات السلسلة الزمنية بتلك التوزيعات النظرية للنماذج ذات الرتب المختلفة. وفيما يلي نستعرض نماذج بوكس وجينكنز المختلفة (Montgomery et al., 2008).

Autoregressive AR(P)

أولاً: نماذج الانحدار الذاتي Models:

وتأخذ هذه النماذج الشكل التالي:

$$\tilde{y}_t = \phi_1 \tilde{y}_{t-1} + \dots + \phi_p \tilde{y}_{t-p} + \varepsilon_t \quad (٢-١)$$

حيث $\tilde{y}_t = y_t - \mu$ تشير الى الانحرافات عن الوسط الحسابي للسلسلة، وتشير

إلى قيم المتغير في الفترات الزمنية السابقة. أما ϕ_1, \dots, ϕ_p فهي عبارة عن معاملات الانحدار الذاتي. وتمثل ε_t عملية متغيرات عشوائية بحتة white noise process والتي تتكون من سلسلة من المتغيرات العشوائية غير المرتبطة ببعضها البعض ومتوسطها يساوي الصفر وتباينها هو مقدار ثابت يساوي σ_ε^2 .

Moving- Average Models: MA(q)

ثانياً: نماذج المتوسطات المتحركة

وتأخذ هذه النماذج الشكل التالي:

$$\tilde{y}_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (٢-٢)$$

حيث $\theta_1, \theta_2, \dots, \theta_q$ تمثل مجموعه محددة من الأوزان التي يجب أن تحقق شرط

الانعكاس.

ثالثاً: نماذج الانحدار الذاتي والمتوسطات المتحركة المختلطة

Mixed Autoregressive- Moving Average Models: ARMA (p,q)

وتأخذ هذه النماذج في صورتها العامة الشكل التالي:

$$\tilde{Y}_t = \phi_1 \tilde{Y}_{t-1} + \phi_2 \tilde{Y}_{t-2} + \dots + \phi_p \tilde{Y}_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} \dots - \theta_q \varepsilon_{t-q} \quad (2-3)$$

ويمكننا بالاعتماد على دراسة سلوك معاملات الارتباط الذاتي ومعاملات الارتباط الذاتي الجزئي تحديد النموذج المناسب للبيانات. فإذا كانت معاملات الارتباط الذاتي تتضاءل ببطء وبشكل أسي نحو الصفر بينما تسقط معاملات الارتباط الذاتي الجزئي مباشرة نحو الصفر بعد عدد معين من الفجوات فعندئذ يكون نموذج AR مناسباً، أما إذا كانت معاملات الارتباط الذاتي الجزئي تتضاءل ببطء وبشكل أسي بينما تسقط معاملات الارتباط الذاتي مباشرة نحو الصفر بعد عدد معين من الفجوات فهذا يشير إلى نموذج MA . وأخيراً إذا كان كلا من معاملات الارتباط الذاتي ومعاملات الارتباط الذاتي الجزئي يتضاءل تدريجياً وبشكل أسي فإن هذا يشير إلى نموذج ARMA الذي يحتوي على حدود MA وأخرى AR. ويتم عن طريق حساب عدد معاملات الارتباط الذاتي ومعاملات الارتباط الذاتي الجزئي التي تختلف معنوياً عن الصفر تحديد نوع النموذج ودرجته.

رابعاً: نماذج الانحدار الذاتي والمتوسطات المتحركة التكاملية

Autoregressive integrated Moving Average Models: ARIMA (p,d,q)

يمكن استخدام نماذج AR أو MA أو ARMA التي تم مناقشتها فيما سبق لتوصيف النموذج المناسب لسلسلة الفروق التي نحصل عليها عند تحويل السلاسل الزمنية غير الساكنة إلى سلاسل زمنية ساكنة باستخدام تحويلة الفروق، ويكون النموذج هو ARIMA (p,d,q) .

ويأخذ هذا النموذج في صورته العامة الشكل التالي:

$$\tilde{W}_t = \phi_1 \tilde{W}_{t-1} + \phi_2 \tilde{W}_{t-2} + \dots + \phi_p \tilde{W}_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} \dots - \theta_q \varepsilon_{t-q} \quad (2-4)$$

حيث $\tilde{W}_t = w_t - \mu_w$ وترمز w_t إلى سلسلة الفروق من الدرجة d ؛ $w_t = \nabla^d y_t$.

على الرغم من أهمية فحص الشكل البياني لدوال الارتباط الذاتي ودوال الارتباط الذاتي الجزئي كمؤشر مبدئي يمكننا من التعرف على نوع النموذج المناسب ودرجته، إلا أنه تجدر الإشارة إلى وجود معايير أخرى يمكن استخدامها كذلك في التعرف على نوع النموذج المناسب ودرجته ونذكر منها ما يلي:

(١) خرائط تباين البواقي: Residual Variance Plots

وتتلخص فكرة خرائط تباين البواقي في أنه إذا كانت درجة النموذج المقدر أصغر من الدرجة الحقيقية التي يجب أن يكون عليها فإننا نتوقع أن يكون التقدير غير المتحيز لتباين البواقي أكبر من تباين البواقي الحقيقي حيث أننا في هذه الحالة نكون قد حذفنا من النموذج عدد من الحدود كان من الممكن أن تساهم في تفسير

جزء أكبر في تباين y_t . ويتم رسم $\hat{\sigma}_\varepsilon^2$ مع درجات مختلفة للنموذج لنحصل على منحني يتناقص في البداية حتى يثبت عند النقطة التي تناظر الدرجة الحقيقية للنموذج.

(٢) معيار أكايكي للمعلومات Akaike's Information Criterion (AIC)

بافتراض أن نموذج معين يحتوي على m معلمه مستقلة فإن المعيار AIC يعرف كالتالي:

$$AIC(m) = n \log \hat{\sigma}_\varepsilon^2 + 2m \quad (2-5)$$

حيث: n عدد مشاهدات السلسلة الزمنية مطروحاً منها عدد معاملات الانحدار الذاتي، وترمز $\hat{\sigma}_\varepsilon^2$ الى تقدير الإمكان الأعظم لتباين البواقي. وترمز m عدد المعالم في النموذج. وفي حالة نموذج ARMA فإن:

$$m = (\text{عدد معاملات الانحدار الذاتي} + \text{عدد معاملات المتوسطات المتحركة}) + 1$$

(٣) معيار بيبز للمعلومات Bayesian information Criterion (BIC)

يأخذ معيار بيبز للمعلومات لنموذج يحتوي على عدد m من المعالم الشكل التالي:

$$BIC(m) = n \log \hat{\sigma}_\varepsilon^2 - (n - m) \log \left(1 - \frac{m}{n}\right) + m \log n \quad m^{-1} \left(\frac{\hat{\sigma}_y^2}{\hat{\sigma}_\varepsilon^2} - 1\right) \quad (2-6)$$

حيث ترمز $\hat{\sigma}_\varepsilon^2$ لتقدير الامكان الأعظم لتباين البواقي وهذا التقدير قائم على أساس نموذج له m معلمة بينما ترمز $\hat{\sigma}_y^2$ للتباين المحسوب لعينة المشاهدات.

وتكون الدرجة المناسبة للنموذج هي قيمة m التي عندها يصل $BIC(m)$ و $AIC(m)$ لحدده الأدنى.

(٢-٢) تقدير النموذج Model Estimation

بعد الانتهاء من مرحلة توصيف النموذج تكون الخطوة التالية هي الحصول على تقديرات لمعالم النموذج.

وبافتراض توصيف نموذج $ARIMA(p, d, q)$ الذي يأخذ الشكل العام التالي:

$$\phi(B) \nabla^d Y_t = \theta(B) \varepsilon_t \quad (2,7)$$

$$\phi(B) W_t = \theta(B) \varepsilon_t$$

تعد طريقة المربعات الصغرى وطريقة الإمكان الأعظم طريقتين أساسيتين في مرحلة تقدير النموذج. وفيما يلي سوف نعرض طريقة المربعات الصغرى التي تعتبر تقريبا جيداً لطريقة الإمكان الأعظم في ظل افتراض أن حدود الخطأ تمثل سلسلة متغيرات عشوائية بحتة بمعنى أن حدود الخطأ تكون مستقلة عن بعضها البعض وتتبع التوزيع الطبيعي بمتوسط صفر وتباين σ_ε^2 .

ويتم طبقاً لطريقة المربعات الصغرى اختيار قيم المعالم بحيث تجعل مجموع مربعات الخطأ ε_t أقل ما يمكن. وتتكون قيم ε_t من الفرق بين قيم السلسلة الزمنية الفعلية $W_t = \nabla^d Y_t$ وقيم السلسلة الزمنية المقدرة \hat{W}_t . أي أنه يتم اختيار قيم المعالم بحيث تجعل $S(\phi, \theta) = \sum \varepsilon_t^2$ أقل ما يمكن.

ولحساب قيم ε_t فإنه يمكن إعادة كتابة المعادلة (٢,٧) على الشكل التالي:

$$\varepsilon_t = W_t - \phi_1 W_{t-1} - \dots - \phi_p W_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \quad (٢,٨)$$

و يتم استخدام طريقة التقدير غير الخطية عند حساب قيم ε_t و تدنية $\sum \varepsilon_t^2$ حيث يكون النموذج (٢,٨) بصفة عامة غير خطي في المعالم خاصة في حالة وجود حدود متوسطات متحركة.

كما يلزم الحصول على قيم بداية Starting Values للبيانات (W_{-p+1}, \dots, W_0) ونرمز لها W^* والأخطاء $(\varepsilon_{-q+1}, \dots, \varepsilon_{-1}, \varepsilon_0)$ ونرمز لها ε^* حتى يمكن استخدام المعادلة (٢,٨) في حساب قيم $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$. وبناءً على هذا فإنه لأي اختيار مفترض للمعالم (ϕ, θ) وقيم البداية (W^*, ε^*) نستطيع أن نحسب القيم ε_t المشروطة بقيم كل من $(\phi, \theta / W^*, \varepsilon^*, W)$ ومن ثم حساب مجموع المربعات الشرطي حيث:

$$S^*(\phi, \theta) = \sum_1^n \varepsilon_t^2 \quad (٢,٩)$$

(٣-٢) إجراء الفحوص التشخيصية للنموذج Diagnostic Checking

يتم في هذه المرحلة إجراء بعض الاختبارات على النموذج المقدر للتأكد من أنه مناسب احصائياً. وتعطي هذه المرحلة الإرشادات الجوهرية حول كيفية إعادة صياغة النموذج غير المناسب للوصول الى النموذج البديل الأكثر ملاءمة. وتتمثل أهم الاختبارات التشخيصية التي يمكن أن تجري على نماذج السلاسل الزمنية فيما يلي:

(١) **فحص معالم النموذج:** من أهم الاختبارات التي تستخدم في فحص النموذج هي اختبارات فحص مدى ثبات قيم المعالم، فقد يكون النموذج غير ملائم نتيجة التغير في قيم معالمه مع الزمن. كذلك يجب أن يتم فحص مدى ملاءمة النموذج الموفق بالتعرف على المعالم غير الضرورية، إن وجدت، أو إضافة معالم جديدة الى النموذج إذا كان هناك حاجة الى ذلك. وأخيراً فإن فحص معاملات الارتباط بين مقدرات المعالم يعتبر ضرورياً لتحديد المعلمة التي يجب حذفها من النموذج. فإذا لوحظ كبر القيمة المطلقة لمعامل الارتباط بين أي مقدرين من مقدرات معالم النموذج فإن هذا يعني إمكانية حذف أحدهما دون أن يؤثر ذلك على ملاءمة النموذج.

(٢) **تحليل البواقي:** وهو يعتبر من أهم وأبسط اختبارات فحص النماذج. فإذا كان النموذج المقدر يمثل فعلياً العملية العشوائية التي تتولد وفقاً لها بيانات السلسلة فإن حدود الخطأ لهذا النموذج يجب أن تكون متغيرات عشوائية بحتة White noise متوسطها الصفر وتباينها ثابت كما أنها تكون غير مرتبطة ببعضها ذاتياً. ويتم تحليل البواقي بواسطة دالة الارتباط الذاتي للبواقي The Residual ACF والتي يتم حسابها كما يلي:

$$r_k(\hat{\varepsilon}) = \frac{\sum_{t=1}^{n-k} (\hat{\varepsilon}_t \hat{\varepsilon}_{t+k})}{\sum_{t=1}^n \hat{\varepsilon}_t^2} \quad (٢,١٠)$$

فإذا كانت البواقي من النموذج المقدر تمثل بالفعل متغيرات عشوائية بحيث فسنجد أن دالة الارتباط الذاتي لها لا تحتوي على أي نتوءات كبيرة، كما يجب ألا تختلف قيم معاملات الارتباط الذاتي للبواقي إحصائياً عن الصفر.

(٢-٤) التنبؤ Forecasting

يتم حساب التنبؤ بحيث يكون متوسط مربعات خطأ التنبؤ أقل ما يمكن:

$$E[e_T^2(L)] = \left[(Y_{T+L} - \hat{Y}_T(L))^2 \right] \quad (٢,١١)$$

حيث يتم الحصول على التنبؤ بأخذ التوقع الشرطي لـ Y_{T+L} :

$$\hat{Y}_T(L) = E \left[Y_{T+L} \mid Y_T, Y_{T-1}, \dots, Y_1 \right] \quad (٢,١٢)$$

يتم الحصول على التنبؤات $\hat{Y}_T(L)$ و $L \geq 1$ بشكل تكراري recursively باستخدام النموذج المقدر بحيث يتم أولاً حساب التنبؤ لفترة واحدة للأمام ثم باستخدام هذا التنبؤ يتم حساب التنبؤ لفترة الثانية للأمام وهكذا حتى نصل إلى التنبؤ بالفتره L للأمام.

ولتوضيح طريقة حساب التنبؤات وبفرض نموذج ARIMA:

$$\phi(B)W_t = \theta(B)\varepsilon_t \quad (٢,١٣)$$

$$W_t = \sum^d W_t \quad \text{ومنها} \quad W_t = \nabla^d Y_t \quad \text{حيث:}$$

وبإعادة كتابة المعادلة (٢,١٣) في الصورة التفصيلية كما يلي:

$$W_t = \phi_1 W_{t-1} + \dots + \phi_p W_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} + \delta \dots \quad (٢,١٤)$$

فانه لحساب التنبؤ $\hat{Y}_T(L)$ يجب أن نبدأ بحساب التنبؤ لفترة واحدة للأمام $\hat{W}_T(1)$ كما يلي:

$$\hat{W}_T(1) = E \left[Y_{T+1} \mid Y_T, \dots, Y_1 \right] = \phi_1 W_T + \dots + \phi_p W_{T-p+1} - \theta_1 \hat{\varepsilon}_T - \dots - \theta_q \hat{\varepsilon}_{T-q+1} + \delta \quad (2.15)$$

حيث $\hat{\varepsilon}_T$ ، $\hat{\varepsilon}_{T-1}$ ، ... عبارة عن قيم البواقي المشاهدة، مع ملاحظة أن القيمة المتوقعة للخطأ ε_{T+1} تساوى الصفر. باستخدام التنبؤ لفترة واحدة للأمام $\hat{W}_T(1)$ نستطيع أن نحصل على التنبؤ لفترة الثانية للأمام $\hat{W}_T(2)$:

$$\hat{W}_T(2) = E \left[Y_{T+2} \mid Y_T, \dots, Y_1 \right] = \phi_1 \hat{W}_T + \phi_2 W_T + \dots + \phi_p W_{T-p+2} - \theta_2 \hat{\varepsilon}_T - \dots - \theta_q \hat{\varepsilon}_{T-q+2} + \delta \quad (2.16)$$

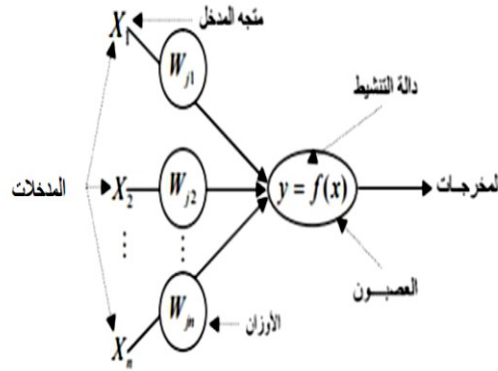
ثم باستخدام التنبؤ لفترة الثانية للأمام نستطيع أن نحصل على التنبؤ لفترة الثالثة للأمام وهكذا. وبعد الحصول على التنبؤ لسلسلة الفروق W_t ، فإن التنبؤ بالسلسلة Y_t يمكن الحصول عليه بتطبيق عملية الجمع عدد d من المرات على السلسلة W_t .

٣- الشبكات العصبية الاصطناعية (ANN) Artificial Neural Networks

أخذت نماذج الشبكات العصبية الاصطناعية مكانة مميزة في التطبيقات المختلفة وفي العديد من المجالات كأحد أهم أساليب التنبؤ. ومما زاد من استخدام الشبكات العصبية بشكل واسع في مجال التنبؤ؛ انها تحتاج إلى وضع القليل من الفروض وكذلك تحتاج الى عدد أقل من المشاهدات مقارنة ببعض الطرق الأخرى كالسلاسل الزمنية بأسلوب بوكس وجينكنز (Wallace, 2008). وتدور فكرة الشبكات العصبية حول محاكاة العقل البشري باستخدام الحاسب الآلي حيث يتم إنشاء نموذج معلومات يحاكي النظام العصبي للإنسان؛ وتتم المحاكاة من خلال اتباع عمليات التعلم الذاتي التي تعتمد على الخبرات المختزنة في الشبكة لتحقيق أفضل نتائج (Rojas, 1996). وسوف نتعرض فيما يلي للمكونات الأساسية للشبكات العصبية الاصطناعية والصياغة الرياضية لها وأنواعها.

(١-٣) المكونات الأساسية للشبكات العصبية الاصطناعية:

تتكون الشبكة العصبية الاصطناعية من ثلاث مكونات رئيسية. يتمثل المكون الأول في طبقة المدخلات التي تتكون من وحدات الإدخال. ويتمثل المكون الثاني في طبقة المعالجة التي تتكون من وحدات المعالجة التي تتم فيها العمليات الحسابية. وأخيراً يوجد طبقة المخرجات التي تقوم بإخراج نتائج الشبكة. وبين كل طبقة من هذه الطبقات هناك عدداً من الوصلات البينية التي تربط كل طبقة بالطبقة التي تليها ويتم في وحدات المعالجة ضبط الأوزان الخاصة بكل وصلة بينية وهي التي نحصل عن طريقها على ردة الفعل لكل مدخل من المدخلات للشبكة. وتحتوي الشبكة على طبقة واحدة فقط من وحدات الإدخال، لكنها قد تحتوي على أكثر من طبقة من طبقات المعالجة. ويمكن توضيح مكونات الشبكة العصبية الاصطناعية كما في الشكل التالي:



شكل (3-1): مكونات الشبكة العصبية الاصطناعية

ويمكن اختصار العمليات الرياضية التي تتم داخل العصبون بالمعادلة الآتية:

$$y_k = f(\sum w_{kj} x_j + b_k) \quad \dots \dots \dots (3.1)$$

حيث: x_1, x_2, \dots, x_n تمثل إشارات المدخل، wk_1, wk_2, \dots, wk_n تمثل الأوزان للعصبون. K وتسمى $\sum w_{kj} x_j + b_k$ تابع عملية الجمع، أما فتمثل التحيز الذي يمكن اعتباره على أنه أحد الأوزان W . ومدخله $X_0=1$. أما عن دوال التنشيط (التحويل) في العصبون فيوجد العديد من أشكال دوال التنشيط حيث تصلح كل دالة لنوع معين من التطبيقات وتقوم كل منها بوظائف مختلفة. ومن أهم دوال التنشيط نجد دالة السيجمويد Sigmoid ويوجد نوعين من هذه الدالة؛ النوع الأول يعمل على جعل قيم المخرجات داخل الفترة (٠,١) أما النوع الثاني ويُعرف بدالة تنشيط سيجمويد ثنائي القطبية ويعمل على جعل قيم المخرجات داخل الفترة (-1,1). وتعد هذه الدالة من أهم دوال التنشيط المستخدمة في الشبكات العصبية الاصطناعية، كما توجد دالة الإشارة والدالة الخطية (رياض، ٢٠١٧).

(٢-٣) التركيب المعماري للشبكات العصبية الاصطناعية


تتألف الشبكة العصبية من عدد من العصبونات المرتبطة داخليا فيما بينها. وتحدد نوع الشبكة بناء على نوعية الارتباط بين العصبونات المكونة للشبكة بالإضافة الى طبيعة هذه العصبونات. ويقصد بالتركيب المعماري للشبكة العصبية الطريقة التي ترتبط بها وحدات المعالجة مع بعضها البعض داخل كل طبقة أو بين الطبقات المختلفة في الشبكة. ويمكن تصنيف التركيب المعماري للشبكة العصبية وفقاً لكل من عدد الطبقات التي تتكون منها الشبكة وطبيعة انتشار البيانات خلال الشبكة (Maciel and Ballini, 2008) و (Dietrich, 2005).

أولاً: تصنيف الشبكات العصبية الاصطناعية وفقاً لعدد الطبقات

يمكن تصنيف الشبكات العصبية الاصطناعية وفقاً لعدد الطبقات التي تتضمنها إلى شبكات وحيدة الطبقة و شبكات متعددة الطبقات، وفيما يلي توضيح مبسط لكل منها.

الشبكات وحيدة الطبقة Single Layer Network

وهي من أبسط أنواع الشبكات العصبية وتتألف من طبقة واحدة من عناصر المعالجة. ترتبط مدخلات الشبكة في هذا النوع بشكل مباشر مع مخرجاتها، حيث يتم إجراء كل الحسابات في طبقة المخرجات. ويوضح الشكل (3-2) التالي تركيب الشبكة العصبية وحيدة الطبقة.




شكل (3-2): تركيب الشبكة العصبية وحيدة الطبقة

● الشبكات متعددة الطبقات Multilayer Network

يتركب هذا النوع من الشبكات من أكثر من طبقة من عناصر المعالجة التي تربط بينها الوصلات البينية والتي تسمى الأوزان. حيث تتكون الشبكة متعددة الطبقات على الأقل من طبقتين طبقة لاستقبال المدخلات، وهي غير محسوبة في عدد الطبقات، وطبقة المخرجات، وبين طبقة المدخلات وطبقة المخرجات توجد طبقة مخفية. ويمكن أن تحتوي الشبكة على أكثر من طبقة مخفية، ويتوقف ذلك على نوع التطبيق المستخدم في الشبكة،

ويوضح الشكل (3-3) التالي تركيب الشبكة العصبية متعددة الطبقات:



شكل (3-3): تركيب الشبكة العصبية متعددة الطبقات

ثانياً: تصنيف الشبكات العصبية وفقاً لطبيعة انتشار البيانات عبر طبقاتها


يمكن تصنيف الشبكات العصبية وفقاً لطبيعة انتشار البيانات عبر طبقات وحداتها وترابطها إلى شبكات التغذية المتقدمة أو الأمامية وشبكات التغذية الراجعة أو خلفية التغذية.

● شبكات التغذية المتقدمة (أمامية التغذية) Feed Forward Network

في هذا النوع من الشبكات العصبية يتم استقبال المدخلات من الأمام وتبث المخرجات الي الخلف أي في نفس الاتجاه. ومن ثم تكون الشبكة العصبية أمامية التغذية إذا كان اتجاه الإشارات من طبقة المدخلات في اتجاه طبقة المخرجات وليس العكس مع عدم وجود اتصال بين عناصر الطبقة الواحدة.

● شبكات التغذية الراجعة (خلفية التغذية) Feed Back Network

ويأخذ هذا النوع من الشبكات العصبية شكل الشبكة متعددة الطبقات، حيث يحتوي على الأقل على حلقة تغذية خلفية واحدة. فمخرجات أحد العصبونات اما أن تعود لتمثل مدخلات لنفس العصبون فيما يسمى بالتغذية الخلفية الذاتية أو أن تكون مدخلات لعصبون آخر. ويمكن توضيح هذا النوع كما في الشكل التالي.



شكل (3-4): الشبكات العصبونية خلفية التغذية

(٣-٣) التعلم في الشبكات العصبية الاصطناعية

ان الخاصية المميزة للشبكات العصبية الاصطناعية هي مقدرتها على التعلم من بيئتها وتحسين أدائها من خلال التدريب. ويهدف التعلم في الشبكات العصبية إلى تحديد قيمة الأوزان المرجحة من خلال تدريب الشبكة والذي يمكن أن يتم بإحدى طرق ثلاث؛ التعلم المراقب والتعلم غير المراقب والتعلم بإعادة التدعيم.

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

٢- التعلم غير المراقب: ويسمى أيضاً التعلم الذاتي، حيث تقوم أساليب التعلم هنا على أساس قدرة الشبكة على اكتشاف الملامح المميزة لهيكل المدخلات من خلال مجموعة البيانات المتاحة ومن ثم يتم تعميم هذه الملامح المميزة على المخرجات. بمعنى أن للشبكات العصبية هنا القدرة على التنظيم الذاتي لأوزان ترابطاتها طبقاً لطبيعة ما يعرض عليها من أنماط.


٣- التعلم بإعادة التدعيم: تقوم عملية التدعيم على أساس الخلط بين طريقة التعلم المراقب والتعلم غير المراقب. حيث لا يفصح للشبكة العصبية الاصطناعية عن القيم الحقيقية للمخرجات كما هو الحال في التعلم غير المراقب، ولكن يشار إلى الشبكة بصحة نتائجها أو خطئها كما في طريقة التعلم المراقب. التعلم بإعادة التدعيم هو تعلم يتم فيه التدريب بدون مراقب، وهو يعد تقييم لنظام التغذية الخلفي حيث يتم تقييم سلوك النظام.

٤- الدراسة التطبيقية

تم في هذه الدراسة الاعتماد على بيانات سلسلة زمنية يومية لسعر صرف الجنيه المصري في مقابل اليورو مكونة من ٩٧١ مشاهدة تغطي الفترة من ٢٠٢٠/١/١ وحتى ٢٠٢٣/٩/٢٠. وقد كانت الفترة من ٢٠٢٠/١/١ إلى ٢٠٢٣/٨/٢٢ وتتكون من ٩٥٠ مشاهدة هي فترة التقدير للنماذج المختلفة المقترحة، أما الفترة من ٢٠٢٣/٨/٢٣ إلى ٢٠٢٣/٩/٢٠ فهي فترة التنبؤ وتتكون من ٢١ مفردة. وتجدر هنا الإشارة إلى أن أسبوع العمل في البنوك يتكون من خمسة أيام.

٤-١ استخدام منهجية بوكس وجينكنز في تحليل السلاسل الزمنية:


تتمثل الخطوة الأولى في التعرف على النموذج وفقاً لمنهجية بوكس وجينكنز في تحديد ما إذا كانت السلسلة الزمنية ساكنة أم لا. ويساعدنا في ذلك فحص الرسم البياني للسلسلة الزمنية؛ ويظهر شكل (4-1) الرسم البياني للسلسلة الزمنية الخاصة بسعر صرف الجنيه المصري مقابل اليورو.



شكل (4-1)

رسم السلسلة الزمنية الأصلية (الجنيه مقابل اليورو) باستخدام الخط البياني

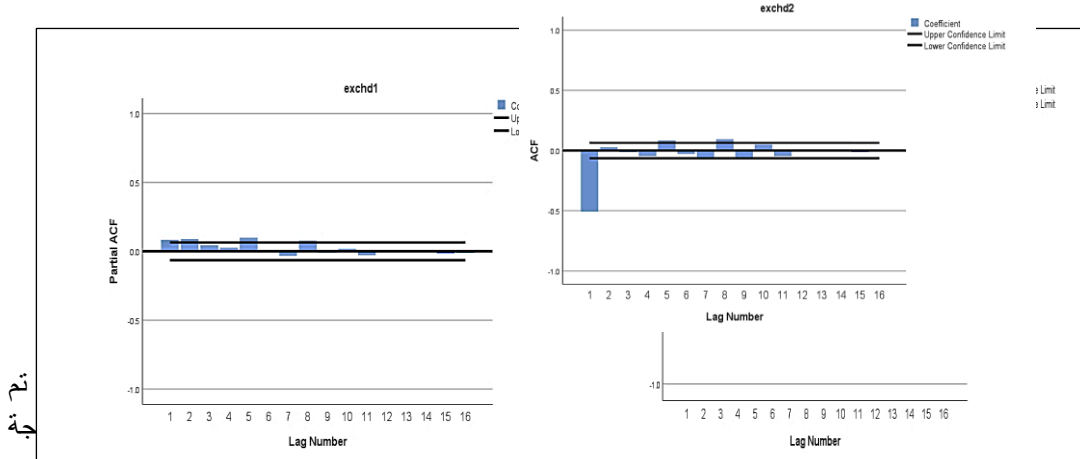
يتبين من شكل (4-1) عدم سكون السلسلة الزمنية في الوسط حيث يوجد اتجاه عام واضح بها، كما يلاحظ ثبات التباينات ومن ثم عدم الحاجة إلى تحويل البيانات. وبهدف الوصول إلى حالة السكون تم أخذ الفروق المتتالية من الدرجة الأولى. ويوضح شكل (4-2) التالي رسم الخط البياني لسلسلة الفروق من الدرجة الأولى، ويتبين عدم وجود أي اتجاه عام واضح بهذه السلسلة.



شكل (4-2)

رسم سلسلة الفروق من الدرجة الأولى للبيانات باستخدام الخط البياني

ويوضح شكل (4-3) معاملات الارتباط الذاتي ومعاملات الارتباط الذاتي الجزئي لسلسلة الفروق من الدرجة الأولى، ويلاحظ أن كلاً من معاملات الارتباط الذاتي ومعاملات الارتباط الذاتي الجزئي تنخفض بالتدرج متجهة ناحية الصفر مما يرجح أن يكون النموذج مختلط ARIMA (p,d,q) مناسباً لتوصيف البيانات.




الثانية للبيانات:

Date. Format: "DDDD"

شكل (4-3)


معاملات الارتباط الذاتي ومعاملات الارتباط الذاتي الجزئي لسلسلة الفروق من الدرجة الأولى كذلك تم أخذ الفروق من الدرجة الثانية للبيانات ويوضح شكل (4-4) رسم الخط البياني لسلسلة الفروق من الدرجة الثانية للبيانات:



شكل (4-4)

رسم سلسلة الفروق من الدرجة الثانية للبيانات باستخدام الخط البياني

ويوضح شكل (4-5) التالي معاملات الارتباط الذاتي ومعاملات الارتباط الذاتي الجزئي لسلسلة الفروق من الدرجة الثانية للبيانات:



شكل (4-5)

معاملات الارتباط الذاتي ومعاملات الارتباط الذاتي الجزئي لسلسلة الفروق من الدرجة الثانية للبيانات ولتحديد درجة النموذج المناسب تم تقدير واختبار عدد من النماذج وهي:

$$ARIMA(1,1,1), ARIMA(0,2,1), ARIMA(1,2,1)$$

يوضح جدول (4-1) قيم بعض المعايير التي تم حسابها لجميع نماذج بوكس - جينكنز المقترحة بهدف اختيار النموذج الأنسب الذي يمكن الاعتماد عليه في التنبؤ. مع ملاحظة أن المعايير بالجدول أدناه تم حسابها بالاعتماد على المشاهدات المستخدمة في تقدير النماذج وعددها ٩٥٠ مشاهدة.

جدول (4-1) قيم بعض المعايير المحسوبة للمفاضلة بين نماذج بوكس - جينكنز الثلاث المقترحة

Model Statistics							
Model	Model Fit statistics				Ljung-Box Q(18)		
	RMSE	MAPE	MAE	Normalized BIC	Statistics	DF	Sig.
ARIMA(1,1,1)	.20٦	.469	.102	-3.157	٢4.328	16	.574
ARIMA(0,2,1)	.205	.466	.102	-3.164	26.058	17	.073
ARIMA(1,2,1)	.20٥	.469	.102	-3.146	23.217	16	.108

وعلى الرغم من تقارب قيم المعايير RMSE و MAPE و MAE إلا أن النموذج ARIMA (1,2,1) هو الأفضل من حيث قيم المعايير BIC و Ljung-Box ولذلك فقد تم الاستقرار على استخدام النموذج ARIMA (1,2,1) في مرحلة التنبؤ.

٤-٢ استخدام الشبكات العصبية:

تتكون الشبكة العصبية المستخدمة في التنبؤ بسعر صرف الجنيه المصري مقابل اليورو من ثلاث طبقات. الطبقة الأولى وهي طبقة المدخلات وقد بدأنا التحليل بتضمينها القيمتين السابقتين لسعر صرف الجنيه المصري مقابل اليورو وسنرمز لهما y_{t-1} و y_{t-2} . الطبقة الثانية وهي الطبقة المخفية وتتكون من نيورون واحد، ثم الطبقة الثالثة والأخيرة وهي طبقة المخرجات وتتمثل في القيمة الحالية لسعر صرف الجنيه المصري مقابل اليورو عند الزمن t . إلا أنه عند تدريب الشبكة تبين عدم وجود أهمية للمتغير y_{t-2} كمتغير تفسيري في طبقة المدخلات حيث لم تتجاوز أهميته ١٠٪، لذا تم إعادة تدريب الشبكة مع الاقتصار على المتغير y_{t-1} في طبقة المدخلات. يتم تدريب الشبكة عدد كبير من المرات حتى يتم الحصول على أقل خطأ ممكن. وقد تم تقسيم المشاهدات المستخدمة في توفيق النموذج وعددها ٩٥٠ مشاهدة بنسبة ٧٠٪ منها لتدريب الشبكة و ٣٠٪ في اختبارها. ويوضح جدول (4-2) تقديرات المعالم لهذا النموذج:

جدول (4-2) تقديرات المعالم لنموذج الشبكات العصبية

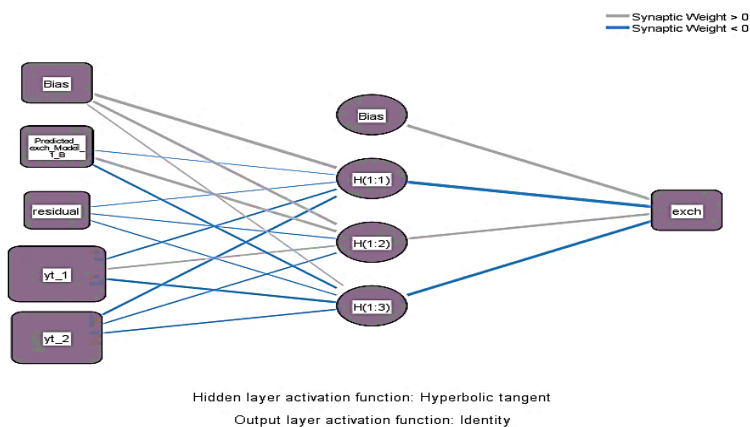
		Predicted	
		Hidden Layer 1	Output Layer
Predictor		H(1:1)	exch
Input Layer	(Bias)	.252	
	y_{t-1}	-.440	
Hidden Layer 1	(Bias)		.609
	H(1:1)		-2.530

٤-٣ الجمع بين الشبكات العصبية وتحليل السلاسل الزمنية بمنهجية بوكس - جينكنز:

تعددت طرق الجمع بين الشبكات العصبية وتحليل السلاسل الزمنية (Jiuran and Bingfeng, 2013) و (Khashei and Bijari, 2010) و (Tsenga et al., 2002) و (Wang and Leu, 1996) وفيما يلي يتم تقدير ثلاث نماذج تجمع بين الأسلوبين والمقارنة بين التنبؤات التي يتم الحصول عليها من هذه النماذج.

٤-٣-١ استخدام القيم المقدرة والبواقي المتحصل عليها من نموذج $ARIMA(1,2,1)$ بالإضافة الى y_{t-1} و y_{t-2} كمدخلات عند بناء الشبكة العصبية (نموذج الجمع الأول):

ويوضح شكل (4-6) البناء الهيكلي لهذا النموذج:



شكل (4-6) البناء الهيكلي لنموذج الجمع الأول


وقد كان تقدير المعالم لهذا النموذج كما هو موضح بالجدول التالي:

جدول (4-3) تقديرات المعالم لنموذج الجمع الأول

Predictor		Predicted			
		Hidden Layer 1			Output Layer
		H(1:1)	H(1:2)	H(1:3)	exch
Input Layer	(Bias)	.699	.462	.144	
	Predicted_exch_Model_1_B	-.005	.474	-.238	
	residual	-.013	-.033	-.089	
	yt_1	-.206	.225	-.365	
	yt_2	-.349	-.144	-.148	
Hidden Layer 1	(Bias)				.640
	H(1:1)				-1.291
	H(1:2)				.411
	H(1:3)				-.537

٢-٣-٤ استخدام القيم المقدرة والبيواقي المتحصل عليها من نموذج $ARIMA(1,2,1)$ كمدخلات عند بناء الشبكة العصبية (نموذج الجمع الثاني):

ويوضح شكل (4-7) البناء الهيكلي لهذا النموذج:



Hidden layer activation function: Hyperbolic tangent

Output layer activation function: Identity

شكل (4-7) البناء الهيكلي لنموذج الجمع الثاني

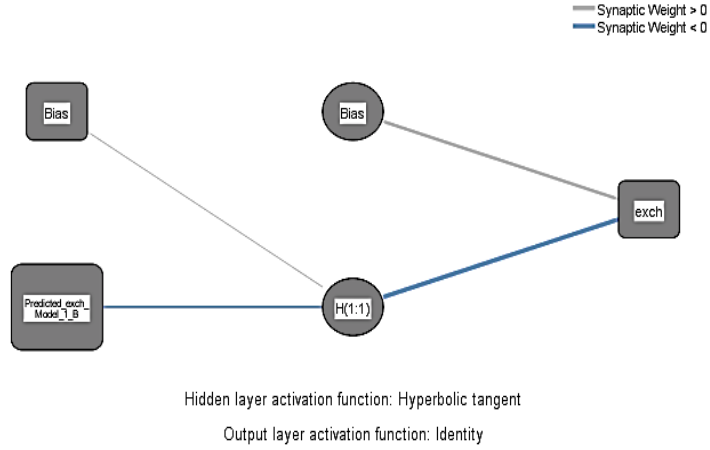
وقد كان تقدير المعالم لهذا النموذج كما هو موضح بالجدول (4-4) التالي:

جدول (4-4) تقديرات المعالم لنموذج الجمع الثاني

Predictor		Predicted	
		Hidden Layer 1	Output Layer
		H(1:1)	exch
Input Layer	(Bias)	.328	
	Predicted_exch_Model_1_B	-.469	
	residual	-.016	
Hidden Layer 1	(Bias)		.725
	H(1:1)		-2.414

4-3-3 استخدام القيم المقدرة المتحصل عليها من نموذج $ARIMA(1,2,1)$ كمدخلات عند بناء الشبكة العصبية (نموذج الجمع الثالث):

ويوضح شكل (4-8) البناء الهيكلي لهذا النموذج:



شكل (4-8) البناء الهيكلي لنموذج الجمع الثالث

وقد كان تقدير المعالم لهذا النموذج كما هو موضح بالجدول (4-5) التالي:

جدول (4-5) تقديرات المعالم لنموذج الجمع الثالث

Predictor		Predicted	
		Hidden Layer 1	Output Layer
		H(1:1)	exch
Input Layer	(Bias)	.228	
	Predicted_exch_Model_1_B	-.391	
Hidden Layer 1	(Bias)		.608
	H(1:1)		-2.788

٤-٤ - المفاضلة بين النماذج المقترحة باستخدام مقاييس دقة التنبؤ:

يوضح جدول (4-6) التنبؤات التي تم الحصول عليها باستخدام النماذج المقترحة:

جدول (4-6) التنبؤات باستخدام النماذج المقترحة

القيم الفعلية	ARIMA(1,2,1)	نموذج الشبكات العصبية	نموذج الدمج الأول	نموذج الدمج الثاني	نموذج الدمج الثالث
33.50	33,45	33.44	33.52	33,40	33,38
33.35	33,45	33.47	33.39	33,29	33,38
33.32	33,45	33.36	33.35	33,27	33,38
33.37	33,46	33.34	33.31	33,31	33,38
33.67	33,46	33.38	33.47	33,52	33,38
33.70	33,46	33.59	33.59	33,54	33,38
33.44	33,46	33.62	33.58	33,36	33,39
33.23	33,46	33.43	33.40	33,21	33,39
33.29	33,47	33.28	33.27	33,25	33,39
33.15	33,47	33.32	33.12	33,15	33,39
33.09	33,47	33.21	33.06	33,11	33,39
33.01	33,47	33.17	32.93	33,04	33,39
33.01	33,48	33.11	32.88	33,04	33,40
33.21	33,48	33.11	32.98	33,20	33,40
33.17	33,48	33.26	33.01	33,17	33,40
33.10	33,48	33.23	33.03	33,11	33,40
32.93	33,49	33.18	32.88	32,99	33,40
32.98	33,49	33.05	32.83	33,02	33,41
32.98	33,49	33.09	32.77	33,02	33,41
32.94	33,49	33.09	32.76	32,99	33,41
33.08	33,49	33.06	32.85	33,10	33,41

وقد تم حساب أهم المعايير الإحصائية المستخدمة لقياس دقة التنبؤ للنماذج المقترحة حيث تم حساب MAPE و MSPE و MSE على النحو التالي:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

$$MSPE = \frac{1}{n} \sum_{i=1}^n \left(\frac{y_i - \hat{y}_i}{y_i} \right)^2$$

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

حيث n هي فترة التنبؤ والتي تتكون من عدد 21 مفردة.

ويوضح جدول (4-7) التالي النماذج والنتائج المتحصل عليها فيما يخص هذه المعايير:

جدول (٧-٤) القيم المحسوبة لمعايير دقة التنبؤ للنماذج المقترحة

The model	MARPE	MSRPE	MSPE
ARIMA(1,2,1)	0.009117117	0.0001088	0.11888
Neural Networks	0.009117117	0.0001088	0.11888
Combined model 1	0.00335671	0.00000160145	0.017638095
Combined model 2	0.001470328	0.00000374669	0.0042048
Combined model 3	0.007616609	0.0000777257	0.085104762

ويلاحظ أن نموذج الدمج الثاني هو أفضل النماذج المقترحة من حيث معايير اختيار النموذج.

5- النتائج والتوصيات:

لا شك أن نجاح السياسات الاقتصادية والمالية يعتمد بالأساس على التخطيط الجيد الذي يقوم على التوقعات السليمة لما ستصير عليه الأوضاع في المستقبل. ومن هنا كانت أهمية اختيار الطرق المناسبة للتنبؤ بالظواهر المختلفة ومحاولة الوصول الى أدق التنبؤات. وفي مجال سعر الصرف اليومي للجنيه المصري في مقابل اليورو - وهو مجال التطبيق في هذه الدراسة - فقد تم التعرض لأساليب مختلفة للتنبؤ وتم تقدير واختبار العديد من النماذج بهدف الوصول الى أفضل نموذج يمكن أن يستخدم للتنبؤ بالقيم المستقبلية لسعر صرف الجنيه المصري مقابل اليورو. ونعرض فيما يلي لأهم النتائج التي توصلت إليها الدراسة، كما نقدم بعض التوصيات التي يمكن أن تفيد في المجالين النظري والتطبيقي.

1- هناك اتجاه عام متزايد مع الزمن في قيم السلسلة المشاهدة لسعر صرف الجنيه المصري مقابل اليورو مما يعني عدم الثبات في الوسط بينما كان هناك ثبات في التباينات، ويراعى عند دراسة التباينات أخذ التوقيتات التي قامت فيها الحكومة بتحرير سعر الصرف في السنوات الأخيرة في الاعتبار.

2- اتضح عند استخدام تحليل السلاسل الزمنية بمنهجية بوكس - جينكنز أن نموذج ARIMA (1,2,1) يعد الأنسب وفقاً لهذا الأسلوب للتنبؤ بسعر صرف الجنيه المصري مقابل اليورو.

3- تؤكد عند استخدام الشبكات العصبية أهمية القيم السابقة للظاهرة بفترة ابطاء واحدة Y_{t-1} في بناء النموذج. وهو ما يتوافق مع ما تم التوصل إليه في تحليل السلاسل الزمنية بمنهجية بوكس - جينكنز أيضاً.

4- تتماثل درجة دقة التنبؤ بسعر صرف الجنيه المصري مقابل اليورو المتحصل عليها عند استخدام تحليل السلاسل الزمنية بمنهجية بوكس - جينكنز واستخدام الشبكات العصبية.

5- لقد تضمن الجمع بين تحليل السلاسل الزمنية بمنهجية بوكس - جينكنز والشبكات العصبية على مميزات كل من الأسلوبين وقد أعطت بالفعل نماذج الجمع المقترحة تنبؤات أفضل من تلك التي تم الحصول عليها من كل من الأسلوبين على حدا.

6- اتضح عند استخدام الجمع بين تحليل السلاسل الزمنية بمنهجية بوكس - جينكنز والشبكات العصبية أن استخدام القيم المقدرة والبقايا المتحصل عليها من نموذج ARIMA (1,2,1) كمدخلات عند بناء الشبكة العصبية (نموذج الجمع الثاني) يعطي النموذج الأفضل للتنبؤ بسعر صرف الجنيه المصري مقابل اليورو.

7- تتعدد أساليب التنبؤ التي يمكن لواضعي السياسات الاقتصادية الاعتماد عليها، وتقدم الدراسة الحالية فيما يتعلق بسعر صرف الجنيه المصري مقابل اليورو نموذجاً للتنبؤ يعطي أدق النتائج يعتمد على الجمع بين تحليل السلاسل الزمنية بمنهجية بوكس - جينكنز والشبكات العصبية. ويمكن تعميم تطبيق أسلوب الجمع المقترح أيضاً في التنبؤ بالظواهر الاقتصادية المختلفة.

المراجع References

أولاً: المراجع العربية

- ١- البلتاجي، يسري (٢٠٢٤) " أثر التطور في استخدام أساليب الشبكات العصبية Neural Network على فعالية البيانات الضخمة Big Data في دعم نظام معلومات المحاسبة الإدارية في ترشيد القرار الإداري - دراسة تجريبية "، مجلة المحاسبة والمراجعة لاتحاد الجامعات العربية، العدد الأول.
- ٢- أبو رغيف، كفاء علي عيسى (٢٠٢١) " التنبؤ بمخاطرة أسعار الصرف باستخدام الشبكة العصبونية دراسة تطبيقية "، مجلة الإدارة والاقتصاد، العدد ١٢٩، الجامعة المستنصرية.
- ٣- الشوافي، جمال احمد وحجاج، عبد الوهاب السيد (٢٠١٣) " الذكاء الاصطناعي وتحليل السلاسل الزمنية "، المجلة العلمية لقطاع كليات التجارة، جامعة الأزهر، العدد العاشر.
- ٤- الطويل، سارية عبد الشكور (٢٠١٩) " استخدام نماذج ARFIMA-ANN الهجينة في التنبؤ بأسعار الفقم العالمية " رسالة ماجستير، جامعة الأزهر - غزة، فلسطين.
- ٥- حامد، عماد يعقوب (٢٠١١) " استخدام نماذج بوكس - جنكنز ونماذج الشبكات العصبية الاصطناعية للتنبؤ في السلاسل الزمنية للقطاع الزراعي السوداني "، المؤتمر الدولي الثالث للإحصائيين العرب، الاحصاء في الاستراتيجيات التنموية، عمان - الأردن.
- ٦- حمدان، بديع (٢٠١٥) " التنبؤ بأسعار صرف الدولار مقابل الشيكل باستخدام نموذج ARIMA-ANN الهجين " رسالة ماجستير، جامعة الأزهر - غزة، فلسطين.
- ٧- دربال، أمينة (٢٠١٤) " محاولة التنبؤ بمؤشرات الأسواق المالية العربية باستعمال النماذج القياسية دراسة حالة: مؤشر دبي المالي "، رسالة دكتوراه، جامعة أبي بكر بالقائد - تلمسان، الجزائر.
- ٨- رياض، قادري (٢٠١٧) " مقارنة رياضية وقياسية للتنبؤ بالمبيعات " رسالة دكتوراه، جامعة أبي بكر بالقائد - تلمسان، الجزائر.
- ٩- صليوا، رهاد عماد ومطر، ظافر رمضان (٢٠١٩) " مقارنة أداء التنبؤ بين بعض الشبكات العصبية الاصطناعية ومنهجية بوكس- جينكنز مع التطبيق "، المجلة العراقية للعلوم الإحصائية العدد ٢٨.
- ١٠- مبارك، أمال السيد (١٩٩٨) " التنبؤ باستخدام الجمع بين أسلوبي تحليل الانحدار وتحليل السلاسل الزمنية: التطبيق على الودائع الجارية بالعملة المحلية " رسالة ماجستير، جامعة المنصورة، مصر.

ثانياً: المراجع الأجنبية

- ١- Aladag, C., Erol, E. and Cem, K. (2012) " Improvement in Forecasting Accuracy Using the Hybrid Model of ARFIMA and Feed Forward Neural Network", American Journal of Intelligent Systems, 2(2) , 12-17.

-
-
- ٢- Adhikari, R. and Agrawal, R. K. (2012) " Forecasting strong seasonal time series with artificial neural networks ", Journal of Scientific & Industrial Research, Vol. 71.
- ٣- Box, G.P. and Jenkins, G.M. (1976) " Time Series Analysis: Forecasting and Control " , Holden-Day, New Jersey.
- ٤- Clemen, R. T. (1989) "Combining forecasts: A Review and Annotated Bibliography", International Journal of Forecasting, 5, PP.559-583.
- ٥- Cabarkapa , S., Kojic, N., Savic, A. and Zivkoviv, B.(2010) " use of artificial neural networks in financial time series prediction and financial risk prediction." Infotech-Jahorina vol.q,Ref.E-I I I-6,P.584-587.
- ٦- Dhamija , A. and Bhalla, V., (2010) " Financial Time Series Forecasting: Comparison of Neural Networks and ARCH Models". International Research Journal of Finance and Economics, ISSN 1450-2887 Issue 49.
- 7- Dietrich, M. (2005) " Using simple neural networks to analyze firm activity". Sheffield Economic Research Paper Series.
- 8- Iebeling, K. and Milton, B. (1996) "Designing a neural network for forecasting financial and economic time series" Neurocomputing, Vol. (10) , pp. 215-236.
- 9- Jiuran, H. and Bingfeng, S. (2013) " The application of ARIMA-RBF model in urban rail traffic volume forecast." The 2nd International Conference on Computer Science and Electronics Engineering (ICCSEE).
- 10- Khashei, M. and Bijari, M. (2010) "An artificial neural network (p, d, q) model for time series forecasting." Expert Systems with Applications 37, 479-489.
- ١1- Khashei, M. and Bijari, M. (2011) "Exchange rate forecasting better with hybrid artificial neural networks models." J. Math. Comput. Sci. 1, No.1, 103-125.
- ١2- Moreno, J.J, Pol1, A.P. and Gracia, P.M. (2011) " Artificial neural networks applied to forecasting time series " Psicothema, Vol. 23, no. 2, pp. 322-329.
- ١3- Kumar, P.C. and Walia, E. (2006) "Cash Forecasting: An Application of Artificial Neural Networks in Finance". International Journal of Computer Science & Applications, Vol. III, No. I, pp. 61 – 77.
- ١4- Maciel, L. and Ballini, R. (2008) " Design A Neural network for time series financial forecasting: Accuracy and Robustness Analysis". Instituto de Economia (IE), Universidade Estadual de Campinas (UNICAMP).

-
-
- ١٥- Matroushi, S. (2011) " Hybrid computational intelligence systems based on statistical and neural networks methods for time series forecasting: the case of gold price" , Lincoln University, United Kingdom.
- ١٦- Montgomery, D.C., Jennings, C., and Kulachi, M., (2008) "Introduction to Time Series Analysis and Forecasting", John Wiley & Sons, Inc, USA.
- ١٧- Nakamura, E. (2005) "Inflation Forecasting using a Neural Network". Harvard University, Littauer Center, Cambridge MA 02138. E-mail: nakamura@fas.harvard.edu. Homepage: <http://www.harvard.edu/~nakamura>.
- ١٨- Pao, H.T. (2008) "A comparison of neural network and multiple regression analysis in modeling capital structure". *Expert Systems with Applications*, 35, 720–727.
- 19- Pahlavani, Mosayeb, Roshan and Reza (2015) " The Comparison among ARIMA and hybrid ARIMA-GARCH Models in Forecasting the Exchange Rate of Iran ", *International Journal of Business and Development Studies*, Vol. 7, Issue 1, Page 31-50.
- ٢٠- Rojas, R. (1996) "Neural Networks, A Systematic Introduction". Springer-Verlag, Berlin.
- ٢1- Soni, S. (2015) "Applications of ANNs in Stock Market Prediction: A Survey", *International Journal of Computer Science & Engineering Technology (IJCSET)*, Vol. 2, No. 3.
- ٢2- Türk, A. (2011) "Predicting Financial Crisis with Artificial Neural Network Model: the Case of Turkey". *Research Journal of International Studies - Issue 21*.
- ٢3- Tseng, F.M., Yu, H.C. and Tzeng, G.H. (2002) " Combining neural network model with seasonal time series ARIMA model." *Technological Forecasting and Social Change* 69, 71-87.
- ٢4- Wang, J.h. and Leu, J.Y. (1996) " Stock market trend prediction using ARIMA-based neural networks." *IEEE Int. Conf. Neural Networks*, 4 (6), 2160-2165.
- ٢5- Wallace, M.P. (2008) "Neural Networks and their application to finance". *Business Intelligence Journal*.

A Proposed Model for Improving the Box-Jenkins Methodology Based on the Neural Network Approach (Applied Study)

Abstract

The aim of this research is to reach the best model for predicting the daily exchange rate of the Egyptian pound against the Euro. This is achieved by comparing several forecasting methods, which include time series analysis using Box-Jenkins methodology, artificial neural networks, and finally combining time series analysis and artificial neural networks. The forecasting process relies on the output of the Box-Jenkins model as inputs to the artificial neural network to construct a hybrid forecasting model and overcome neural network issues when building prediction models. This approach aims to obtain the most accurate forecasts of the Egyptian pound exchange rate against the Euro. Daily data has been used from 1/1/2020 to 22/8/2023, consisting of 950 observations. The data is divided into two different periods: the training period from 1/1/2020 to 23/8/2023, and the testing period consisting of 21 observations starting from 23/8/2023 to 20/9/2023. It should be noted that the working week in banks consists of five days. The practical results show that combining time series analysis and artificial neural networks improves prediction accuracy compared to using time series analysis or artificial neural networks separately. The study indicates that the combined model, based on the ARIMA (1, 2, 1) model, produces the most accurate results for predicting the exchange rate of the Egyptian pound against the Euro compared to other models.

Keywords:

Forecasting methods, Time series analysis, Box-Jenkins methodology, Artificial neural networks, Combined methods, Improve forecasts, The exchange rate of Egyptian pound against euro, Autoregressive integrated Moving Average Models.