

الذكاء الاصطناعي وتحليل السلاسل الزمنية

د/ عبدالوهاب السيد حجاج

مدرس بقسم الإحصاء

كلية التجارة - جامعة الأزهر

MAIL: Wahabstat@yahoo.com

Mobile: 0020-01224709386

د/ جمال احمد الشوافى

رئيس قسم الإحصاء

كلية التجارة - جامعة الأزهر

Mail Dr_Gamal1@yahoo.com

Mobile: 0020-01066543923

ملخص البحث

هذا البحث يعتبر امتدادا لبحث (2003) Alshawadfi والذي قدم فيه طريقة جديدة ومؤثرة للتنبؤ بنماذج ARMA، باستخدام أحد طرق الذكاء الاصطناعي وهي طريقة الشبكات العصبية، كما قارن بين الطريقة المقترحة وطريقة بوكس-جينكنز. ويتضمن هذا البحث هدفين:

أولهما: تعميم طريقة Alshawadfi للتنبؤ بالسلاسل الزمنية المولدة من نماذج ARMAX باستخدام الشبكات العصبية الاصطناعية (ANN)، ولتحقيق هذا الهدف تم توليد 32000 عينة بأحجام مختلفة (-100-60-40-25) من نماذج ARMAX بمعلمات مختلفة تستخدم لتدريب الشبكة، بعد ذلك تم مقارنة البيانات المولدة بالبيانات الحقيقية لقياس دقة التنبؤات.

الهدف الثاني: مقارنة أداء الطريقة المقترحة للشبكات العصبية الاصطناعية مع أداء طريقة "بوكس و جينكنز" لتوضيح أي منهما أفضل للتنبؤ بنماذج ARMAX وذلك من خلال قياس دقة التنبؤات لكل من الطريقتين باستخدام ثلاث طرق هي متوسط مربعات الخطأ Mean of Squared Error (MSE)، متوسط الانحرافات المطلقة Mean Absolute Deviation (MAD)، نسبة الحالات التي تتحقق فيها أخطاء مطلقة أقل في الطريقتين The Percentage of cases of Minimum Absolute error (MAEP).

ولانجاز عملية تدريب الشبكة واختبارها وحساب تنبؤات طريقتي بوكس-جينكنز والشبكات العصبية مع المقارنة بين الطريقتين تم استخدام حزم برامج ماتلاب MATLAB. وتم تصميم برنامج كمبيوتر مناسب ضمن حزم برامج ماتلاب MATLAB (أنظر الملحق المرفق مع البحث) لتوليد البيانات و لانجاز عملية تدريب الشبكة واختبارها وحساب تنبؤات طريقتي بوكس-جينكنز والشبكات العصبية مع المقارنة بينهما.

وقد أظهرت نتائج البحث وجود قدرة عالية للطريقة المقترحة للتنبؤ لنماذج ARMAX باستخدام أحد طرق الذكاء الاصطناعي - وهي طريقة الشبكات العصبية - على التنبؤ بالقيم المستقبلية للسلسلة الزمنية المعطاة وذلك بطريقة آلية، حيث أظهرت النتائج من دراسة 32000 عينة والتي تم توليدها أن متوسط مربعات أخطاء التنبؤ MSE خاصة في حالة العينات الصغيرة، ومتوسط القيمة المطلقة لخطأ التنبؤ MAD ، وكذلك متوسط النسبة MAEP أفضل من نظيرتها في أسلوب بوكس-جينكز، وذلك كمتوسط عام بالنسبة لكل العينات وكل النماذج وللمشاهدات المستقبلية الثلاث الأولى. وبناء على ذلك يمكن القول بصلاحيّة الطريقة المقترحة للتنبؤ بالقيم المستقبلية للسلاسل الزمنية المولدة من نماذج ARMAX.

[١] مقدمة

إن توافر قواعد بيانات دقيقة وممثلة لواقع الظاهرة أو الظواهر محل الدراسة ثم استخدام أسلوب علمي وأدوات تحليل لإجراء معالجة الكترونية Electronic processing بدلا من المعالجة اليدوية Manual processing لهذه البيانات هو المطلوب في الوقت الحالي. والهدف هو الحصول على معلومات كافية كما وكيفا لاحتياجات الباحثين أو صانعي القرارات.

ويعرف **الذكاء الاصطناعي** Artificial intelligence بأنه علم يتضمن مجموعة أساليب وطرق جديدة في برمجة أنظمة الحاسب تستخدم لتطوير أنظمة تحاكي بعض عناصر ذكاء الإنسان وتسمح لها بالقيام بعمليات استنتاجية على حقائق وقوانين يتم تمثيلها في ذاكرة الحاسب، بعبارة أخرى الذكاء الاصطناعي: علم يتناول كيفية جعل الآلة - أي الحاسب - تؤدي عمليات مناظرة لقدرات البشر العقلية.

وقد ظهر الذكاء الاصطناعي في الخمسينات من القرن الماضي نتيجة الثورة التي حدثت في مجالي المعلومات والتحكم الآلي، وترمى أبحاثه إلى

تحقيق هدفين رئيسيين: الأول: الوصول إلى فهم عميق للذكاء الإنساني عن طريق محاكاته. الثاني: الاستثمار الأفضل للحاسب الآلي والعمل على استغلال إمكاناته كافة، وخصوصاً بعد التطور السريع في قدرات الحاسبات ورخص ثمنها، ولغاته هي: لغة Lisp: وهي لغة معالجة اللوائح (List Processing Language)، ولغة Prolog: وهي لغة البرمجة بالمنطق (Programming in Logic)، وهذه اللغات تتيح للمبرمج إمكانيات كبيرة في كتابة البرامج. ومن المجالات المرتبطة بهذا العلم: علم التحكم الآلي Cybernetics، وعلم الروبوت Robotics، والتعلم بمساعدة الحاسب CAI، والتصميم الهندسي بمساعدة الحاسب CAD، والترجمة الآلية MT، والتميز الآلي للأنماط Pattern recognition، والألعاب الإلكترونية كالشطرنج..... وغيرها.

ويتضمن الذكاء الاصطناعي فروعاً عديدة من أهمها: النظم الخبيرة Expert Systems، والتقيب في البيانات Data Mining، والخوارزميات الجينية Genetic algorithms، والشبكات العصبية Neural Networks. وخلال هذا البحث سنبين كيف يمكن استخدام أحد فروع الذكاء الاصطناعي وهو الشبكات العصبية في تحليل السلاسل الزمنية.

السلسلة الزمنية عبارة عن مجموعة مشاهدات أو قياسات مرتبة حسب الزمن، ويعتبر أسلوب تحليل السلاسل الزمنية Time Series Analysis أحد الأدوات المستخدمة في التحليل الإحصائي للبيانات غير المستقلة زمنياً بمعنى أن المشاهدات المتتالية عادة ما تكون غير مستقلة أي تعتمد على بعضها البعض.

تحليل السلاسل الزمنية يقصد به الطريقة أو الطرق المستخدمة لنمذجة بيانات سلاسل زمنية والتنبؤ بالقيم المستقبلية لهذه السلاسل. وقد حظي تحليل

السلاسل الزمنية باهتمام كبير في مجالات عديدة منها الاقتصاد والأعمال والتخطيط والمبيعات والعلوم الطبيعية و الهندسية وغيرها.

وبالرغم من أن دراسة نماذج السلاسل الزمنية قد بدأت منذ سنوات عديدة إلا أنه يمكن القول بأن بوكس و جينكنز قد جعلوا استخدام هذه النماذج أكثر انتشاراً وبيّنوا إمكانية استخدامها في البيانات الموسمية كما أنهما أوضحا كيفية تطبيق هذه النماذج عملياً.

وتتضمن طريقة بوكس-جينكنز لتحليل السلاسل الزمنية أربعة مراحل هي: توصيف النموذج، وتقدير معالمه، و التحقق من صلاحيته، وأخيراً مرحلة التنبؤ حيث يتم استخدام النموذج المقترح في التنبؤ بالقيم المستقبلية للسلاسل الزمنية. ولمزيد من التفصيل عن هذه الطريقة (انظر (Box-) Jenkins (1976). كما توجد طرق أخرى لتحليل السلاسل الزمنية منها طرق تقليدية وطرق باستخدام أسلوب يبيز سواء باستخدام تكاملات عديدة أو تقريبات مناسبة لدالة الإمكان الأعظم أو حتى باستخدام الطرق القائمة على المعاينة. أنظر على سبيل المثال:

Harvey &Phillips(1977), Box-Jenkins (1976)، Shaarawy & Alshawadfi (1987), Alshawadfi (1994.1996).

وبالرغم من الانتشار الهائل لأسلوب " بوكس و جينكنز " منذ السبعينيات من القرن العشرين و الذي مازال يفوق كل الأساليب الحديثة لتحليل السلاسل الزمنية، إلا أن تطبيق هذا الأسلوب بشكل دقيق يتطلب مهارة وممارسة قد لا تتوافر في كثير من غير المتخصصين، علاوة على ذلك فإننا نعيش اليوم عصر المعلوماتية والعالم الرقمي الذي يحوى كل أنشطة المال والأعمال في بيئة متكاملة ومتشابكة، وانطلاقاً من أن تقنيات المعلوماتية والحوسبة في تطور سريع فقد جاءت هذه الدراسة للبحث عن طريقة مرنة يمكنها التعامل مع البيئة الديناميكية، و إيجاد تنبؤات بدقة عالية للقيم المستقبلية بطريقة آلية.

وتعد الشبكات العصبية الاصطناعية (ANN) Network Artificial Neural من أهم الطرق المرنة التي لديها القدرة على التعلم الذاتي السريع وسرعة التغيير في البيئة الديناميكية، وذلك من خلال قواعدها الخاصة ووفق منهجية محددة وتعزيز هذا المنهج عبر التدريب بطريقة تحاكي فيها عمل الخلايا العصبية الدماغية من حيث بنيتها ومعالجتها للمدخلات.

[١-١] مشكلة البحث

تكمن المشكلة أنه في حالة انحدار المشاهدات الحالية Y_t على الأخطاء السابقة أي في حالة نماذج المتوسطات المتحركة Moving Average (MA)، أو نماذج الانحدار الذاتي (AR) Auto-Regressive مع المتوسطات المتحركة (المختلطة) (ARMA)، أو النماذج المختلطة مع متغير خارجي (exogenous inputs ARMAX)، يكون لدالة الإمكان شكلا معقدا بسبب أن الأخطاء لها علاقة غير خطية في المعلمات مما يصعب معه التعبير عن دالة التوزيع الاحتمالي لبعض أو كل معالم النموذج في شكل قياسي أو باستخدام أحد التوزيعات المعروفة كما وأنه في حالة استخدام أسلوب ببيز يصعب إيجاد مصفوفة التباين والتغاير "مقلوب مصفوفة الدقة" ومحدد مصفوفة التباين والتغاير، واختيار دالة احتمال قبلية مناسبة لها، خاصة مع زيادة حجم العينة.

ولتجنب تلك المشكلة لزم البحث عن طريقة جديدة للتنبؤ بخلاف الطرق الإحصائية التقليدية والتي تعتمد على دالة الإمكان في تقدير معالمها، وهذه الطريقة هي الشبكات العصبية الاصطناعية، حيث تمتاز هذه الطريقة بأنها تعمل بصورة آلية لاختيار نموذج مناسب يوضح كيفية اعتماد المخرجات على المدخلات.

[٢-١] هدف البحث

هذا البحث يعتبر امتدادا لبحث (Alshawadfi(2003) والذي اقترح طريقة جديدة ومؤثرة للتنبؤ بنماذج ARMA، كما قارن الطريقة المقترحة بطريقة بوكس-جينكنز ويتضمن البحث الحالي هدفين:

▪ الهدف الأول: تعميم طريقة (Alshawadfi (2003) للتنبؤ بالسلاسل الزمنية المولدة من نماذج ARMAX باستخدام الشبكات العصبية الاصطناعية (ANN)، ولتحقيق هذا الهدف يتم توليد 32000 عينة بأحجام مختلفة من نماذج ARMAX بمعلمات مختلفة تستخدم لتدريب الشبكة، بعد ذلك يتم مقارنة البيانات المولدة بالبيانات الحقيقية لقياس دقة التنبؤات.

▪ الهدف الثاني: مقارنة أداء الطريقة المقترحة للشبكات العصبية الاصطناعية مع أداء طريقة " بوكس و جينكنز " لتوضيح أي منهما أفضل للتنبؤ بنماذج ARMAX وذلك من خلال قياس دقة التنبؤات لكل من الطريقتين باستخدام ثلاث مقاييس:

١- متوسط مربعات الخطأ (Mean of Squared Error (MSE)

٢- متوسط الانحرافات المطلقة (Mean Absolute Deviation (MAD)

٣- نسبة الحالات التي تتحقق فيها أخطاء مطلقة أقل في الطريقتين

The Percentage of cases of Minimum Absolute error (MAEP)

[٣-١] أهمية البحث

تأتي أهمية البحث في استخدامه لأحد طرق الذكاء الاصطناعي وهي طريقة الشبكات العصبية في التنبؤ بالسلاسل الزمنية المولدة من نماذج ARMAX كطريقة جديدة يمكن استخدامها للتنبؤ بكثير من الظواهر في مجالات عديدة، حيث أنها تمتاز عن غيرها من الأساليب الإحصائية التقليدية

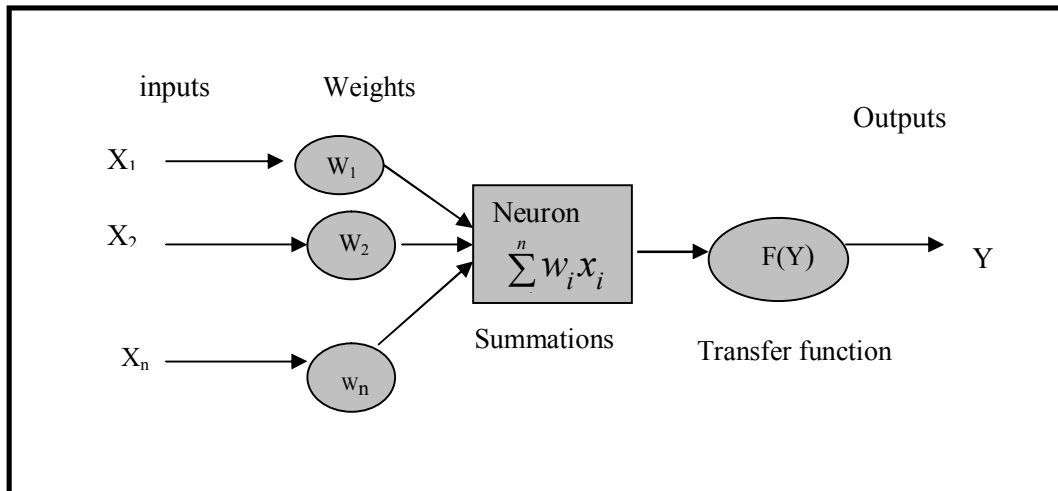
بمزايا منها: أنها تفيد في الحصول على تنبؤات جيدة، حيث أنها تعطي مجموع مربعات أخطاء غير خطية أقل، كما أن طريقة الشبكات العصبية الاصطناعية (ANN) تحتاج عينات أصغر نسبيا في اختبار مصداقية النماذج، ومن مزاياها أيضا أنه يتم التنبؤ فيها بصورة آلية وأنها تصلح في حالة النماذج الخطية وغير الخطية، كما يمكن استخدامها لتقييم قدرة الأساليب الإحصائية الأخرى في تقدير النماذج واستخدامها في التنبؤ.

[٢] الشبكات العصبية الاصطناعية

تعد الشبكات العصبية الاصطناعية (ANN) Neural Networks Artificial أحد أهم طرق الذكاء الاصطناعي، و تتمحور فكرتها حول محاكاة قدرة العقل البشري على التعرف على الأنماط، وتمييز الأشياء، باستخدام الحاسب الآلي من خلال إتباع عملية التعلم الذاتية التي تحدث في العقل، والتي يتم فيها الاستفادة من الخبرات السابقة في سبيل الوصول إلى أفضل نتائج في المستقبل. (نظر: حاجي، والمحميد، (١٩٩٩)، ص ١٩).

شكل (٢-١)

نموذج لوحة تشغيل



والشكل (٢-١) السابق يبين وحدة تشغيل بسيطة داخل الشبكة العصبية (انظر: (Turban, et al. (2005)).، حيث يكون لكل وحدة تشغيل مسار إدخال واحد أو أكثر تتحصر مهمته في نقل المعلومات من العالم الخارجي إلى وحدة التشغيل الذي تقوم بدورها بعملية التجميع البسيطة، ثم تحويل المعلومات بواسطة دالة تفعيلية تعرف بدالة التحويل، بعد ذلك تنقل المعلومات كمرجات من خلال مسار المخرجات. وبشكل رياضي فإن كل خلية عصبية تستقبل عدد من إشارات المدخلات (X_1, X_2, \dots, X_n) والتي تماثل التفرعات العصبية Dendrites، ثم يتم ضرب كل المدخلات في الأوزان (W_1, W_2, \dots, W_n) التي تعد الوسيلة الأساسية لذاكرة الشبكات العصبية الاصطناعية طويلة المدى وتعبّر عن درجة أهمية المدخلات، وحاصل الجمع summations يتم معالجته باستخدام دالة تحويل $F(Y)$ Transfer function لنحصل منها على إشارات المخرجات (Y) Output Signals

[١-٢] تعلم الشبكة العصبية Learning of the Neural Network

تعلم الشبكة العصبية الاصطناعية هي العملية التي من خلالها تقوم الشبكة العصبية بتعديل نفسها استجابة للمدخلات من أجل الحصول على المخرجات المستهدفة. وبأسلوب آخر فهي عملية اكتساب المعرفة، حيث تبحث الشبكة العصبية عن المعرفة من مجموعة بيانات العينة. وأثناء عملية التعلم تعدل الشبكة أوزان الاتصال على أساس المدخلات الواردة حتى تقترب المخرجات من المخرجات الحقيقية أو المستهدفة (انظر (Zurada (1992)).

و يتم تعليم أو تدريب الشبكة العصبية على اكتشاف العلاقات المنطقية في البيانات بإتباع إحدى الطرق الآتية:

[١-١-٢] التعليم الإشرافي: Supervised Learning

تعد هذه الطريقة هي الأكثر انتشارا في تدريب الشبكة العصبية، وفيها تجمع عينات من البيانات تحتوى قيماً للمتغيرات المدخلة وقيماً للمتغيرات

المخرجة، و تقوم الشبكة بمقارنة النتائج التي تقدرها للمتغيرات الخارجة لكل عينة مدخلة بالقيم الفعلية لهذه المتغيرات، وبناء على ذلك تقوم الشبكة بإجراء التعديلات على أوزان الاتصال بهدف تقليل الأخطاء في النتائج، ثم تعاد عملية التدريب عدة مرات إلى أن يتم الوصول إلى نتائج مقبولة.

[٢-١-٢] التعليم غير الإشرافي Unsupervised Learning

تتشابه هذه الطريقة مع طريقة التعليم الإشرافية إلا أنها تختلف عنها في أن العينات المستخدمة في عملية التدريب لا تتضمن أية قيم للمتغيرات الخارجة، وتتكون البيانات الداخلة إلى الشبكة من عدة قطاعات أو مجموعات، حيث تتدرب الشبكة في هذه الحالة على اكتشاف المميزات غير الظاهرة في مجموعة البيانات المستخدمة في عملية التدريب، ومن ثم استخدام تلك المميزات في تقسيم بيانات المدخلات إلى مجموعات مختلفة فيما بينها ومقاربة داخل كل مجموعة.

[٣-١-٢] Reinforcement Learning التعليم بإعادة التدعيم:

هذه الطريق خليط بين الطريقتين السابقتين، حيث لا يفصح للشبكة العصبية عن القيم الحقيقية للمخرجات كما هو الحال في طريقة التدريب غير الإشرافية ولكن يشار للشبكة بصحة نتائجها المحصلة أو خطأها كما في طريقة التعليم الإشرافية.

[٢-٢] Typical Architectures الميكل العام للشبكة

عملية تنظيم الخلايا العصبية في طبقات وكيفية الاتصال بين هذه الخلايا لتكوين الشبكة تسمى بهيكل الشبكة Architectures، و بوجه عام من الممكن تقسيم هيكل الشبكة العصبية الاصطناعية إلى ثلاثة أنواع رئيسية هي: (١) شبكة وحيدة الطبقة ذات التغذية الأمامية Single-Layer Feed forward Network، (٢) شبكة متعددة الطبقات ذات التغذية الأمامية Multi-Layer Feed forward Network، (٣) شبكة متعددة الطبقات ذات

التغذية المرتدة Multi-Layer Recurrent Network (انظر: Demuth &

Beale 1998) و سنوضح كل نوع فيما يلي:

[٢-٢-١] شبكة وحيدة الطبقة ذات التغذية الأمامية

وهي أبسط هياكل الشبكات العصبية الاصطناعية، والنوع الأكثر شيوعاً منه يسمى Perceptron، وهو أبسط صيغة للشبكات العصبية الاصطناعية، كما أنه النموذج الذي تبنى عليه الأنواع الأخرى من الشبكات وحيدة الطبقة، كما يعد أبسط أنواع الشبكات العصبية أمامية التغذية حيث تنتقل المعلومات من الطبقة المدخلات إلى طبقة المخرجات مباشرة، كما أنها تتعلم عن طريق التعليم الإشرافي. والشكل (2-1) السابق يوضح هيكل شبكة عصبية وحيدة الطبقة بتغذية أمامية. ومن خلال تلك الشبكة تتم عملية التعلم عن طريق قيام وحدات المعالجة بعدة خطوات رئيسية هي:

الخطوة الأولى: التحديد العشوائي للقيم الابتدائية للأوزان w_1, w_2, \dots, w_n ، وللقيمة الحدية Threshold Value (θ) وذلك في المدى $[-0.5, 0.5]$.

الخطوة الثانية: عملية التنشيط: فبعد أن تستقبل كل وحدة معالجة (نيرون) Neuron العديد من الإشارات المدخلة، و حساب المجموع الموزون لهذه المدخلات المستخدمة و الذي عادة ما يتم باستخدام دالة المجموع Summation Function الآتية:

$$X = \sum_{i=1}^n w_i x_i \quad \dots \dots \dots (2-1)$$

حيث:

X صافي المدخلات الموزونة للخلية العصبية

w_i الأوزان النسبية لعقد الاتصال ما بين الطبقات

x_i قيمة المدخلات i

n عدد مدخلات الخلية العصبية

ويتم تنشيط المدرك Perceptron عن طريق تطبيق المدخلات X_1, X_2, \dots, X_n والمخرجات المرغوب بها $T(k)$ ، وحساب المخرجات الفعلية عند التكرار k كما يلي:

$$y(k) = \text{step} \left[\sum_{i=1}^n X_i(k) W_i(k) - \theta \right] \quad \dots \dots \dots \quad (2-2)$$

وهذا النوع من دوال التحويل (التنشيط) يسمى بدالة الخطوة Step

.Function

وتجدر الإشارة إلى انه بجانب دالة الخطوة يوجد كثير من دوال التنشيط

ولكن وجد أن قلة فقط منها لها تطبيقات عملية و من أهم هذه الدوال ما يلي:

١- دالة الإشارة Sign Function

٢- دالة الخطوة Step Function

٣- الدالة الخطية Linear Function

٤- ٤- الدالة التجميعية Function Sigmoid و عادة تستخدم دالة الإشارة

Sign Function و دالة الخطوة Step Function للخلايا العصبية في

اتخاذ القرارات لمهام التصنيف، وتمييز الأنماط. (انظر على سبيل المثال:

نجينفيتسكى، (٢٠٠٤)، ص ٢٣٥).

وتعتبر الدالة التجميعية sigmoid Function أكثر دوال التحويل

استخداما لما تتميز به من بساطة في التمييز وسهولة في حساب الميل، أما دالة

التحويل الخطية Linear Function فيمكن أن تستخدم في بعض تطبيقات

السلاسل الزمنية، وفي أغلب الأحوال دالة التحويل تجمع من توليفة

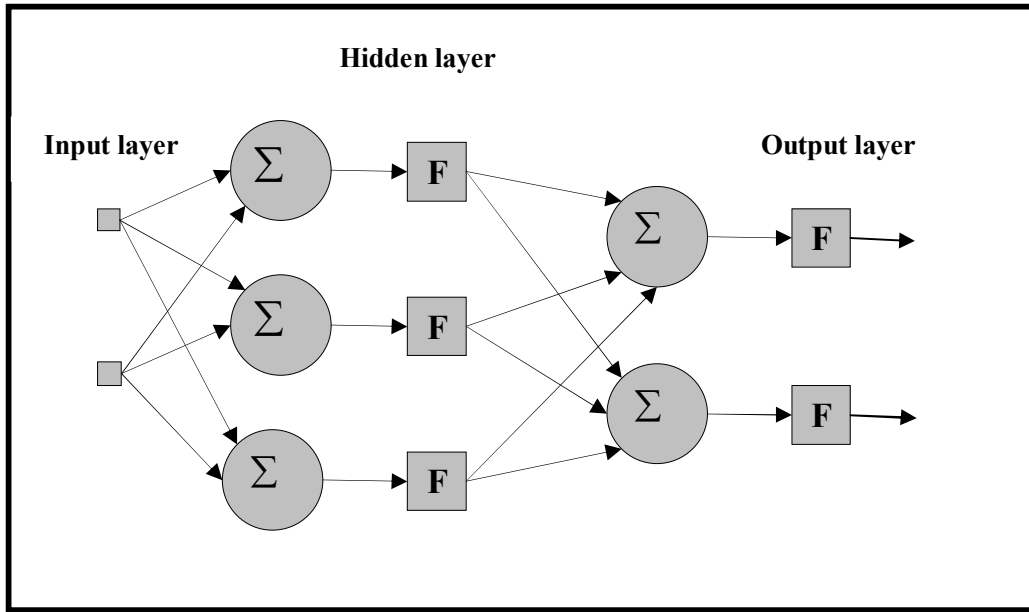
خطية. (أنظر: (Alshawadfi (2003).

[٢-٢-٢] شبكة متعددة الطبقات ذات التغذية الأمامية

تتكون الشبكة متعددة الطبقات من واحد أو أكثر من الطبقات (أو المستويات) من عقد الاتصال Nodes تسمى طبقات مخفية Hidden Layers توجد بين طبقات المدخلات Input Layers وطبقات المخرجات Output Layers، وفي الشبكات ذات التغذية الأمامية تنتشر إشارات المدخلات في الاتجاه الأمامي من طبقة لطبقة، ولا يسمح بالرجوع للخلف، ويمكن لهذا النوع من الشبكات حل العديد من المشاكل المعقدة التي لا تستطيع الشبكة ذات الطبقة الواحدة حلها، ولكن تدريبها قد يستغرق وقتاً أطول. انظر: Hijazi (2007)

شكل (٢-٢)

الشبكة متعددة الطبقات ذات تغذية أمامية



وتقوم العناصر الحسابية في الطبقة المخفية بإجراء عملية الجمع الموزون وترسل إشارة مخرجات (أنماط تنبيه) إلى طبقة المخرجات التي تقوم هي

الأخرى بعملية الجمع الموزون وتحديد أنماط المخرجات للشبكة كلها. (انظر: (٢٠٠٤) نجينفيتسكى). كما انه بزيادة عدد وحدات المعالجة داخل الطبقة الخفية أو إضافة أكثر من طبقة مخفية في الشبكة، يسمح للشبكة بالتعامل مع كثير من الدوال المعقدة والتقريب الدقيق للدوال المستمرة وهذا ما نصت عليه نظرية (Cybenko). (أنظر (1989) Cybenko).

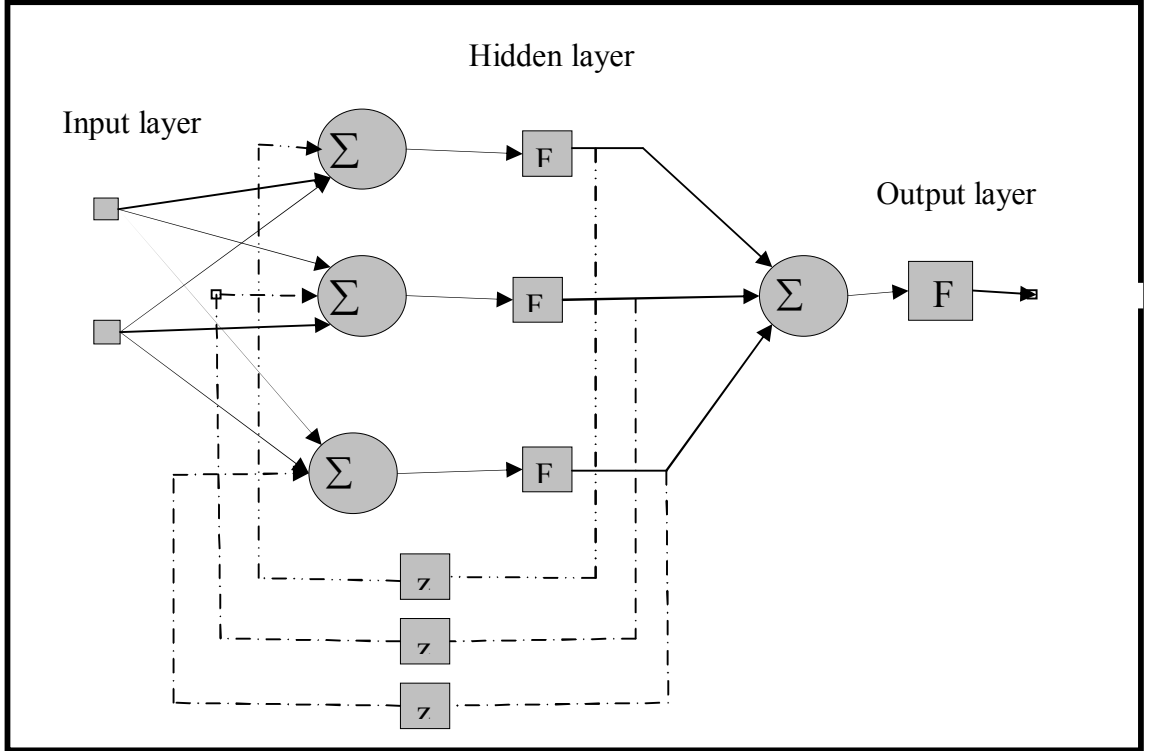
أما بالنسبة لعملية التعليم فإنها تستمر بنفس الطريقة في الشبكة وحيدة الطبقة، حيث تحدد الأوزان باستخدام التعلم بالتغذية الخلفية Back Propagation Learning، وقبل هذا التحديث يوجد خطوتين متتاليتين أولهما أمامية Forward والأخرى تراجعية Backward، ففي الخطوة الأمامية يتم حساب مخرجات الشبكة من البيانات المدخلة، ومقارنة هذه المخرجات مع المخرجات المستهدفة عن طرق حساب الخطأ. أما في الخطوة التراجعية فتقوم الشبكة بتعديل الأوزان النسبية بهدف تصغير الخطأ، وتسمى العملية التي تضم المرحلتين السابقتين بالدورة (Epoch)، ويتم تكرار هذه الدورة إلى أن نصل لأقل مجموع مربعات للخطأ.

[٢-٢-٣] شبكة متعددة الطبقات ذات التغذية المرتدة

وهي النوع الثاني من الشبكات العصبية متعددة الطبقات، وهذا النوع يحتوي على حلقة تغذية خلفية واحدة على الأقل (مسار مغلق من التغذية الخلفية feedback loop) كما في الشكل (٢-٣)، حيث أنه وعلى عكس الشبكة متعددة الطبقات ذات التغذية الأمامية يتم حساب الخطأ بين مخرجات الشبكة والمخرجات الحقيقية ولكن يتم تغذية الخطأ في اتجاه عكسي (عكس اتجاه المدخلات) للشبكة لتعديل الأوزان وبالتالي يتم تخفيض الخطأ، وهذا الإجراء يتم تكراره حتى يصل الخطأ إلى أقل قيمة ممكنة.

شكل (٢-٣)

الشبكة متعددة الطبقات ذات التغذية مرتدة



[٣] نموذج ARMAX

يعد نموذج ARMAX بمثابة تعميم لنماذج بوكس - جينكنز حيث يتضمن متغيرات انحدار ذاتي (AR) Auto-Regressive، ومتوسطات متحركة (MA) Moving Average، بالإضافة إلى المتغير الخارجي exogenous inputs.

أي أنه في هذا النموذج تتحدر المشاهدات الحالية Y_t على القيم السابقة للسلسلة الحالية وعلى القيم الحالية X_t و السابقة لسلسلة أخرى، وتتحد كذلك

على الأخطاء الحالية والسابقة، ويمكن تعريفه وفقاً للمرجع (Alshawadfi 1994) كما يلي:

$$\phi(B)Y_t = \omega(B)X_t + \theta(B)e_t \dots \dots (3-1)$$

حيث:

Y_t : هي المشاهدة Y عند الزمن t ، $t=1,2,3,\dots,n$
 X_t : هي متغيرات خارجية مستقلة عن e_t
 e_t : تمثل سلسلة من المتغيرات العشوائية المستقلة والتي لها توزيع طبيعي متوسطه الصفر، وتباينه σ^2

$\theta(B), \omega(B), \phi(B)$: هي كثيرات حدود تأخذ الصورة:

$$\begin{aligned} \phi(B) &= 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p, \phi_i \in R, i = 1, 2, \dots, p \\ \omega(B) &= \omega_0 + \omega_1 B + \omega_2 B^2 + \dots + \omega_h B^h, \omega_j \in R, j = 1, 2, \dots, h \\ \theta(B) &= 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q, \theta_k \in R, k = 1, 2, \dots, q \end{aligned}$$

حيث:

B هي معامل الإزاحة للخلف خطوة واحدة، أي أن:

$$B^r Y_t = Y_{t-r}, r=1,2,\dots,n \dots \dots (3-2)$$

وبافتراض أن السلسلة المولدة من النموذج في المعادلة (3-1) مستقرة (ربما بعد تحويله مناسبة) بمعنى أن كل جذور المعادلة $\phi(B)=0$ تقع

خارج دائرة الوحدة، والسلسلة لا تمثل تغذية مرتدة من المخرجات Y_t للمدخلات X_t ، كما تكون العملية قابلة للانقلاب إذا كانت كل جذور المعادلة $\theta(B)=0$ واقعة خارج دائرة الوحدة.

والنموذج السابق يمكن التعبير عنه في الشكل التالي:

$$Y_t = \sum_{i=1}^p \phi_i Y_{t-i} - \sum_{j=0}^h \omega_j X_{t-j} - \sum_{k=1}^q \theta_k \varepsilon_{t-k} + \varepsilon_t \dots \dots \dots (3-3)$$

كما يمكن كتابة هذا النموذج في صيغة مصفوفات كما يلي:

$$Y = XW + E \dots \dots \dots (3-4)$$

حيث:

$$X = \begin{bmatrix} y_m & y_{m-1} & \dots & y_{m-p+1} & x_m & x_{m-1} & \dots & x_{m-h+1} & \varepsilon_m & \varepsilon_{m-1} & \dots & \varepsilon_{m-q+1} \\ y_{m+1} & y_m & \dots & y_{m-p} & x_{m+1} & x_m & \dots & x_{m-h} & \varepsilon_{m+1} & \varepsilon_m & \dots & \varepsilon_{m-q} \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ y_{n-2} & y_{n-3} & \dots & y_{n-p-1} & x_{n-2} & x_{n-3} & \dots & \dots & \varepsilon_{n-2} & \varepsilon_{n-3} & \dots & \varepsilon_{n-q-1} \\ y_{n-1} & y_{n-2} & \dots & y_{n-p} & x_{n-1} & x_{n-2} & \dots & x_{n-h} & \varepsilon_{n-1} & \varepsilon_{n-2} & \dots & \varepsilon_{n-q} \end{bmatrix}$$

$$W = [\phi_1 \quad \phi_2 \quad \dots \quad \phi_p \quad \omega_0 \quad \omega_1 \quad \omega_2 \quad \dots \quad \omega_h \quad \theta_1 \quad \theta_2 \quad \dots \quad \theta_q]'$$

$$Y = [y_{m+1} \quad y_{m+2} \quad \dots \quad \dots \quad y_n]'$$

$$E = [\varepsilon_{m+1} \quad \varepsilon_{m+2} \quad \dots \quad \dots \quad \varepsilon_n]', \quad m = \max(p, h) \dots \dots \dots (3-5)$$

ونلاحظ أن كل من y_{t-1} و x_{t-1} ، في متجه المدخلات X تكون معلومة، بينما e_{t-1}

تكون مجهولة، ويتم استخدام الخطأ المقدر ε_{t-1} ، وكذلك $\varepsilon(0)$ من الممكن أن نضع لها قيمة ابتدائية تساوى الصفر.

حيث أن الخطأ (البواقي) الناتج عبارة عن الفرق بين القيمة الحقيقية والقيمة المقدرة:

$$e_{(t)} = y_{p(t)} - y_{(t)} \\ = y_{p(t)} - XW \dots \dots \dots (3-6)$$

ويكون الهدف هو الحصول على تقدير للمعالم W التي تجعل مجموع مربعات البواقي أقل ما يمكن.

[٤] نموذج شبكات عصبية مقترح لتحليل السلاسل الزمنية

من الممكن اعتبار الشبكات العصبية الاصطناعية كنموذج انحدار غير خطي يتكون من المتغيرات المدخلة وتتمثل في القيم الماضية للسلسلة $X_{t+1}, X_{t+2}, \dots, X_{t+h}$ أو تحويلاتها و قيم متغير خارجي $Y_{t+1}, Y_{t+2}, \dots, Y_{t+p}$ والأخطاء $\varepsilon_{t+1}, \varepsilon_{t+2}, \dots, \varepsilon_{t+q}$ حيث X مصفوفة تأخذ الشكل التالي:

$$X = \begin{bmatrix} z_m & z_{m-1} & \dots & z_{m-p+1} & x_m & x_{m-1} & \dots & x_{m-h+1} & \varepsilon_m & \varepsilon_{m-1} & \dots & \varepsilon_{m-q+1} \\ z_{m+1} & z_m & \dots & z_{m-p} & x_{m+1} & x_m & \dots & x_{m-h} & \varepsilon_{m+1} & \varepsilon_m & \dots & \varepsilon_{m-q} \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ z_{n-2} & z_{n-3} & \dots & z_{n-p-1} & x_{n-2} & x_{n-3} & \dots & \dots & \varepsilon_{n-2} & \varepsilon_{n-3} & \dots & \varepsilon_{n-q-1} \\ z_{n-1} & z_{n-2} & \dots & z_{n-p} & x_{n-1} & x_{n-2} & \dots & x_{n-h} & \varepsilon_{n-1} & \varepsilon_{n-2} & \dots & \varepsilon_{n-q} \end{bmatrix}$$

ومتجه المخرجات Z بأبعاد $h \times 1$ هو:

$$Z = [z_{n+1}, z_{n+2}, \dots, z_{n+h}] \dots \dots \dots (4-1)$$

هذه النماذج من الممكن أن تستخدم كتقريب للعلاقات المحددة
:deterministic relations

$$Z = v(X) \quad \dots (4-2)$$

أو العلاقات العشوائية: stochastic relations

$$Z = v(X) + \varepsilon \quad \dots (4-3)$$

حيث يفترض أن $E|\varepsilon| = 0$ ، وكذلك الدالة $v(X) = E(Z|X)$ غالباً ما تكون غير معلومة ويتم تقريبها بواسطة الدالة $g(X, W)$ ، حيث W تمثل متجه المعالم وتسمى الأوزان، والتي تكون مجموعة جزئية في فراغ المعالم parameter space وتقدر من مجموعة البيانات المدربة (العينة)، وكل من فراغ المعالم ومتجه المعالم يعتمد على دالة التقريب التي تم اختيارها $g(X, W)$.

وحيث أنه من الممكن الحصول على تنبؤات مشاهدات السلسلة المستقبلية y_{t+l} في نموذج ARMAX كمجموع مرجح من المشاهدات السابقة للسلاسل y_t و x_t بالإضافة إلى المتغير العشوائي ε_t (أنظر Reinsel and Box, Jenkins, p.446 (1994))، أي انه يصبح كنموذج ARX كما يلي:

$$y_{t+l} = \sum_{j=1}^{\infty} \pi_j y_{t+l-j} + \sum_{j=1}^{\infty} \eta_j X_{t+l-j} + \varepsilon_{t+l} \quad \dots (4-4)$$

حيث تمثل π_j و η_j الأوزان المرجحة وهي عبارة عن:

$$\pi(B) = \frac{\varphi(B)}{\theta(B)} = (1 - \pi_1 B - \pi_2 B - \dots)$$

$$\eta(B) = \frac{\theta(B)}{\omega(B)} = (1 - \eta_1 B - \eta_2 B - \dots)$$

(4-5)

كما أن مجموع هذه الأوزان يساوى الواحد الصحيح:

$$\pi(B) + \eta(B) = 1 \quad \dots (4-6)$$

بالإضافة إلى أنه من الممكن لنموذج ARMAX أن يكون حالة خاصة لعملية الشبكة العصبية في المعادلة (4-1) بكتابة $v(X)$ كما يلي:

$$v(X) = \sum_{j=1}^{\infty} \pi_j y_{t+l-j} + \sum_{j=1}^{\infty} \eta_j X_{t+l-j} \quad \dots (4-7)$$

لذلك فإن نموذج الشبكة العصبية المقرب من الممكن أن يكون في الصيغة التالية:

$$Z_{t+1} = g(X, W) + \varepsilon_{t+1} \quad \dots (4-8)$$


وعند التنبؤ بقيمة Z مع وجود دالة التقريب $g(X, W)$ فإنه يوجد نوعين من الخطأ، الخطأ الأول: هو الخطأ العشوائي ε ، والخطأ الثاني: هو خطأ التقريب و الذي يمثل الفرق بين القيمة الفعلية والقيمة المقدرة $v(X) - g(X, W)$ ، والخطأ الثاني يكافئ الخطأ في نماذج الانحدار غير الخطية التي تحتوى على خطأ في التحديد وتوزيع الخطأ فيها يكون غير محدد، وذلك على عكس العديد من النماذج الإحصائية. وتحديد المعالم لدالة التقريب $g(X, W)$ تسمى ببناء الشبكة

"network architecture"، وهذه الدالة عبارة عن توليفة من الدوال الخطية وغير الخطية. وعادة ما يتم تصوير الشبكة بواسطة أشكال بيانية تمثل فيها الدوال الفرعية

sub-functions بواسطة دوائر، والنتائج المحولة من واحد أو أكثر من الدوال الفرعية بواسطة الأسهم. وعلى سبيل المثال يمكن تمثيل نموذج الانحدار الخطي كشبكة عصبية اصطناعية كما بالشكل التالي (انظر: Arminger and Enache (1996).

شكل (٤-١)

نموذج الانحدار الخطى كشبكة عصبية اصطناعية



حيث يوضح هذا الشكل كيفية تمثيل نموذج الانحدار الخطى باستخدام نموذج شبكة عصبية ويتكون هذا البناء من وحدة واحدة تضم المتغيرات الخطية المدخلة X_1, X_2, \dots, X_k

بجوار الثابت 1، مع متجه المعالم (الأوزان) w وهذا النموذج هو أبسط النماذج الرياضية للشبكات ويسمى الخلية الخطية الانضباطية Adaptive Linear Neurons (ADALINE)، ولا يحتوى هذا النموذج على طبقة مخفية بل تنتقل المعلومات مباشرة من الطبقة الأمامية إلى النهائية من خلال دالة تحويل مناسبة:

$$Z = g(X, W) = XW \quad \dots (4-9)$$

حيث Z متغير ذو بعد واحد (وحدة إخراج واحدة)، ونموذج الشبكة في هذه الحالة يعطى بالعلاقة الرياضية (المحددة):

$$Z = XW \quad \dots (4-10)$$

أو بالعلاقة العشوائية:

$$Z = XW + e \quad \dots (4-11)$$

وهذا النموذج يعادل نموذج الانحدار الخطى البسيط أحادى المتغيرات، القادر على أداء التقريب الخطى فقط، ولكن الكثير من الدوال $v(X)$ تكون دوال غير خطية مما قد يؤدي إلى خطأ في التقريب.

[5] المقارنة بين طريقتي بوكس-جينكنز والشبكات العصبية

لكي يتم مقارنة الطريقة الجديدة مع طريقة بوكس-جينكنز تم توليد 32000 عينة بواقع 500 عينة لكل نموذج من 32 نموذج مختارة من نماذج $ARMAX(p,h,q)$ مع أحجام عينات مختلفة (25-40-60-100-150)، وتم المقارنة بين تنبؤات المشاهدات وقيمها الحقيقية لقياس دقة التنبؤات ومقارنة أداء الطريقة المقترحة للشبكات العصبية الاصطناعية مع أداء طريقة " بوكس - جينكنز " لقياس دقة الطريقة المقترحة للتنبؤ بنماذج $ARMAX$. وتم قياس دقة التنبؤات لكل من الطريقتين باستخدام ثلاث مقاييس متعلقة بالبوياقي ($MSE, MAD, MAEP$) لكل طريقة بشكل مستقل للمقارنة وإبداء الملاحظات. علاوة على ذلك فإن هذه المقارنة تتم وفقا لثلاثة معايير (حجم العينة، النموذج المحدد، أفق التنبؤ)، وفيما يلي شرح لهذه المقاييس:

[1-5] مقارنة نتائج مقياس MSE

فيما يلي جدول (5-1) الذي يحتوى على نتائج مقياس MSE لكل من تنبؤات بوكس-جينكنز وتنبؤات الشبكات العصبية الاصطناعية مع نماذج $ARMAX$ المحددة بأحجام عينات مختلفة، كذلك جدول (5-2) الذي يحتوى على نتائج مقياس MSE للثلاثة مشاهدات المستقبلية عند أحجام عينات مختلفة:

جدول (٥-١)

قيم MSE لتنبؤات بوكس-جينكنز والشبكات العصبية موزعة وفقا لأحجام عينات ونماذج مختلفة

Average	150	100	60	40	25	Method	Sam.Size
							P,h,q
0.0026	0.0038	0.0034	0.0026	0.0022	0.0013	NN	(1,1,0)
0.0035	0.0034	0.0037	0.0034	0.0036	0.0037	BJ	
0.0027	0.0037	0.0035	0.0026	0.0023	0.0015	NN	(1,2,0)
0.0028	0.0027	0.0030	0.0027	0.0027	0.0030	BJ	
0.0023	0.0033	0.0030	0.0024	0.0018	0.0012	NN	(1,1,1)
0.0032	0.0028	0.0036	0.0029	0.0032	0.0036	BJ	
0.0020	0.0027	0.0026	0.0021	0.0018	0.0010	NN	(0,1,0)
0.0020	0.0018	0.0021	0.0019	0.0019	0.0021	BJ	
0.0019	0.0026	0.0023	0.0023	0.0017	0.0010	NN	(0,2,0)
0.0018	0.0017	0.0019	0.0018	0.0017	0.0019	BJ	
0.0025	0.0033	0.0033	0.0029	0.0020	0.0014	NN	(0,1,1)
0.00188	0.0018	0.0019	0.0019	0.0019	0.0019	BJ	
0.0029	0.0040	0.0038	0.0029	0.0021	0.0017	NN	(0,1,2)
0.00198	0.0019	0.0020	0.0020	0.0020	0.0020	BJ	
0.0026	0.0035	0.0031	0.0028	0.0021	0.0015	NN	(0,2,1)
0.0021	0.0019	0.0022	0.0020	0.0020	0.0022	BJ	
0.0024	0.0026	0.0031	0.0026	0.0020	0.0013	NN	Average
0.0024	0.0022	0.0023	0.0023	0.0024	0.0025	BJ	

جدول (٥-٢)

قيم MSE للملاحظات الثلاثة المستقبلية لتنبؤات بوكس-جينكنز والشبكات مع أحجام عينات مختلفة

Average	Z_{n+3}	Z_{n+2}	Z_{n+1}	Method	Pred.horizon
					Sam.Size
0.0013	0.0013	0.0013	0.0013	NN	25
0.0026	0.0025	0.0027	0.0025	BJ	
0.0020	0.0020	0.0019	0.0020	NN	40
0.0024	0.0025	0.0023	0.0023	BJ	
0.0026	0.0026	0.0025	0.0026	NN	60
0.0023	0.0022	0.0024	0.0024	BJ	
0.0031	0.0031	0.0032	0.0030	NN	100
0.0023	0.0023	0.0022	0.0024	BJ	
0.0034	0.0034	0.0033	0.0034	NN	150
0.0022	0.0021	0.0023	0.0024	BJ	
0.0024	0.0025	0.0024	0.0024	NN	Average
0.0024	0.0023	0.0024	0.0024	BJ	


ومن خلال جدول (5-1)، و جدول (5-2) نلاحظ أن:

وفقا لحجم العينة: نلاحظ من جدول (5-1) أن أداء الطريقتين يتقارب بزيادة حجم العينة مع ملاحظة أن متوسط أداء الشبكات العصبية أفضل تقريبا لكل نموذج على حده

فعلى سبيل المثال نجد أنه عند حجم العينة 25 كانت قيمة مقياس MSE لتنبؤات الشبكات العصبية تساوى 0.0013 وهى أقل من قيمته بالنسبة لتنبؤات بوكس-جينكنز التي تساوى 0.0026 وبالتالي يكون أداء الشبكات العصبية هو الأفضل. ولكن بوجه عام فإن أداء طريقة الشبكات العصبية كان متعادلا مع أداء طريقة بوكس-جينكنز وذلك لان المتوسط العام للطريقتين كان 0.0024. ومن الممكن ملاحظة هذه النتائج من خلال الشكل البياني التالي:

شكل (١-٥)


قيم MSE لتنبؤات بوكس-جينكنز والشبكات العصبية وفقا لحجم العينة



وفقا للنموذج المحدد: نلاحظ من جدول (5-1) أن قيمة MSE لتنبؤات طريقة الشبكات العصبية كانت أقل من قيمتها لتنبؤات طريقة بوكس-جينكنز وذلك في حالة النماذج $ARMAX(1,2,0)$ ، $ARMAX(1,1,0)$ ، $ARMAX(1,1,1)$ ، وبالتالي كانت الأفضل مع تلك النماذج، بينما كانت قيمة MSE لتنبؤات طريقة بوكس-جينكنز أقل من قيمتها لتنبؤات طريقة الشبكات العصبية وذلك في حالة النماذج $ARMAX(0,2,0)$ ، $ARMAX(0,2,1)$ ، $ARMAX(0,1,2)$ ، $ARMAX(0,1,1)$ وبالتالي كانت الأفضل مع تلك النماذج. ومن الممكن ملاحظة هذه النتائج من خلال الشكل البياني التالي:

شكل (٥-٢)

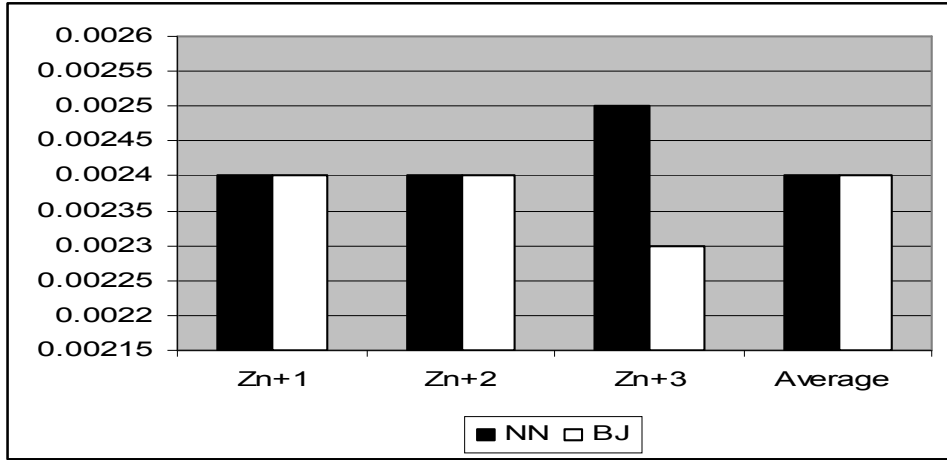
قيم MSE لتنبؤات بوكس-جينكنز والشبكات العصبية لنماذج ARMAX



وفقاً لأفق التنبؤ: نلاحظ في جدول (2-5) أن قيمة MSE لتنبؤات طريقة الشبكات العصبية للمشاهدات الثلاثة المستقبلية أقل من أو مساوية تقريباً لقيمتها لتنبؤات طريقة بوكس-جينكنز وحيث أن المتوسط العام للتنبؤ بالمشاهدات الثلاثة المستقبلية متساوياً للطريقتين إذا يمكن القول بتساوي أداء الطريقتين للتنبؤ بالمشاهدات المستقبلية. ومن الممكن ملاحظة هذه النتائج من خلال الشكل البياني التالي:

شكل (٣-٥)

قيم MSE للملاحظات الثلاثة المستقبلية لتنبؤات بوكس-جينكنز والشبكات العصبية



[٣-٥] مقارنة نتائج مقياس MAD

فيما يلي جدول (5-3) والذي يحتوى على نتائج مقياس MAD لكل من تنبؤات بوكس-جينكنز وتنبؤات الشبكات العصبية لنماذج ARMAX المحددة بأحجام عينات مختلفة، وكذلك جدول (5-4) يحتوى على نتائج مقياس MAD للملاحظات المستقبلية الثلاثة الأولى.

جدول (٣-٥)

قيم MAD لتنبؤات بوكس-جينكنز والشبكات العصبية موزعة وفقا لأحجام العينات ونماذج ARMAX المختلفة.

Average	150	100	60	40	25	Method	Sam.size
							P,h,q
0.0006	0.0007	0.0007	0.0006	0.0006	0.0004	NN	(1,1,0)
0.0014	0.0014	0.0014	0.0014	0.0014	0.0014	BJ	
0.0006	0.0008	0.0007	0.0006	0.0006	0.0004	NN	(1,2,0)
0.0013	0.0013	0.0013	0.0013	0.0013	0.0013	BJ	

Average	150	100	60	40	25	Method	Sam.size
							P,h,q
0.0006	0.0007	0.0007	0.0006	0.0005	0.0004	NN	(1,1,1)
0.0013	0.0013	0.0013	0.0013	0.0013	0.0014	BJ	
0.0005	0.0006	0.0006	0.0006	0.0005	0.0003	NN	(0,1,0)
0.0011	0.0011	0.0011	0.0011	0.0011	0.0011	BJ	
0.0005	0.0006	0.0006	0.0006	0.0005	0.0003	NN	(0,2,0)
0.0011	0.0010	0.0011	0.0011	0.0010	0.0011	BJ	
0.0006	0.0007	0.0007	0.0007	0.0005	0.0004	NN	(0,1,1)
0.0011	0.0011	0.0011	0.0011	0.0011	0.0011	BJ	
0.0007	0.0008	0.0008	0.0007	0.0005	0.0005	NN	(0,1,2)
0.0011	0.0011	0.0011	0.0011	0.0011	0.0011	BJ	
0.0006	0.0007	0.0007	0.0006	0.0005	0.0004	NN	(0,2,1)
0.0011	0.0011	0.0011	0.0011	0.0011	0.0012	BJ	
0.0006	0.0007	0.0007	0.0006	0.0005	0.0004	NN	Average
0.0012	0.0012	0.0012	0.0012	0.0012	0.0012	BJ	

جدول (٥-٤)

قيم MAD لطريقتي بوكس-جينكنز والشبكات العصبية موزعة وفقا لأحجام العينات والمشاهدات المستقبلية الثلاثة الأولى.


Average	Z_{n+3}	Z_{n+2}	Z_{n+1}	method	Pred.horizon
					Sam.Size
0.0004	0.0004	0.0004	0.0004	NN	25
0.0012	0.0012	0.0012	0.0012	BJ	
0.0005	0.0005	0.0005	0.0005	NN	40
0.0012	0.0012	0.0011	0.0012	BJ	
0.0006	0.0006	0.0006	0.0006	NN	60
0.0012	0.0012	0.0012	0.0012	BJ	
0.0007	0.0007	0.0007	0.0007	NN	100
0.0012	0.0012	0.0012	0.0012	BJ	
0.0007	0.0007	0.0007	0.0007	NN	150
0.0012	0.0011	0.0012	0.0012	BJ	
0.0006	0.0006	0.0006	0.0006	NN	Average
0.0012	0.0012	0.0012	0.0012	BJ	

ومن خلال جدول (5-3)، و جدول (5-4) نلاحظ أن:

وفقا لحجم العينة: نلاحظ من جدول (5-3) أن قيم MAD لتنبؤات طريقة الشبكات العصبية أقل من قيم MAD لتنبؤات طريقة بوكس-جينكنز وهذا يدل على أن أداء طريقة الشبكات العصبية أفضل من أداء طريقة بوكس-جينكنز مع كل أحجام العينات، أي أنه وبوجه عام فإن أداء طريقة الشبكات العصبية أفضل من طريقة بوكس-جينكنز وذلك لان المتوسط العام لطريقة الشبكات العصبية وهو 0.0006 كان أقل من المتوسط العام لطريقة بوكس-جينكنز هو 0.0012. ومن الممكن ملاحظة هذه النتائج من خلال الشكل البياني التالي.

شكل (٤-٥)

قيم MAD لتنبؤات بوكس-جينكنز والشبكات العصبية وفقا لحجم العينة




وفقا للنموذج المحدد: نلاحظ من جدول (5-3) أن قيم MAD لتنبؤات طريقة الشبكات العصبية كانت أقل من قيمتها لتنبؤات طريقة بوكس-جينكنز وذلك في حالة كل نماذج ARMAX المحددة، وبالتالي كانت الأفضل مع

كل تلك النماذج، كما كان المتوسط العام لقيم MAD في حالة تنبؤات طريقة الشبكات العصبية وهو يساوي 0.0006 أقل من قيمته في حالة تنبؤات طريقة بوكس-جينكنز الذي يساوي 0.0012. ومن الممكن ملاحظة هذه النتائج من خلال الشكل البياني التالي:

شكل (٥-٥)

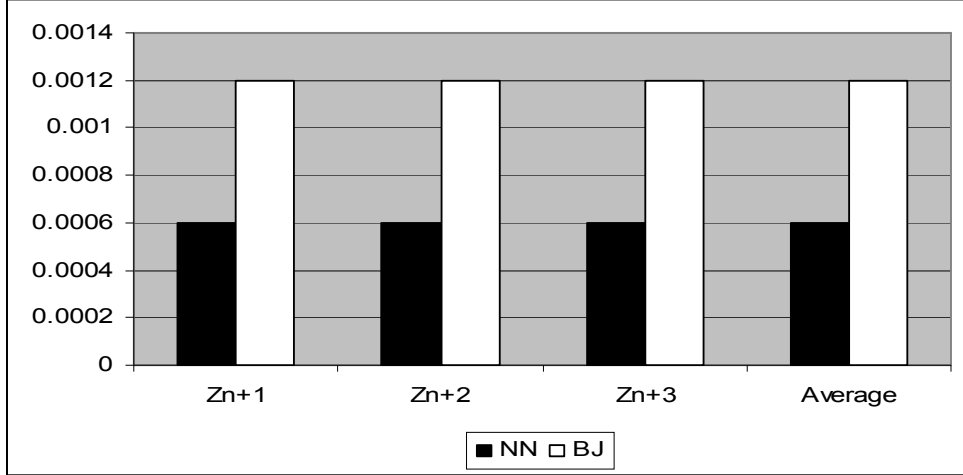
MAD لتنبؤات بوكس-جينكنز والشبكات العصبية نماذج ARMAX



وفقاً لأفق التنبؤ: نلاحظ من جدول (4-5) أن قيم MAD للملاحظات الثلاثة المستقبلية لتنبؤات طريقة الشبكات العصبية أقل من قيم MAD لتنبؤات طريقة بوكس-جينكنز وهذا ما يدل على أن أداء طريقة الشبكات العصبية كان أفضل من أداء طريقة بوكس-جينكنز للملاحظات الثلاثة المستقبلية. ومن الممكن ملاحظة هذه النتائج من خلال الشكل البياني التالي.

شكل (٥-٦)

قيم MAD للملاحظات الثلاثة المستقبلية لبوكس-جينكنز والشبكات العصبية



[٣-٥] مقارنة نتائج مقياس MAEP

فيما يلي جدول (5-5) يحتوي على نتائج مقياس متوسط نسبة الأخطاء المطلقة الأقل لتنبؤات الشبكات العصبية إلى بوكس-جينكنز MAEP مع نماذج ARMAX المحددة بأحجام عينات مختلفة، كذلك جدول (5-6) يحتوي على نتائج مقياس MAEP للثلاثة مشاهدات المستقبلية الأولى.

جدول (٥-٥)

قيم MAEP لنماذج ARMAX مع أحجام العينات المختلفة

Average	150	100	60	40	25	sam.size
						P,h,q
1.60576	1.4471	1.4634	1.4622	1.5274	2.1287	(1,1,0)
1.5335	1.2904	1.3637	1.5107	1.5013	2.0014	(1,2,0)
1.5111	1.2854	1.3023	1.3715	1.5993	1.9970	(1,1,1)
1.5436	1.3918	1.4337	1.4354	1.3547	2.1024	(0,1,0)
1.5782	1.4306	1.4411	1.2716	1.6115	2.1362	(0,2,0)
1.54158	1.4169	1.3975	1.3574	1.5951	1.9410	(0,1,1)
1.42622	1.2324	1.2024	1.3928	1.6167	1.6868	(0,1,2)
1.53322	1.3700	1.4579	1.4188	1.4985	1.9209	(0,2,1)
1.534148	1.3581	1.3828	1.4026	1.5381	1.9893	Average

جدول (٥-٦)

قيم MAEP للمشاهدات المستقبلية الثلاثة

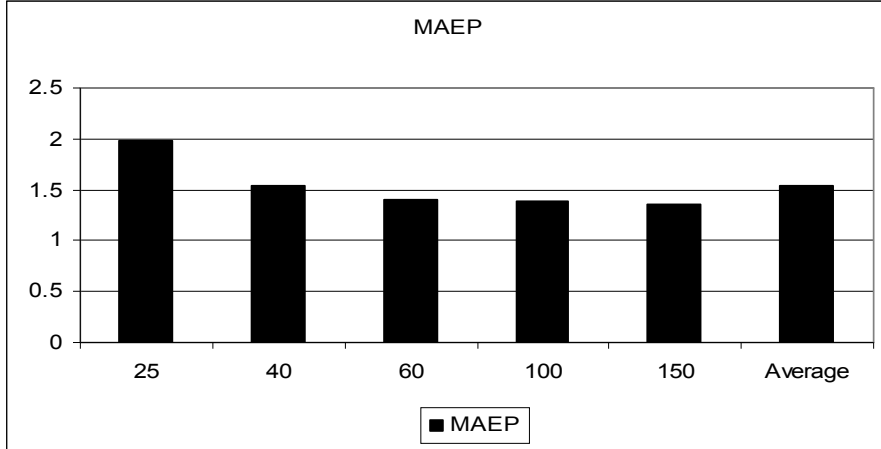
Average	Z _{n+3}	Z _{n+2}	Z _{n+1}	Pred. horizon
				sam.Size
1.9893	1.9696	2.0442	1.9541	25
1.5381	1.5731	1.5151	1.5260	40
1.4026	1.3750	1.4187	1.4140	60
1.3828	1.3700	1.3666	1.4117	100
1.3581	1.3342	1.3790	1.3610	150
1.5342	1.52438	1.54472	1.53336	Average

ومن خلال جدول (5-5)، و جدول (5-6) نلاحظ أن:

وفقا لحجم العينة: نلاحظ من جدول (5-5) أن قيم مقياس متوسط نسبة الأخطاء المطلقة الأقل للشبكات العصبية إلى بوكس-جينكنز (MAEP) تقل بزيادة حجم العينة حيث أنها كانت تمثل 198.93 % عند حجم العينة 25 ، ثم أصبحت 153.81 % عند حجم العينة 40 إلى أن وصلت 135.81 % عند حجم العينة 150 ، وهذا يدل على أن أداء طريقة الشبكات العصبية يكون أفضل من أداء طريقة بوكس-جينكنز إذا كانت حجم العينة صغير، بمعنى آخر يمكن القول أن أداء طريقة بوكس-جينكنز يتحسن بزيادة حجم العينة. وبوجه عام فان نسبة الأخطاء المطلقة الأقل للشبكات العصبية إلى بوكس-جينكنز MAEP في المتوسط كانت 1.5342% أي أن أداء طريقة الشبكات العصبية يفوق أداء طريقة بوكس-جينكنز بنسبة 53.42 % . ومن الممكن ملاحظة هذه النتائج من خلال الشكل البياني التالي:

شكل (٧-٥)

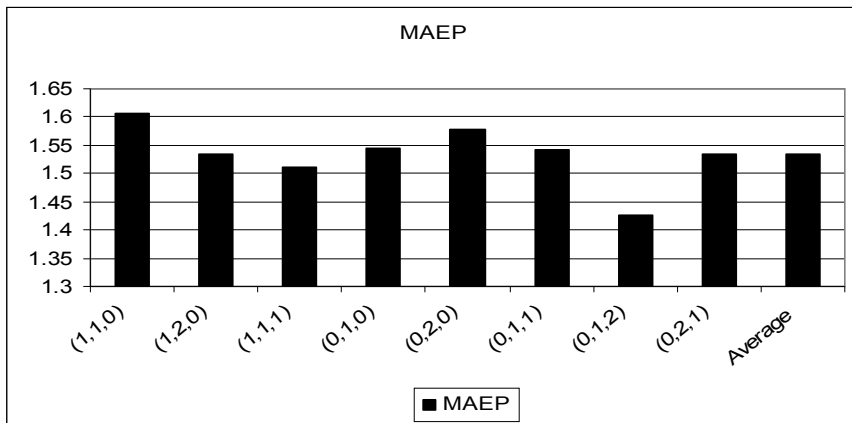
قيم متوسط النسب MAEP وفقا لحجم العينة



ووفقا للنموذج المحدد: نجد أن نسبة الأخطاء المطلقة الأقل للشبكات العصبية إلى بوكس-جينكنز والتي في جدول (5-5) بلغت أعلى قيمة لها مع نموذج $ARMAX(1,1,0)$ وكانت تساوي 160.576%، بينما كانت أقل قيمة لها مع نموذج $ARMAX(0,1,2)$ حيث كانت تساوي 142.622%. ومن الممكن ملاحظة هذه النتائج من خلال الشكل البياني التالي:

شكل (٨-٥)

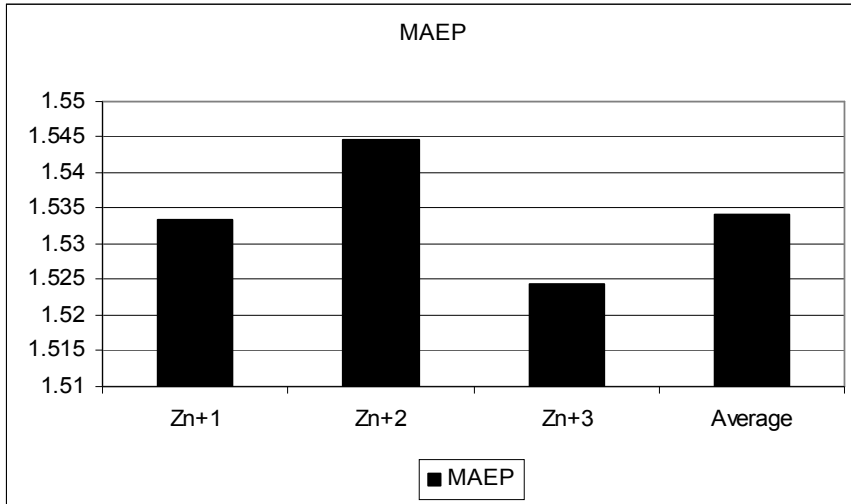
قيم متوسط النسب MAEP وفقا لنماذج ARMAX



وفقاً لأفق التنبؤ: نلاحظ في جدول (5-6) أن قيم مقياس متوسط نسبة الأخطاء المطلقة الأقل للشبكات العصبية إلى بوكس-جينكنز MAEP للملاحظات الثلاثة المستقبلية كبيرة بمعنى أنها تزيد عن نسبة 100%، وذلك يدل على تفوق أداء طريقة الشبكات العصبية على طريقة بوكس-جينكنز خلال فترة التنبؤ. ومن الممكن ملاحظة هذه النتائج من خلال الشكل البياني التالي.

شكل (٥-٩)

قيم MAEP للملاحظات المستقبلية الثلاثة



[٦] الخلاصة

يعتبر هذا البحث امتداداً لبحث (Alshawadfi(2003) والذي اقترح طريقة جديدة ومؤثرة للتنبؤ بنماذج ARMA باستخدام أحد طرق الذكاء الاصطناعي وهي طريقة الشبكات العصبية، كما قارن بين الطريقة المقترحة وطريقة بوكس-جينكنز. ويتضمن هذا البحث هدفين **أولهما**: تعميم طريقة Alshawadfi للتنبؤ بالسلاسل الزمنية المولدة من نماذج ARMAX باستخدام الشبكات العصبية الاصطناعية (ANN)، ولتحقيق هذا الهدف تم

توليد 32000 عينة بأحجام مختلفة (25-40-60-100-150) من نماذج ARMAX بمعلمات مختلفة تستخدم لتدريب الشبكة، بعد ذلك تم مقارنة البيانات المولدة بالبيانات الحقيقية لقياس دقة التنبؤات.

الهدف الثاني: مقارنة أداء الطريقة المقترحة للشبكات العصبية الاصطناعية مع أداء طريقة "بوكس و جينكنز" لتوضيح أي منهما أفضل للتنبؤ بنماذج ARMAX وذلك من خلال قياس دقة التنبؤات لكل من الطريقتين باستخدام ثلاث طرق هي متوسط مربعات الخطأ Mean of Squared Error (MSE)، متوسط الانحرافات المطلقة Mean Absolute Deviation (MAD)، نسبة الحالات التي تتحقق فيها أخطاء مطلقة أقل في الطريقتين The Percentage of cases of Minimum Absolute error (MAEP).

ولانجاز عملية تدريب الشبكة واختبارها وحساب تنبؤات طريقتي بوكس-جينكنز والشبكات العصبية مع المقارنة بين الطريقتين تم استخدام حزم برامج ماتلاب MATLAB. وتم تصميم صندوق أدوات لبرنامج ماتلاب MATLAB TOOLBOX مناسب ضمن حزم برامج ماتلاب MATLAB (أنظر الملحق المرفق مع البحث) لتوليد البيانات ٣٢٠٠٠ عينة و لانجاز عملية تدريب الشبكة واختبارها وحساب تنبؤات طريقتي بوكس-جينكنز والشبكات العصبية والمقارنة بينهما.

وقد أوضحت نتائج البحث القدرة العالية للطريقة المقترحة للتنبؤ لنماذج ARMAX باستخدام أحد طرق الذكاء الاصطناعي - وهي طريقة الشبكات العصبية - على التنبؤ بالقيم المستقبلية للسلسلة الزمنية المعطاة وذلك بطريقة آلية، حيث أظهرت النتائج من دراسة 32000 عينة والتي تم توليدها أن متوسط مربعات أخطاء التنبؤ MSE خاصة في حالة العينات الصغيرة، ومتوسط القيمة المطلقة لخطأ التنبؤ MAD، وكذلك متوسط النسبة

MAEP أفضل من نظيرتها في أسلوب بوكس-جينكز، وذلك كمتوسط عام بالنسبة لكل العينات وكل النماذج وللمشاهدات المستقبلية الثلاث الأولى. وبناء على ذلك يمكن القول بصلاحيّة الطريقة المقترحة للتنبؤ بالقيم المستقبلية للسلاسل الزمنية المولدة من نماذج ARMAX.

المراجع

أولاً: المراجع العربية

- (١) جعفر محمد حاجي، محمد عبد الهادي المحميد، (١٩٩٩م). "الشبكات العصبية: التنبؤ بأسعار صرف الدينار الكويتي مقابل الدولار الأمريكي"، المجلة العربية للعلوم الإدارية، مجلد ٦، عدد ١، يناير (١٩٩٩)، ص ١٧ - ٣٥.
- (٢) ميشيل نجينفيتسكي، (٢٠٠٤م). " الذكاء الصناعي دليل النظم الذكية " تعريب سرور على إبراهيم سرور، دار المريخ للنشر، الرياض، المملكة العربية السعودية، ص ٢٥٢.

ثانياً: المراجع الأجنبية

- (1) Arminger, G. and Enache, D. (1996), "Statistical Models and Artificial Neural Networks". In: Bock, H.H. and Polasek, W. (Eds.): *Data Analysis and Information Systems*, Vol. 7, Springer Verlag, Heidelberg, 243-260.
- (2) Al-Shawadfi, Gamal A.(1994). "Bayesian Inference of ARMAX Models", Scientific Magazine, Faculty of Commerce, Al-Azhar University, Cairo, Egypt, Vol. 20 July 1994.
- (3) Al-Shawadfi, Gamal A.(1996). "Bayesian Estimation for the Parameters of the Seasonal ARMAX Models", Scientific Magazine, Faculty of Commerce, Ain Shams University Cairo, Egypt, Vol. 1 July 1996,PP. 139-151.

- (4) Al-Shawadfi, Gamal A.(1997). "The Derivation of Bayesian Predictive Density for the Seasonal ARMAX Model", Scientific Magazine, Faculty of Commerce Tanta University, Vol.1 April 1997, Tanta, Egypt.
- (5) Al-Shawadfi, Gamal A.(2003). " A comparison between neural network and Box-Jenkins Forecasting Techniques With Application to Real data " King Saud University, King Fahd National Library Cataloging-in-Publication Data.
- (6) Box, G. E. P., Jenkins, G. M., and Reinsel, G. C. (1994). "Time Series Analysis, Forecasting and Control", (3rd ed.), Englewood Cliffs, NJ: Prentice-Hal l, p (151).
- (7) Cybenko, g.(1989). "Approximation by superposition of sigmoidal functions ", Mathematics of control, Signals and Systems, 2, 303-314.
- (8) Demuth H. & Beale M. (1998). " Neural Networks Toolbox: Users Guide, Version 3.0", The Math Works inc Natick, MA.
- (9) Harvey, A. C. and Phillips, G. A.(1977). "A comparison of Estimators in the ARMA (1,1)model", University of Kent(Unpublished Paper).
- (10) Hijazi, D. (2007), "Predicting the stock market method of using artificial neural cells.", M.A. Thesis Department of Statistics, Faculty of Economics and Political Science, Cairo University, Cairo, Egypt.
- (11) Shaarawy S. and Ismail M. A., (1987). "Bayesian inference for seasonal ARMA models", Egypt. Statist. J. 31, 323-336.
- (12) Turban, E., Aronson J. and Liang T. (2005). "Decision Support Systems and Intelligent Systems ". 7th edition Prentice Hall.
- (13) Zurada, J. M. (1992). "Artificial Neural Systems".1st ed. St. Paul, MN., West Publishing Company.

ملحق

MATLABTOOLBOX

تدريب الشبكة واختبارها وحساب تنبؤات طريقتي بوكس-جينكيز والشبكات العصبية مع المقارنة بينهما باستخدام ٣٢٠٠٠ عينة مولدة بالكمبيوتر

```
%.. toolbox for Time Series Forecasting Training &Testing Using Neural Network
Technique
%....file name : train2010...output file out2010.mat , out2010';
diary('outout2010')
clear all;
tic;
mu=0; sigma=1; mm=60; m=mm-10; n=1; m0=500; n1=32; n2=8; n3=4; h=3;
ss01(n2,h)=0.0;ss02(n2,h)=0.0;sb01(n2,h)=0.0;sb02(n2,h)=0.0;ss(n2,h)=0;sb(n2,h)=0;
p=[1 1 0; 1 1 0; 1 1 0; 1 1 0; 1 2 0; 1 2 0; 1 2 0; 1 2 0; 1 1 1; 1 1 1; 1 1 1;1 1 1;
  0 1 0; 0 1 0; 0 1 0; 0 1 0; 0 2 0; 0 2 0; 0 2 0; 0 2 0; 0 1 1; 0 1 1; 0 1 1; 0 1 1;
  0 1 2; 0 1 2; 0 1 2; 0 1 2; 0 2 1; 0 2 1; 0 2 1; 0 2 1];
a=[.3 .5 .7 .9 .3 .5 .7 .9 .3 .5 .7 .9 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0;
  0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0;
  0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0;
  .3 .5 .7 .9 .3 .3 .5 .5 .3 .5 .7 .9 .3 .5 .7 .9 .3 .3 .5 .5 .3 .5 .7 .9 .3 .5 .7 .9 .3 .3 .5 .5;
  0 0 0 0 -.5 .5 -.7 .3 0 0 0 0 0 0 0 0 -.5 .5 -.7 -.5 0 0 0 0 0 0 0 0 0 0 -.5 .5 -.7 -.5;
  0 0 0 0 0 0 0 0 .3 .5 .7 .9 0 0 0 0 0 0 0 0 .3 .5 .7 .9 .3 .3 .5 .5 .3 .5 .7 .9;
  0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 -.5 .5 -.7 -.5 0 0 0 0];
' 1..... initialization arrays .....';
for i=1:m0;
e(mm,1)=0.0;e0(m,1)=0.0;
E(mm,1)=0.0; E0(m,1)=0.0;
x(mm,n1)=0;y(mm,n1)=0;
% .....generating samples.. .....;
e=normrnd(mu,sigma,mm,n);
E=normrnd(mu,sigma,mm,n);
x(1,:)= e(1)*ones(1,n1);
x(2,:)= e(2)*ones(1,n1) + a(3,:).*x(1,:);
y(1,:)= E(1)*ones(1,n1);
y(2,:)= E(2)*ones(1,n1)+ a(1,:).*y(1,:)+ a(3,:).*x(2,:)- a(4,:).*x(1,:)-a(6,:)*E(1);
for i1=3:mm;
x(i1,:)= e(i1)*ones(1,n1) + a(4,:).*x(i1-1,:) + a(5,:).*x(i1-2,:);
y(i1,:)= E(i1)*ones(1,n1) + a(1,:).*y(i1-1) + a(2,:).*y(i1-2)+ a(3,:).*x(i1) -
a(4,:).*x(i1-1) - a(5,:).*x(i1-2)-a(6,:).*E(i1-1,:)-a(7,:).*E(i1-2,:);
end;
x0=x(11:mm,:); x1=x0(1:(m-h),:); x2=x0((m-h+1):m,:);
y0=y(11:mm,:); y1=y0(1:(m-h),:); y2=y0((m-h+1):m,:);
z=[x0; y0] ; z0=unstk(z,m,2*n1); z1=z0(1:(m-h),:); z2=z0((m-h+1):m,:);
if i==1;
xx = x0 ; xx1= x1 ; xx2 = x2 ;
yy = y0 ; yy1= y1 ; yy2 = y2 ;
zz = z0 ; zz1= z1 ; zz2 = z2 ;
else;
xx = [xx x0] ; xx1= [xx1 x1] ; xx2 = [xx2 x2];
yy = [yy y0] ; yy1= [yy1 y1] ; yy2 = [yy2 y2] ;
zz = [zz z0] ; zz1= [zz1 z1] ; zz2 = [zz2 z2];
```

```

end; end;
%2.....transforming data.....;
xx0 = 0.8*(xx-ones(m,1)*min(xx))./(ones(m,1)*(max(xx)-min(xx)))+0.1;
xx01 = xx0(1:(m-h),:); xx02=xx0((m-h+1):m,:);
yy0 = 0.8*(yy-ones(m,1)*min(yy))./(ones(m,1)*(max(yy)-min(yy)))+0.1;
yy01 = yy0(1:(m-h),:); yy02=yy0((m-h+1):m,:);
zz0 = 0.8*(zz-ones(m,1)*min(zz))./(ones(m,1)*(max(zz)-min(zz)))+0.1;
zz01 = zz0(1:(m-h),:);zz02=zz0((m-h+1):m,:);
%3.....training ,testing and predicting phase.....;
j00=0
for j = 1 : m0;
for j0 = 1 : n1;
j00 = j00 + 1
j1 = fix((j0-1)/n3)+1;
zz00 = zz0(:,2*j00-1:2*j00);zz001= zz01(:,2*j00-1:2*j00);
z000 = zz(:,2*j00-1:2*j00);z0001= zz1(:,2*j00-1:2*j00);
yy00 = yy0(:,j00) ; yy001= yy01(:,j00); yy002 = yy02(:,j00);
y000 = yy(:,j00) ; y0001= yy1(:,j00) ; y0002 = yy2(:,j00);
net =newff([0 1;0 1],[3 1],{'logsig' 'tansig'});
% net=init(net);
net.trainparam.epochs =50;
%net.trainparam.gole =0.001;

net = train(net,zz00',yy00');
f = sim(net,zz00');
YN = min(y000)+(f - 0.1)*(max(y000)- min(y000))/0.8;
pc = [p(j0,:), 1] ;
th = armax(z000,pc);
YB = predict(z000,th,h);
for j3=1:h;
s01 = abs(y0002(j3)-YN(m-h+j3));
b01 = abs(y0002(j3)-YB(m-h+j3));
s02 = (s01)^2;
b02 = (b01)^2;
ss01(j1,j3) = ss01(j1,j3) + s01;
sb01(j1,j3) = sb01(j1,j3) + b01;
ss02(j1,j3) = ss02(j1,j3) + s02;
sb02(j1,j3) = sb02(j1,j3) + b02;
if s01 < b01 ; ss(j1,j3) = ss(j1,j3)+1;
elseif s01 ==b01 ;sb(j1,j3)=sb(j1,j3)+0.5
; ss(j1,j3) = ss(j1,j3)+0.5;
else;s01 > b01 ; sb(j1,j3) = sb(j1,j3)+1;
end; end; end; end;

ss03=(ones(1,n2)*ss01)/(n2*n3*m0);
sb03=(ones(1,n2)*sb01)/(n2*n3*m0);

ss04=(ss01*ones(h,1))/(h*n3*m0);
sb04=(sb01*ones(h,1))/(h*n3*m0);

ss05=(ones(1,n2)*ss02)/(n2*n3*m0);

```



```

sb05=(ones(1,n2)*sb02)/(n2*n3*m0);

ss06=(ss02*ones(h,1))/(h*n3*m0);
sb06=(sb02*ones(h,1))/(h*n3*m0);

ss3=(ones(1,n2)*ss)/(n2*n3*m0);
sb3=(ones(1,n2)*sb)/(n2*n3*m0);

ss4=(ss*ones(h,1))/(h*n3*m0);
sb4=(sb*ones(h,1))/(h*n3*m0);

s1=sum(ss03)/h;
s11=sum(sb03)/h;

s2=sum(ss05)/h;
s22=sum(sb05)/h;

s3=sum(ss3)/h;
s4=sum(sb3)/h;

' 4 comparison between Neural Network and BOX JENKINS forecasts ...Final
results.....';
disp 'mse results'
MSE=[ss02,ss06;[ss05,s2]]
MSE1=[sb02,sb06;[sb05,s22]]

disp 'mae results'
MAE=[ss01,ss04,;[ss03,s1]]
MAE1=[sb01,sb04,;[sb03,s11]]
disp 'nnf results'
mnnf=[ss/(n3*m0),ss4;[ss3,s3]]
disp 'box_jenkins ratios results'
'RATIO results'
ssb = ss./(n3*sb)
RATIO = [ssb,sum(ssb,2)/h;sum(ssb,1)/n2,sum(ssb(:))/(n2*h)]
save 'out2010'
%diary off;
toc

```

Artificial intelligence and time series analysis

Prof. Dr. Gamal Alshawadfi
Head of Statistics Department
MAIL: Dr_Gamal1@yahoo.com
Mobile: 0020-01066543923

Dr. Abd El-Wahab Hagag
Assistant professor
MAIL: Wahabstat@yahoo.com
Mobile: 0020-01224709386

Faculty of Commerce, Al-Azhar University

Abstract

This paper has two objects. First, we present artificial neural networks method for forecasting linear and nonlinear ARMAX time series. Second, we compare the proposed method with the well known Box-Jenkins method through a simulation study . To achieve these objects 32000 samples, generated from different ARMAX models, different sizes (25,40,60,100,150), were used for the network training. Then the system was tested for generated data . The accuracy of the neural network forecasts(NNF) is compared with the corresponding Box-Jenkins forecasts(BJF) by using three tools: the mean square error (MSE) , the mean absolute deviation of error (MAD) and the ratio of closeness from the true values (MPE) . A suitable computer program was designed (MATLAB TOOLBOX) for NN training , testing and comparing with Box-Jenkins method .

The forecasts of the proposed NN approach, as shown from three measures, seem to provide better results than the classical forecasting Box-Jenkins approach . The results suggest that the ANN approach may provide a superior alternative to the Box-Jenkins forecasting approach for developing forecasting models in situations that do not require modeling of the internal structure of the series .

The numerical results show that the proposed approach has a good performance for the forecasting of ARMAX(p,h,q) models.