

طريقة مقترحة للتنبؤ بدوال التحويل باستخدام

الذكاء الاصطناعي

نادر فتحي متولي

مدرس مساعد بقسم الإحصاء

MAIL:Nader_help@yahoo.com

عبد الوهاب السيد حجاج

مدرس بقسم الإحصاء

MAIL:Wahabstat@yahoo.com

كلية التجارة - جامعة الأزهر

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. "، كما يعد هذا البحث امتدادا لبحث الشوادفي، حجاج (٢٠١٣) والذي قدما فيه طريقه جديدة للتنبؤ بنماذج ARMA-X، باستخدام طريقه الشبكات العصبية أيضا، ويتضمن هذا البحث هدفين:

أولهما: تعميم طريقة Alshawadfi، والشوادفي حجاج (٢٠١٣) للتنبؤ بالسلاسل الزمنية المولدة من نماذج دالة التحويل باستخدام الشبكات العصبية الاصطناعية (ANN)، ولتحقيق هذا الهدف تم توليد 96000 عينة بأحجام مختلفة (150-100-60-40-25) من نماذج دالة التحويل 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 دالة التحويل 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 دالة التحويل 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-جينكنز، وذلك كمتوسط عام بالنسبة لكل العينات وكل النماذج وللمشاهدات المستقبلية الثلاث الأولى. وبناء على ذلك يمكن القول بصلاحية الطريقة المقترحة للتنبؤ بالقيم المستقبلية للسلاسل الزمنية المولدة من نماذج دالة التحويل

[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 بدلاً 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

تحاكى 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 إمكانياته 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، والتمييز 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، و يعتبر 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 والهندسية 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 وبينوا 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 بيزر 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 والذي مازال يفوق كل الأساليب الحديثة لتحليل السلاسل الزمنية، إلا أن تطبيق هذا الأسلوب بشكل دقيق يتطلب مهارة وممارسة قد لا تتوفر في كثير من غير المتخصصين، علاوة على ذلك فإننا نعيش اليوم عصر المعلوماتية والعالم الرقمي الذي يحوى كل أنشطة المال والأعمال في بيئة متكاملة ومنتشبكة، 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 Neural Artificial من أهم الطرق المرنة التي لديها القدرة على التعلم الذاتي السريع وسرعة التغير 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 مشكلة البحث أنه في حالة تحليل السلاسل الزمنية المولدة من نماذج دوال التحويل في وجود علاقة غير خطية للأخطاء مع معالم النموذج في هذه الحالة يكون لدالة الإمكان شكلاً معقداً بسبب أن الأخطاء لها علاقة غير خطية في المعلمات مما يصعب معه تحديد شكل التوزيع الاحتمالي لبعض أو كل معالم النموذج في شكل قياسي أو باستخدام أحد التوزيعات المعروفة وأيضاً عند

استخدام أسلوب بيز حيث يصعب إيجاد " مصفوفة التباين والتغاير " ومحدد مصفوفة التباين والتغاير، واختيار دالة احتمال قبلية مناسبة لها، خاصة مع زيادة حجم العينة، بالإضافة إلى ذلك توجد صعوبة عملية في التحليل التقليدي لنماذج دوال التحويل والتي تحتاج إلى خبرة كبيرة لاختبار النموذج المناسب وتقدير م عالمه والتحقق من صلاحيته قبل استخدامه في التنبؤ. ولتجنب مثل هذه المشاكل نحتاج إلى طريقة جديدة للتنبؤ بخلاف الطرق الإحصائية التقليدية، وهذه الطريقة هي الشبكات العصبية الاصطناعية، حيث تمتاز هذه الطريقة بأنها تعمل بصورة آلية لاختيار نموذج يوضح كيفية اعتماد المخرجات على

[٢-١] هدف البحث :

يُعد هذا البحث امتدادا لبحث **Alshawadfi 2003** والذي اقترح طريقة جديدة ومؤثرة للتنبؤ بنماذج ARMA باستخدام طرق الذكاء الاصطناعي Artificial Intelligent وهي طريقه الشبكات العصبية Neural Networks، كما قارن الطريقة المقترحة بطريقة "بوكس وجينكنز"، كما يعد هذا البحث امتدادا لبحث **الشوادفي، حجاج (٢٠١٣)** والذي قدم فيه طريقه جديدة للتنبؤ بنماذج X -ARMA، باستخدام طريقه الشبكات العصبية أيضا، وعلي ذلك يتضمن البحث الحالي هدفين:

- الهدف الأول: تعميم طريقتي (2003) **Alshawadfi** والشوادفي حجاج (٢٠١٣) للتنبؤ بالسلاسل الزمنية المولدة من نماذج دالة التحويل (**transfer function**) باستخدام الشبكات العصبية الاصطناعية (ANN)، ولتحقيق هذا الهدف يتم توليد 96000 عينة بأحجام مختلفة من نماذج دالة التحويل بمعلمات مختلفة تستخدم لتدريب الشبكة عن طريق

تصميم برنامج ماتلاب Matlab لإجراء دراسة المحاكاة ومقارنة الطريقة المقترحة بالطريقة التقليدية.

■ الهدف الثاني: مقارنة أداء الطريقة المقترحة للشبكات العصبية الاصطناعية مع أداء طريقة " بوكس و جينكنز " لتوضيح أي منهما أفضل للتنبؤ بنماذج دالة التحويل 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

[١-٣] أهمية البحث

تأتي أهمية البحث في استخدامه لأحد طرق الذكاء الاصطناعي وهي طريقة الشبكات العصبية في التنبؤ بالسلاسل الزمنية المولدة من نماذج دالة التحويل 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.

[٤-١] الدراسات السابقة

لقد قامت العديد من الأبحاث بدراسة السلاسل الزمنية وكذلك الشبكات العصبية ولكن قليل من الدراسات هي التي تناولت استخدام الشبكات العصبية بالتنبؤ بقيم السلاسل الزمنية بوجه عام ودالة التحويل بوجه خاص وهذا ما يتعلق بمجال هذا البحث نذكر منها ما يلي:

ففي دراسة (2003) Alshawadfi تم تقديم جديدة ومؤثرة للتنبؤ بالسلاسل الزمنية استخدم تقنية الشبكات العصبية الاصطناعية Artificial Neural Network (ANN)، كما قارن بين الطريقة المقترحة وطريقة بوكس-وجنيكنز. و تم استخدام حزم برامج ماتلاب Matlab لتصميم برنامج كمبيوتر مناسب لتوليد البيانات ولانجاز عمليه تدريب الشبكة واختبارها وحساب تنبؤات الطريقة التقليدية وطريقة الشبكات العصبية والمقارنة بينهما وقد أظهر البحث صلاحية الطريقة المقترحة للتنبؤ بالقيم المستقبلية للسلاسل الزمنية باستخدام الشبكات العصبية

ثم جاءت دراسة عاشور (٢٠٠٩) بمناقشة وظيفة دالة التحويل Transfer Function للتنبؤ بالنقد المستلم ومعرفة شكل التدفق النقدي للفترة القادمة حتى تتمكن الإدارة من التخطيط والسيطرة وتقويم الأداء واتخاذ القرار وتقويم أداء نشاط المبيعات للشركة العامة لتوزيع الكهرباء ببغداد.

وفي دراسة (2011) Liu, Lon-Mu قورنت التنبؤات المنتجة بواسطة نموذج دالة التحويل المتزامن ونموذج انحدار الاضطرابات الهادئة مع تنبؤات نموذج الانحدار الذاتي المتكامل مع المتوسط المتحرك [ARIMA] أحادي المتغير

استهدفت دراسة الوصيفي (٢٠١٢) في الوصول إلى نموذج مناسب للتنبؤ بمؤشر البورصة EGX30 وتناولت الدراسة تطبيق الأساليب الآتية: (١) أسلوب الشبكات العصبية (٢) أسلوب تحليل السلاسل الزمنية باستخدام نموذج بوكس وجينكنز. (٣) أسلوب الدمج بين الشبكات العصبية وتحليل السلاسل الزمنية باستخدام البواقي والقيم المقدرة من نموذج ARIMA وقد تمت المقارنة بين تلك الأساليب باستخدام معايير قياس دقة التنبؤ واتضح من خلالها أن أنسب أسلوب للتنبؤ بمؤشر البورصة هو أسلوب الدمج.

وفي دراسة الشوافي وحجاج (٢٠١٣) تم تقديم طريقه جديدة ومؤثره للتنبؤ بنماذج ARMA-X باستخدام طريقه الشبكات العصبية، ويعتبر هذا البحث امتدادا لبحث (2003) Alshawadfi كما قارن بين الطريقتين التقليدية وللتنبؤ بنماذج ARMA-X وقد أظهرت نتائج البحث وجود قدرة عالية للطريقة المقترحة للتنبؤ بنماذج دالة التحويل باستخدام طريقة الشبكات العصبية.

وفي دراسة دريال (٢٠١٤) تم مقارنة نماذج خطية وغير خطية للتنبؤ بمؤشر سوق دبي المالي وتوصلت الدراسة إلى أن نموذج الشبكات العصبية الاصطناعية ANN لديه قدرة أكبر على التنبؤ مقارنة بنموذج الانحدار الذاتي المشروط بعدم تجانس الأخطاء المعمم GARCH

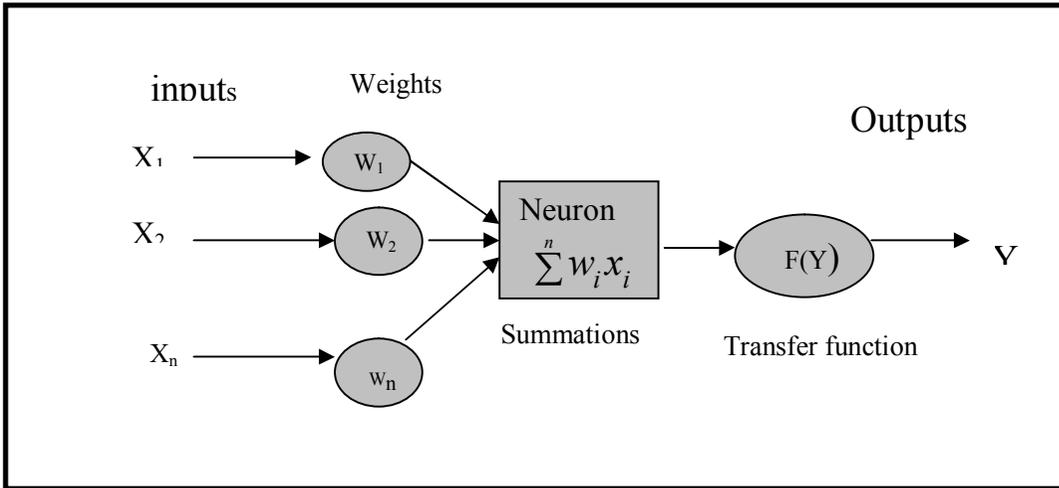
ولقد تناولت دراسة إبراهيم (٢٠١٥) مقارنة دقة التنبؤ بالسلاسل الزمنية متعددة المتغيرات باستخدام نماذج دالة التحويل ونماذج الشبكات العصبية الاصطناعية وذلك بالتطبيق على بيانات مولدة عبارة عن سلاسل زمنية ثنائية المتغيرات ، وتوصلت الدراسة إلى أن نماذج دالة التحويل أكثر دقة في التنبؤ من نماذج الشبكات العصبية الاصطناعية في البيانات المدروسة.

[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، و المحميد، (١٩٩٩)، ص ١٩).

شكل (١-٢)

نموذج لوحدة تشغيل



والشكل (١-٢) السابق يبين وحدة تشغيل بسيطة داخل الشبكة العصبية (انظر: (Turban, et al. (2005)).، حيث يكون لكل وحدة تشغيل مسار إدخال واحد أو أكثر تنحصر 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 تنتقل المعلومات كـمخرجات 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 وتعتبر عن درجة أهمية المدخلات،، وحاصل الجمع summations يتم معالجته باستخدام دالة تحويل $F(Y)$ Transfer function لنحصل منها على إشارات المخرجات Output Signals(Y)

[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)). ويتم تعليم أو تدريب الشبكة العصبية على اكتشاف العلاقات النمطية في البيانات بإتباع إحدى الطرق الآتية:

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

تعد هذه الطريقة هي الأكثر انتشاراً في تدريب الشبكة العصبية، وفيها تجمع عينات من البيانات تحتوي 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 الخارجية، 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 ومقارنة داخل كل مجموعة.

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

هذه الطريقة 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 خطئها كما في طريقة التعليم الإشرافية.

[٢-٢] الميكل العام للشبكة Typical Architectures

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 (1-2) 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:

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

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

وتجدر الإشارة إلى أنه بجانب دالة الخطوة يوجد كثير من دوال التنشيط ولكن وجد أن قلة فقط منها لها تطبيقات عملية و من أهم هذه الدوال ما يلي:

دالة الإشارة Sign Function ٢- دالة الخطوة Step Function

الدالة الخطية Linear Function ٤- الدالة التجميعية Function

Sigmoid وعادة تستخدم دالة الإشارة Sign Function و دالة الخطوة

Step Function للخلايا العصبية في اتخاذ القرارات لمهام التصنيف، وتميز

الأنماط. (انظر على سبيل المثال: نجينفيتسكي، (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

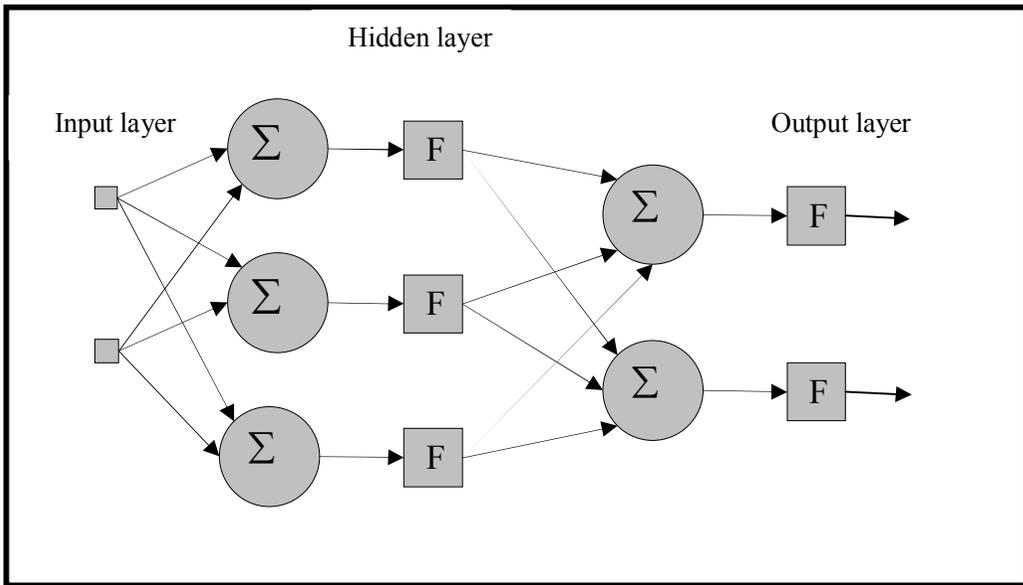
خطية. (أنظر: (Alshawadfi (2003).

[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 (2-2)

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).

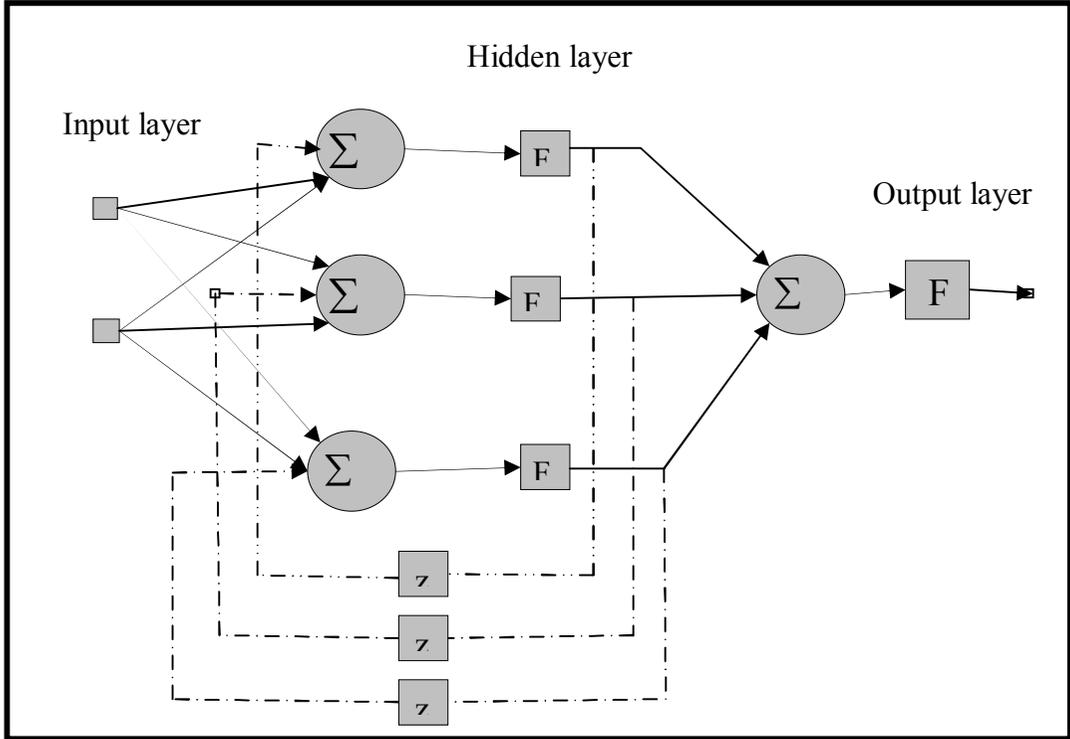
أما بالنسبة لعملية التعليم فإنها تستمر بنفس الطريقة في الشبكة وحيدة الطبقة، حيث تحدث الأوزان باستخدام التعلم بالتغذية الخلفية Backward propagation Learning، وقبل هذا التحديث يوجد خطوتين متتاليتين أولهما أمامية Forward والأخرى تراجعية Backward، ففي الخطوة الأمامية يتم حساب مخرجات الشبكة من البيانات المدخلة، ومقارنة هذه المخرجات مع المخرجات المستهدفة عن طرق حساب الخطأ. أما في الخطوة التراجعية فنقوم 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، و هذا النوع يحتوي على حلقة تغذية خلفية واحدة على الأقل (مسار مغلق من التغذية الخلفية feedback loop) كما في الشكل (2-3)، 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 (3-2)

الشبكة متعددة الطبقات ذات التغذية مرتدة



[٣] نماذج دوال التحويل Transfer Function Models

تستخدم نماذج دوال التحويل Transfer Function Models بكثرة في نمذجة العلاقة بين سلسلتين زمنيتين حيث السلسلة الأولى تمثل المتغير الخارج Output Variable والأخرى تمثل المتغير الداخل Input Variable. وتأخذ العلاقة الشكل التالي:

$$Y_t = v_0 X_t + v_1 X_{t-1} + \dots + v_p X_{t-p} + \varepsilon_t$$

$$Y_t = v(B)X_t + e_t \quad (3-1)$$

حيث أن

B : مشغل الإزاحة للخلف Backshift Operator $[BX_t = X_{t-1}]$.

ε_t : هي متغير عشوائي مستقل تتبع توزيع معتدل بمتوسط 0 وتباين σ_ε^2 .

Y_t : هي المشاهدة Y عند الزمن t (تمثل المتغير الخارج).

X_t : هي متغيرات مستقلة عن e_t (تمثل المتغير الداخل).

$v(B)$: هي كما يلي

$$v(B) = (v_0 + v_1 B + v_2 B^2 + \dots + v_p B^p)$$

وتمثل كل من v_0, v_1, \dots, v_p أوزان نبضات الاستجابة Impulse

Response Weight والتي تعكس الأثر الحادث على Y_t نتيجة تغير X_t

بوحددة واحدة.

ويمكن وضع النموذج $v(B)$ على الصورة الآتية:

$$V(B) = \frac{\omega(B)}{\delta(B)} \quad (3-2)$$

حيث

$$\omega(B) = \omega_0 - \omega_1 B - \omega_2 B^2 - \dots - \omega_s B^s$$

$$\delta(B) = \delta_0 - \delta_1 B - \delta_2 B^2 - \dots - \delta_r B^r$$

وبالتعويض عن قيمة $V(B)$ في نموذج دوال التحويل نحصل على الصيغة

الآتية:

$$Y_t = v(B)X_t + \varepsilon_t = \frac{\omega(B)}{\delta(B)}X_t + \varepsilon_t \quad (3-3)$$

وحيث أن X_t لا تؤثر على المتغير Y_t مباشراً (فورياً) أي يوجد Dead time (b) وبذلك تكون الصيغة العامة لنماذج دوال التحويل هي

$$Y_t = \frac{\omega(B)}{\delta(B)}X_{t-b} + \varepsilon_t \quad (3-4)$$

وبفرض أن العملية (X_t, Y_t) ساكنة حيث $y_t = \nabla^d Y_t, x_t = \nabla^d X_t$

حيث $d, d \setminus$ تشير الفروق الأزمنة لتسكين لكلا من x_t, y_t على الترتيب، فليس من الضروري استخدام نفس نظام المشغل للفروق لكل متغير من متغيرات النموذج.

وبالتالي تكتب المعادلة (3-1) كما يلي

$$y_t = v(B)x_t + e_t \quad (3-5)$$

حيث $e_t = \nabla^d \varepsilon_t$ وبافتراض أن e_t تتبع عملية ARMA(p,q)

$$\nabla^d e_t = \frac{\theta(B)}{\phi(B)}a_t \quad (3-6)$$

حيث

$$\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q$$

$$\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$$

وبالتعويض في العلاقة (3-3) باستخدام العلاقة (3-6) نجد أن صيغة النموذج

هي:

$$\nabla^d y_t = \frac{\omega(B)}{\delta(B)} \nabla^d X_{t-b} + \frac{\theta(B)}{\phi(B)} a_t$$

وفي حالة وجود أكثر من متغير مستقل $(x_i, i = 1, 2, \dots, m)$ يمكن كتابة النموذج على الصورة التالية:

$$y_t = \sum_{i=1}^m \frac{\omega_i(B)}{\delta_i(B)} X_{i,t-b} + \frac{\theta(B)}{\phi(B)} a_t$$

حيث تشير m إلى عدد المتغيرات المستقلة في النموذج، وبفرض أن جميع جذور كثيرات الحدود تقع $\omega_i(B), \delta_i(B), \theta(B), \phi(B)$ تقع خارج دائرة الوحدة.

[٤] نموذج شبكات عصبية مقترح لتحليل السلاسل الزمنية

من الممكن اعتبار الشبكات العصبية الاصطناعية كنموذج انحدار غير خطى يتكون من المتغيرات المدخلة وتتمثل في القيم الماضية للسلسلة $X_{t+1}, X_{t+2}, \dots, X_{t+h}$ أو تحويلاتها وقيم متغير خارجي $Y_{t+1}, Y_{t+2}, \dots, Y_{t+p}$ والأخطاء $\varepsilon_{t+1}, \varepsilon_{t+2}, \dots, \varepsilon_{t+q}$

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

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

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 $E(\varepsilon / X) = 0$ وكذلك الدالة

$v(x) = E(Z / X)$ غالبا ما تكون غير معلومة ويتم تقريبها بواسطة الدالة

حيث W تمثل متجه المعالم وتسمى الأوزان، والتي تكون عنصر في فراغ المعالم parameter space وتقدر من مجموعة البيانات المدربة (العينة sample)، 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+1} في نموذج دالة التحويل كمجموع مرجح من المشاهدات السابقة للسلاسل y_t و x_t بالإضافة إلى المتغير العشوائي ε_t (أنظر Box (1994), p.446 (Jenkins and Reinsels)، أي أنه يصبح كنموذج ARX كما يلي:

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

حيث تمثل π و η 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 يساوي الواحد الصحيح:

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

بالإضافة إلى أنه من الممكن لنموذج دالة التحويل أن يكون حالة خاصة لعملية

الشبكة العصبية في المعادلة (4-1) بكتابة $v(X)$ كما يلي:

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

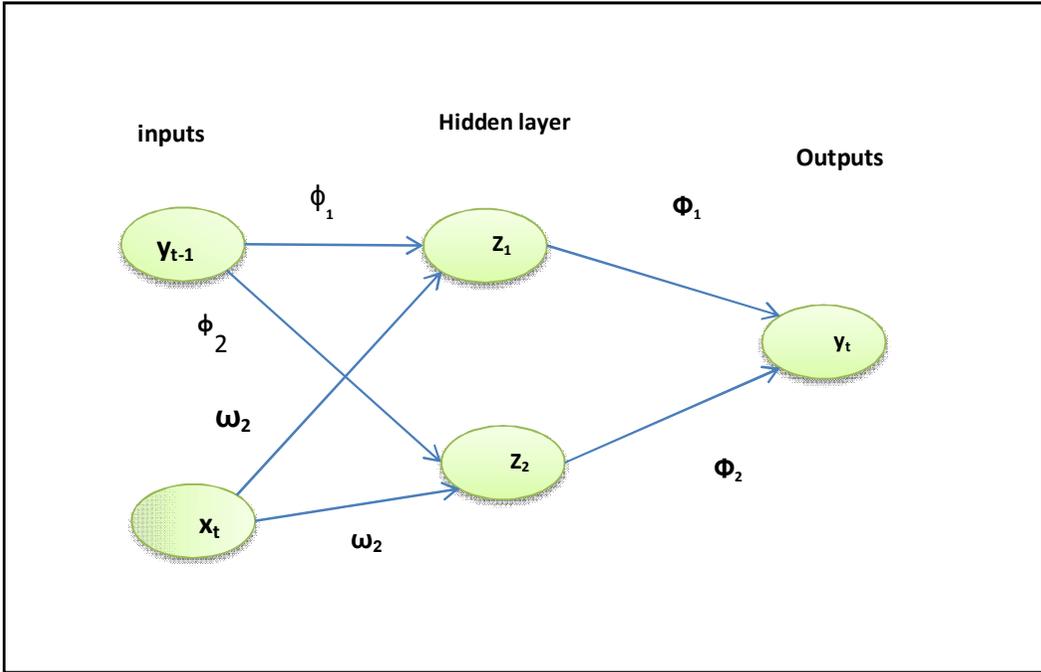
لذلك فإن نموذج الشبكة العصبية المقرب من الممكن أن يكون في الصيغة التالية:

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

وبافتراض وجود سلسلتين زمنيتين y_t تمثل مخرجات الشبكة أو طبقة المخرجات output layer وكانت x_t تمثل مدخلات الشبكة أو طبقة المدخلات output layer، وبافتراض وجود طبقة مخفية واحدة كما في الشكل التالي:

شكل (4-1)

نموذج دالة التحويل كشبكة عصبية اصطناعية



أي أنه يمكن كتابة النموذج الخطي كما يلي:

$$y = c_2 + z \Phi + \varepsilon_2$$

وكما في الشكل السابق نستنتج أن:

$$z = c_1 + \begin{bmatrix} y & x \end{bmatrix} \begin{bmatrix} \phi \\ \omega \end{bmatrix} + \varepsilon_1$$

حيث: C_1 و C_2 ثابت

وكلا من ω, ϕ, Φ تمثل المعالم (أوزان الشبكة)

وبالتالي:

$$y = c_2 + c_1 \Phi \begin{bmatrix} y & x \end{bmatrix} \begin{bmatrix} \phi \\ \omega \end{bmatrix} \Phi + \Phi \varepsilon_1 + \varepsilon_2$$

(4-9)

وحيث أن و بوضع $c = c_2 + c_1 \Phi$ وهى مقدار ثابت نحصل على:

$$y_t = c + \phi y_{t-1} + \omega x_{t-1} + \Phi \varepsilon_{t-1} + \varepsilon_t$$

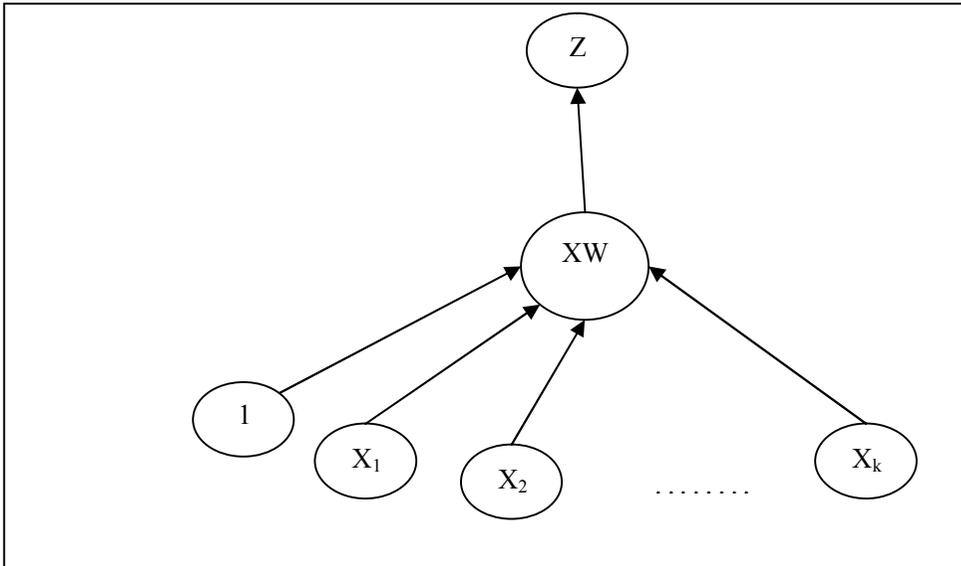
(4-10)

وهذا يمثل نموذج دالة التحويل، حيث تتحدر المشاهدات الحالية y_t على ثلاثة مجموعات وهى قيم y السابقة وقيم x الحالية والسابقة وكذلك الأخطاء الحالية والسابقة.

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: Arming and Enache (1996)).

شكل (4-2)

نموذج الانحدار الخطي كشبكة عصبية اصطناعية



حيث يوضح هذا الشكل كيفية تمثيل نموذج الانحدار الخطي 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 يحتوي هذا النموذج على طبقة مخفية

بل تنتقل المعلومات مباشرة من الطبقة الأمامية إلى النهائية من خلال دالة تحويل مناسبة:

$$Z = g(X, W) = XW \quad \dots \dots \dots (4-11)$$

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

$$Z = XW \quad \dots \dots \dots (4-12)$$

أو بالعلاقة العشوائية:

$$Z = XW + e \quad \dots \dots \dots (4-13)$$

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.

[٥] المقارنة بين طريقي بوكس-جينكنز والشبكات العصبية

لكي يتم مقارنة الطريقة الجديدة مع طريقة بوكس-جينكنز تم توليد 96000 عينة بواقع 500 عينة لكل نموذج من 32 نموذج مختارة من نماذج دالة التحويل مع أحجام عينات مختلفة (100-150-200-250)، وتتم 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. دالة التحويل

وتم قياس دقة التنبؤات لكل من الطريقتين باستخدام ثلاث مقاييس متعلقة بالبواقي (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:

(١-٥) مقارنة نتائج مقياس MSE

فيما يلي جدول (١-٥) يحتوى على نتائج مقياس MSE لكل من تنبؤات بوكس-جينكنز وتنبؤات الشبكات العصبية الاصطناعية مع نماذج دالة التحويل المحددة بأحجام عينات مختلفة، كذلك جدول (٢-٥) يحتوى على نتائج مقياس MSE للثلاثة مشاهدات المستقبلية :

جدول (١-٥)

قيم MSE لتنبؤات بوكس-جينكنز والشبكات العصبية

Sam.size P,h,q	Method	100	150	200	250	Average
(1,1,0)	NN	0.9075	0.8851	0.9363	0.9128	0.9104
	BJ	1.7467	1.8498	1.9248	1.9578	1.8698
(1,2,0)	NN	1.0284	1.0524	1.0785	1.0520	1.0528
	BJ	2.0050	2.0672	2.2381	2.2410	2.1378
(1,1,1)	NN	1.0934	1.1189	1.1143	1.1411	1.1169
	BJ	2.1741	2.2901	2.3652	2.3858	2.3038
(0,1,0)	NN	0.9143	0.9227	0.9123	0.9211	0.9176
	BJ	1.5000	1.5506	1.6114	1.6559	1.5795
(0,2,0)	NN	1.0552	1.0911	1.0617	1.0560	1.0660
	BJ	1.0191	1.0747	1.0522	1.0923	1.0596
(0,1,1)	NN	1.1265	1.1300	1.1563	1.1602	1.1433
	BJ	1.9153	2.0202	2.0893	2.2060	2.0577
(0,1,2)	NN	1.1465	1.1769	1.1820	1.1911	1.1741
	BJ	1.9917	2.0805	2.1524	2.2283	2.1132
(0,2,1)	NN	1.2578	1.2758	1.2655	1.2801	1.2698
	BJ	1.7683	1.9040	1.9629	2.0035	1.9097
Average	NN	1.0662	1.0816	1.0883	1.0893	1.0814
	BJ	1.7650	1.8546	1.9245	1.9713	1.8789

جدول (٥-٢)

قيم MSE لتنبؤات بوكس-جينكنز والشبكات العصبية

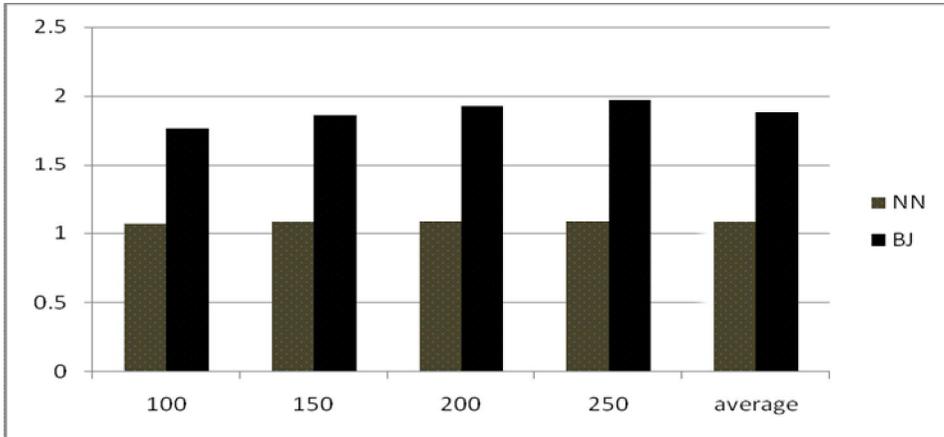
Prediction horizon Sam. size	Method	Z_{n+1}	Z_{n+2}	Z_{n+3}	Average
100	NN	1.0738	1.0724	1.0524	1.0662
	BJ	1.7367	1.7761	1.7823	1.7650
150	NN	1.0827	1.0867	1.0754	1.0816
	BJ	1.8688	1.8531	1.8420	1.8546
200	NN	1.0994	1.0873	1.0784	1.0883
	BJ	1.9254	1.9431	1.9052	1.9245
250	NN	1.1006	1.0883	1.0789	1.0893
	BJ	1.9770	1.9598	1.9772	1.9713
Average	NN	1.0891	1.0837	1.0713	1.0814
	BJ	1.8770	1.8830	1.8767	1.8789

ومن خلال جدول (٥-١) ، و جدول (٥-٢) نلاحظ أن :

- وفقا لحجم العينة : نلاحظ من جدول (٥-١) أن أداء الطريقتين الشبكات العصبية (NN) ، وطريقة بوكس-جينكنز يتقارب بزيادة حجم العينة مع العلم أن طريقة الشبكات أفضل تقريبا في المتوسط العام عن طريقة التقليدية. ويتضح النتائج من خلال الشكل البياني (٥-١).

شكل (١-٥)

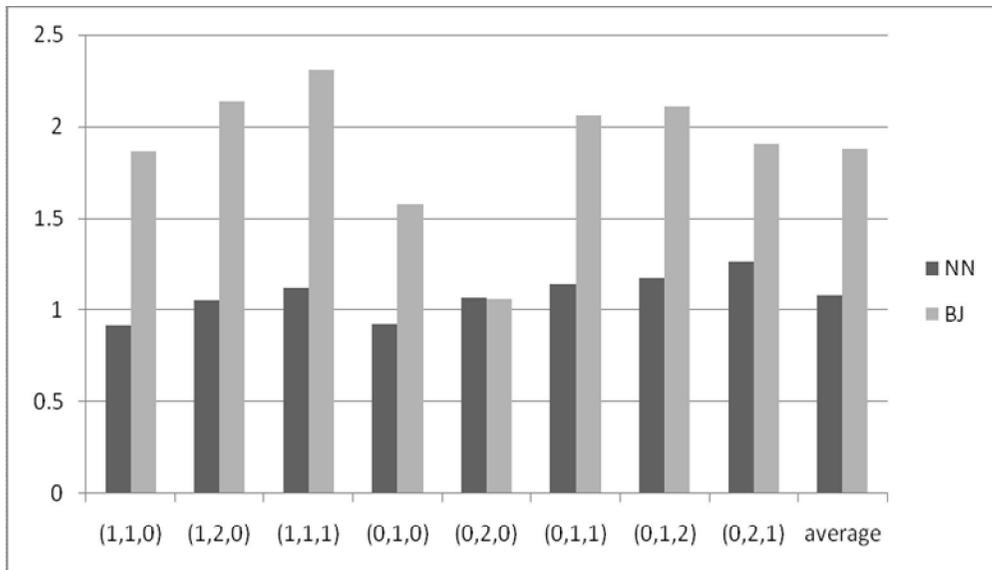
قيم MSE لتنبؤات بوكس-جينكنز والشبكات العصبية وفقا لحجم العينة



- وفقا للنموذج المحدد : نلاحظ من جدول (١-٥) أن قيمة MSE لتنبؤات طريقة الشبكات العصبية كانت أقل من قيمتها لتنبؤات طريقة بوكس-جينكنز وذلك في جميع النماذج فيما عدا نموذج دالة التحويل. ويتضح هذه النتائج من خلال الشكل البياني (٢-٥).

شكل (٢-٥)

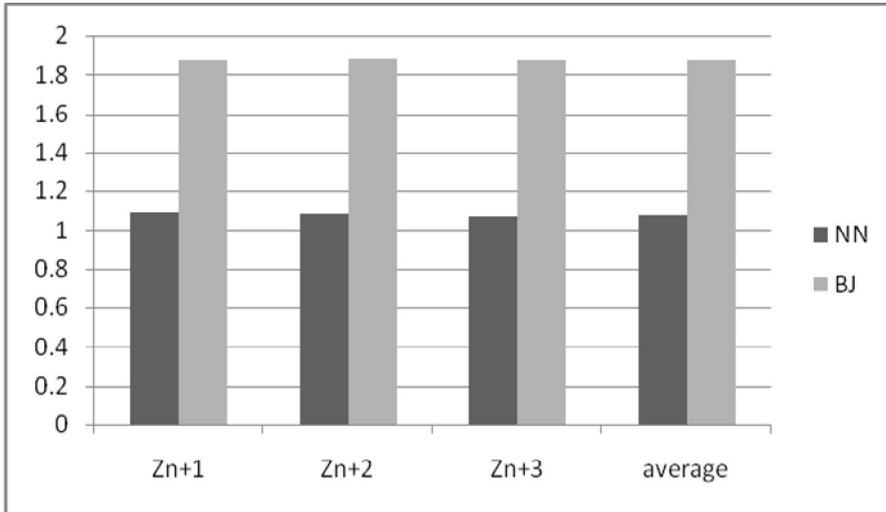
قيم MSE لتنبؤات بوكس-جينكنز والشبكات العصبية لنماذج دالة التحويل



- ووفقاً لأفق التنبؤ : نلاحظ في جدول (٥-٢) أن قيمة MSE لتنبؤات طريقة الشبكات العصبية للمشاهدات الثلاثة المستقبلية أقل في المتوسط من قيمتها في التنبؤات بطريقة بوكس-جينكنز . وحيث أن المتوسط العام للتنبؤ بالمشاهدات الثلاثة المستقبلية أقل في طريقة الشبكات عن الطريقة التقليدية إذا يمكن القول بتفوق أداء طريقة الشبكات للتنبؤ بالمشاهدات المستقبلية . ومن الممكن ملاحظة هذه النتائج من خلال الشكل البياني (٥-٣).

شكل (٥-٣)

قيم MSE للمشاهدات الثلاثة المستقبلية لتنبؤات بوكس-جينكنز والشبكات العصبية



(٥-٢) مقارنة نتائج مقياس MAD

فيما يلي جدول (٥-٣) يحتوي على نتائج مقياس MAD لكل من تنبؤات بوكس-جينكنز وتنبؤات الشبكات العصبية الاصطناعية مع نماذج دالة التحويل المحددة بأحجام عينات مختلفة، كذلك جدول (٥-٤) يحتوي على نتائج مقياس MAD للمشاهدات المستقبلية الثلاثة الأولى:

جدول (٥-٣)

يوضح قيم MAD لتنبؤات بوكس-جينكنز والشبكات العصبية لنماذج دالة التحويل

Sam.size P,h,q	method	100	150	200	250	Average
(1,1,0)	NN	0.7583	0.7545	0.7715	0.7634	0.7619
	BJ	1.0653	1.0912	1.1118	1.1165	1.0962
(1,2,0)	NN	0.7990	0.8089	0.8203	0.8114	0.8099
	BJ	1.1324	1.1547	1.1948	1.1932	1.1688
(1,1,1)	NN	0.8249	0.8360	0.8269	0.8425	0.8326
	BJ	1.1753	1.2056	1.2264	1.2332	1.2101
(0,1,0)	NN	0.7679	0.7692	0.7661	0.7717	0.7687
	BJ	0.9820	0.9914	1.0128	1.0236	1.0025
(0,2,0)	NN	0.8147	0.8303	0.8230	0.8176	0.8214
	BJ	0.8076	0.8248	0.8170	0.8339	0.8208
(0,1,1)	NN	0.8432	0.8425	0.8573	0.8543	0.8493
	BJ	1.1053	1.1331	1.1513	1.1778	1.1419
(0,1,2)	NN	0.8501	0.8591	0.8621	0.8648	0.8590
	BJ	1.1260	1.1477	1.1660	1.1887	1.1571
(0,2,1)	NN	0.8873	0.8942	0.8893	0.8965	0.8918
	BJ	1.0594	1.1032	1.1216	1.1321	1.1041
average	NN	0.8182	0.8243	0.8271	0.8278	0.8243
	BJ	1.0567	1.0815	1.1002	1.1124	1.0877

جدول (٥-٤)

قيم MAD للملاحظات الثلاثة المستقبلية لطريقتي بوكس-جينكنز والشبكات العصبية

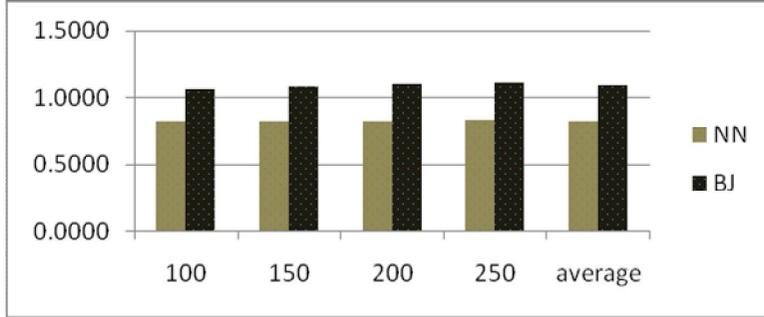
Prediction horizon Sam. size	method	Zn+1	Zn+2	Zn+3	Average
100	NN	0.8207	0.8203	0.8135	0.8182
	BJ	1.0484	1.0610	1.0607	1.0567
150	NN	0.8236	0.8275	0.8220	0.8243
	BJ	1.0879	1.0772	1.0794	1.0815
200	NN	0.8308	0.8266	0.8237	0.8271
	BJ	1.1002	1.1067	1.0937	1.1002
250	NN	0.8326	0.8256	0.8251	0.8278
	BJ	1.1138	1.1098	1.1135	1.1124
Average	NN	0.8269	0.8250	0.8211	0.8243
	BJ	1.0876	1.0887	1.0868	1.0877

ومن خلال جدول (٥-٣) ، وجدول (٥-٤) نلاحظ أن :

- وفقا لحجم العينة : نلاحظ من جدول (٥-٣) أن قيم MAD 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 مع كل أحجام العينات. وبوجه عام فإن أداء طريقة الشبكات العصبية كان أفضل من طريقة بوكس-جينكنز. ويتضح من خلال الشكل البياني (٥-٤).

شكل (٥-٤)

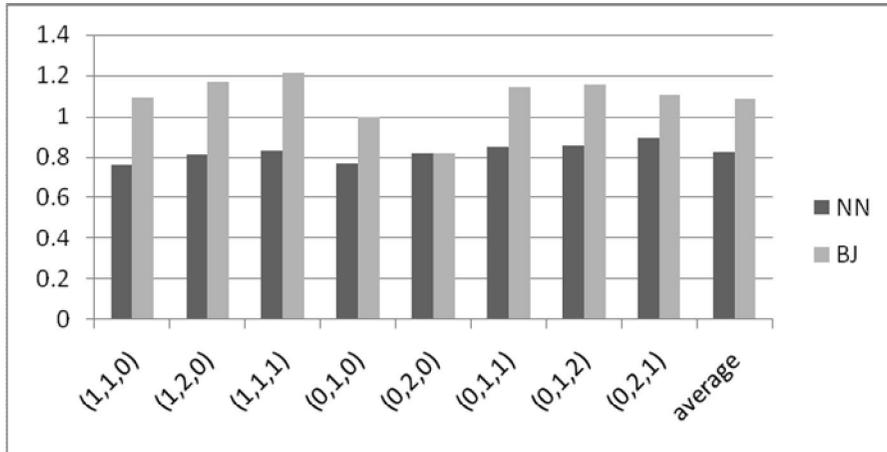
قيم MAD لتنبؤات بوكس-جينكنز والشبكات العصبية وفقا لحجم العينة



- وفقا للنموذج المحدد : نلاحظ من جدول (٥-٣) أن قيمة MAD لتنبؤات طريقة الشبكات العصبية كانت أقل من قيمتها لتنبؤات طريقة بوكس-جينكنز وذلك في جميع حالات كل نماذج دالة التحويل المحددة ، وبالتالي كانت الأفضل مع كل تلك النماذج، كما كان المتوسط العام لقيم MAD في حالة تنبؤات طريقة الشبكات العصبية وهو يساوي 0.8243 أقل من قيمته في حالة تنبؤات طريقة بوكس-جينكنز الذي يساوي 1.0877.امن الممكن ملاحظة هذه النتائج من خلال الشكل البياني (٥-٥).

شكل (٥-٥)

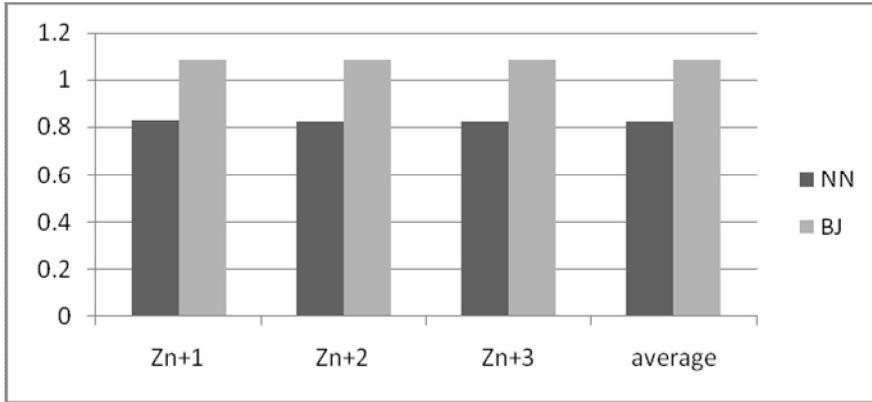
قيم MAD لتنبؤات بوكس-جينكنز والشبكات العصبية لنماذج دالة التحويل



- وفقا لأفق التنبؤ : نلاحظ من جدول (٥-٤) 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 (٥-٦).

شكل (٥-٦)

يوضح قيم MAD للملاحظات الثلاثة المستقبلية لبوكس-جينكنز والشبكات العصبية



(٥-٣) مقارنة نتائج مقياس MAEP

فيما يلي جدول (٥-٥) يحتوى على نتائج مقياس متوسط نسبة الأخطاء المطلقة الأقل لتنبؤات الشبكات العصبية الاصطناعية إلى بوكس-جينكنز مع نماذج دالة التحويل المحددة بأحجام عينات مختلفة ، كذلك جدول (٥-٦) يحتوى على نتائج مقياس MAEP للثلاثة مشاهدات المستقبلية :

جدول (٥-٥)

يوضح قيم MAEP لنماذج دالة التحويل مع أحجام العينات المختلفة

P,h,q \ sam.size	100	150	200	250	Average
(1,1,0)	1.633	1.697	1.671	1.673	1.668
(1,2,0)	1.659	1.692	1.651	1.685	1.672
(1,1,1)	1.646	1.693	1.728	1.72	1.697
(0,1,0)	1.574	1.568	1.61	1.604	1.589
(0,2,0)	0.97	0.964	0.966	1.027	0.982
(0,1,1)	1.636	1.662	1.565	1.657	1.63
(0,1,2)	1.659	1.657	1.648	1.703	1.667
(0,2,1)	1.381	1.431	1.435	1.48	1.432
average	1.52	1.546	1.534	1.568	1.542

جدول (٦-٥)

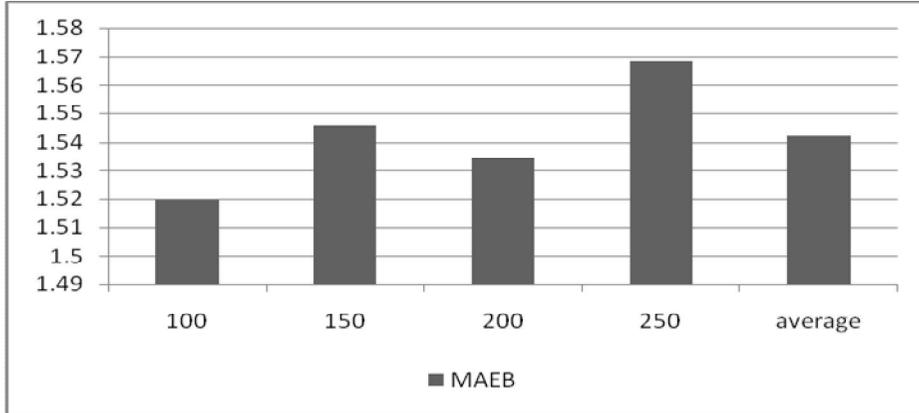
يوضح قيم MAEP للملاحظات المستقبلية الثلاثة

Prediction horizon Sam. size	Zn+1	Zn+2	Zn+3	Average
100	1.4944	1.5232	1.5417	1.5198
150	1.5620	1.5262	1.5487	1.5456
200	1.5252	1.5493	1.5286	1.5344
250	1.5673	1.5639	1.5738	1.5683
Average	1.5372	1.5407	1.5482	1.5420

ومن خلال جدول (٥-٥) ، وجدول (٦-٥) نلاحظ أن :
 وفقا لحجم العينة : نلاحظ من جدول (٥-٥) أن قيم مقياس متوسط نسبة
 الأخطاء المطلقة الأقل للشبكات العصبية الاصطناعية إلى بوكس-جينكنز
 MAEP مما يدل على أن أداء طريقة الشبكات العصبية أفضل من أداء
 طريقة بوكس-جينكنز. وكانت في المتوسط %1.542 أي أن أداء طريقة
 الشبكات العصبية الاصطناعية يفوق أداء طريقة بوكس-جينكنز %54.2 .
 ومن الممكن ملاحظة هذه النتائج من خلال الشكل البياني (٧-٥).

شكل (٥-٧)

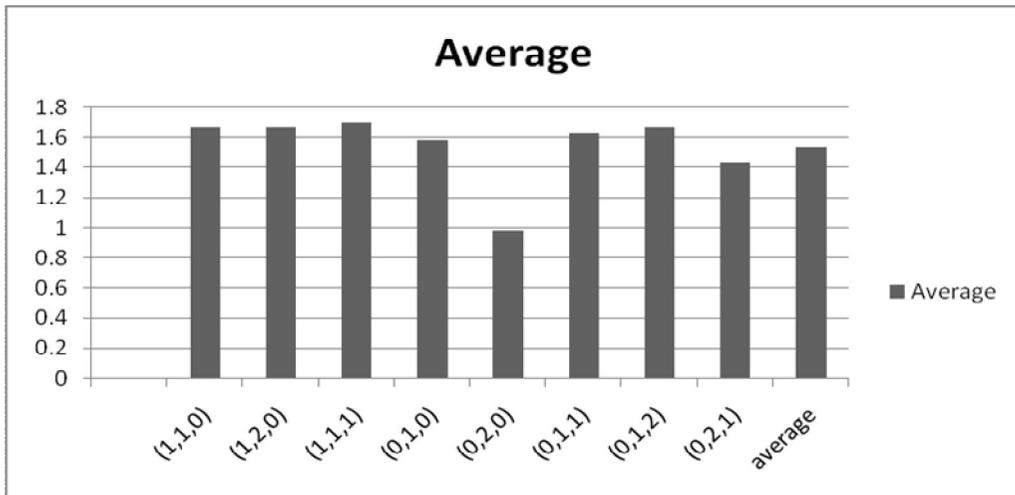
يوضح قيم متوسط النسب MAEP وفقا لحجم العينة



• ووفقا للنموذج المحدد : نجد أن نسبة عدد الأخطاء المطلقة الأقل للشبكات العصبية الاصطناعية إلى بوكس-جينكنز والتي في جدول (٥-٥) حيث كانت جميع النماذج تفوق الطريقة التقليدية فيما عدا نموذج دالة التحويل (0,2,0) حيث كانت تساوي 98.2%. ومن الممكن ملاحظة هذه النتائج من خلال الشكل البياني (٥-٨).

شكل (٥-٨)

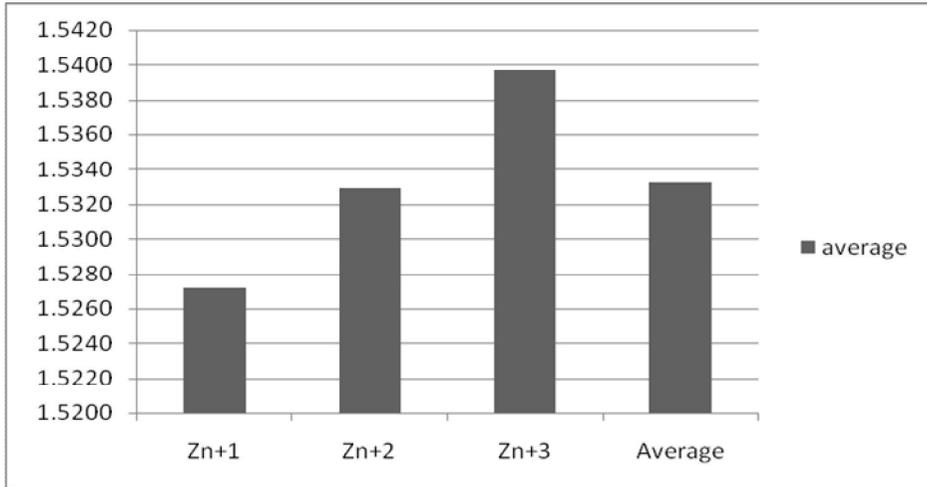
يوضح قيم متوسط النسب MAEP وفقا لنماذج دالة التحويل



- وفقا لأفق التنبؤ : نلاحظ في جدول (٥-٦) أن قيم مقياس متوسط نسبة الأخطاء المطلقة الأقل للشبكات العصبية الاصطناعية 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 (٥-٩).

شكل (٥-٩)

يوضح قيم MAEP للملاحظات المستقبلية الثلاثة



[٦] الخلاصة

يتضمن هذا البحث هدفين :

- الهدف الأول: تعميم طريقتي (Alshawadfi (2003) والشوادفي، حجاج (٢٠١٣) للتنبؤ بالسلاسل الزمنية المولدة من نماذج دالة التحويل (transfer function) باستخدام الشبكات العصبية الاصطناعية (ANN) ، ولتحقيق هذا الهدف يتم توليد 96000 عينة بأحجام مختلفة (100-150-200-250) من نماذج دالة التحويل بمعلمات مختلفة تستخدم لتدريب الشبكة عن طريق تصميم برنامج ماتلاب Matlab لإجراء دراسة المحاكاة ومقارنة الطريقة المقترحة بالطريقة التقليدية .
- الهدف الثاني : مقارنة أداء الطريقة المقترحة للشبكات العصبية الاصطناعية مع أداء طريقة "بوكس و جينكنز " لتوضيح أي منهما أفضل للتنبؤ بنماذج دالة التحويل 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 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 دالة التحويل باستخدام أحد طرق الذكاء الاصطناعي - وهي طريقة الشبكات العصبية - على التنبؤ بالقيم المستقبلية للسلسلة الزمنية المعطاة وذلك بطريقة آلية ، حيث أظهرت النتائج من دراسة 96000 عينة والتي تم توليدها أن متوسط مربعات أخطاء التنبؤ MSE، ومتوسط القيمة المطلقة لخطأ التنبؤ MAD ، وكذلك متوسط النسبة MAEP أفضل من نظيرتها في أسلوب بوكس-جينكنز، 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 دالة التحويل .

[٧] التوصيات :

- أهم التوصيات الممكن تحقيقها مستقبلا تتلخص فيما يلي :
- تطبيق هذه الدراسة للتنبؤ بدوال التحويل في مجالات كثيرة .
 - تعميم هذه الدراسة الى حالة سلاسل زمنية موسمية ، اى حالة نماذج دالة التحويل الموسمية Seasonal Transfer Function
 - تعميم الدراسة لتشمل أكثر من متغير خارجي X_t
 - تعميم الدراسة لتشمل أكثر من متغير تابع Y_t

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 نجيفيتسكي ، (٢٠٠٤ م) . " الذكاء الصناعي دليل النظم الذكية " تعريب سرور على إبراهيم سرور ، دار المريخ للنشر ، الرياض ، المملكة العربية السعودية، ص ٢٥٢ .
- (٣) الشيماء إبراهيم الوصيفي (٢٠١٢م) . "التنبؤ باستخدام الدمج بين الشبكات العصبية الاصطناعية ونماذج بوكس وجينكينز (دراسة تطبيقية)"، رسالة ماجستير غير منشورة ، كلية التجارة بدمياط - جامعة المنصورة .
- (٤) جمال الشوادفي ، عبد الوهاب حجاج (٢٠١٣م). " الذكاء الاصطناعي وتحليل السلاسل الزمنية " مجلة كلية التجارة (بنين) - جامعة الأزهر ، العدد العاشر ، يناير ٢٠١٣م، ص ٥٧٣ - ٦١٢ .
- (٥) دربال أمينة (٢٠١٤م). "محاولة التنبؤ بمؤشرات الأسواق المالية العربية باستعمال النماذج القياسية" رسالة دكتوراة غير منشورة، كلية العلوم الاقتصادية و علوم التسيير و العلوم التجارية ، الجمهورية الجزائرية الديمقراطية الشعبية (٥) إبراهيم محمد إبراهيم (٢٠١٥م). " دراسة مقارنة للتنبؤ بالسلاسل الزمنية متعددة المتغيرات باستخدام نموذجي دالة التحويل و الشبكات العصبية الاصطناعية " ، رسالة دكتوراة غير منشورة، كلية الدراسات العليا ، جامعة السودان للعلوم والتكنولوجيا .

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 دالة التحويل 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 دالة التحويل 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 دالة التحويل 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 I, 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 .


```

%newff, newcf, traingdm, traingda, traingdx, trainlm, rainrp, traincgf,
traincgb, trainbfg, traincgp, trainoss.
j00=0
for n=[ m m-50 m-100 m-150 ]
    j00=0;
    for j = 1 : n1
        dd= [n j]
        for j0 = 1 : m0
            j00 = j00 + 1;
            j1 = fix((j-1)/n3)+1;
            xx1 = [xx0(1:n , j00) , yy0(1:n , j00)] ; yy1 = [yy0(1:n , j00) ,xx0(1:n , j00)]
            ;yx= yy0(1:n ,j00); t =yx(n-h+1:n);
            net = fitnet(1,'traincgf' );
            net.trainparam.epochs =3;
            net.trainParam.showWindow =0 ;
            net = train(net,xx1',yx');
            f = sim(net,xx1');
            w0= min(Y(1:n,j00))+ (f - 0.1)*(max(Y(1:n,j00))- min(Y(1:n,j00)))/0.8;
            w1=w0(n-h+1:n);
            th = armax(yy1 , p(j,:));
            f1 = predict(yy1,th,h);
            w2= min(Y(1:n,j00))+ (f1 - 0.1)*(max(Y(1:n,j00))- min(Y(1:n,j00)))/0.8;
            w3=w2(n-h+1:n);
            s01 = abs(w1 -t');s02 = (s01).^2;
            b01 = abs(w3-t)'; b02 = (b01).^2;
            s01 <b01 ; b=[ans] ;
            ss(j1,:) = ss(j1,:)+b;
            ss01(2*j1-1,:) = ss01(2*j1-1,:) + s01;ss01(2*j1,:) = ss01(2*j1,:) + b01;
            ss02(2*j1-1,:) = ss02(2*j1-1,:) + s02;ss02(2*j1,:) = ss02(2*j1,:) + b02;
        end
    end
end

```

```
end
% 4... Results... ...
disp('MAE RESULTS ')
ss01=ss01/(n3*m0);
MAE=[ss01,(mean(ss01'))';mean(ss01),mean(mean(ss01))]
disp('MSE RESULTS ')
ss02=ss02/(n3*m0);
MSE=[ss02,(mean(ss02'))';mean(ss02),mean(mean(ss02))]
disp('MAER RATIOS RESULTS ')
sb = ss ./ (n3*m0 - ss);
cc= [ n m0 ];
MAER =[sb,(mean(sb'))';mean(sb),mean(mean(sb))]
ss01 = zeros(2*n2 , h) ;
ss02 = zeros(2*n2 , h) ;
ss=zeros(n2,h);
end
toc
```

A suggested method for forecasting transfer functions using artificial intelligence

Abstract

This paper has two objects. First, we present artificial neural networks method for forecasting transfer function time series. Second, we compare the proposed method with the well known Box-Jenkins method through a simulation study . To achieve these objects 96000 samples, generated from different transfer function models, different sizes (100,150,200,250), 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 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 transfer function models.