

استخدام الشبكات العصبية في التكهن بالسلسلة الزمنية لاستهلاك

الطاقة الكهربائية في مدينة الموصل

عزة حازم زكي*

*باسل يونس الخياط

المستخلص

يُعد التكهن بالسلوك المستقبلي للسلسلات الزمنية من الموضوعات المهمة في العلوم الإحصائية، وذلك للحاجة إليه في مجالات الحياة جميعاً، وقد تزايد الاهتمام بموضوع التكهن خلال السنوات الأخيرة وظهرت أساليب حديثة خاصة في مجال علوم الحاسوب، ومنها نماذج الشبكات العصبية الاصطناعية Artificial Neural Networks، إن هذه الأساليب قادرة على التعلم والتكيّف ذاتياً مع أي نموذج، ولا تحتاج إلى افتراضات لطبيعة السلسلة الزمنية. بالمقابل فإن طرائق التكهن الكلاسيكية المستخدمة حالياً مثل طريقة بوكس-جينكنز Box-Jenkins قد يصعب فيها تشخيص السلسلة ونمذجتها لأنها تفترض شروط صارمة. لذلك ظهرت الحاجة إلى مقارنة الطرائق الكلاسيكية المستخدمة في التكهن بالسلسلات الزمنية مع أسلوب الشبكات العصبية لإيجاد الأسلوب الأكثر كفاءة في التكهن.

The Use of Neural Networks in Forecasting of Time Series with Application on Consumption of Electrical Power in Mosul City

ABSTRACT

Forecasting of future behavior of time series is one of the important subjects in statistical sciences, because of its important need in different areas of life. Interest in forecasting had increased in the recent years, and some new techniques in the

* استاذ/كلية علوم الحاسوب والرياضيات/جامعة الموصل

** مدرس مساعد /مركز الحاسبة الالكترونية/جامعة الموصل

تاریخ التسلیم : 2005/3/30 ————— تاریخ القبول : 8/14/2005

field of computer science, like Artificial Neural Networks (ANN), had appeared. These techniques have the ability learning and self-adaptation with any model, and don't need assumptions on the nature of time series. On the other hand the classical forecasting methods, like Box-Jenkins method, need hard conditions. Hence, the need for a comparison between classical methods in forecasting of time series with ANN technique arose.

١- المقدمة

منذ مطلع العقد السابع من القرن العشرين ظهر اهتمام متزايد بتحليل السلاسل الزمنية وطرق التكهن بقيمها المستقبلية، وفي بداية الثمانينيات من القرن العشرين ظهر اهتمام خاص بتحليل السلاسل الزمنية غير الخطية ونمذجتها. ومع بداية العقد الأخير من القرن العشرين ظهرت توجهات لدراسة الخصائص الفوضوية في السلاسل الزمنية. ومع إطلاة القرن الحادي والعشرين تزايدت الاهتمامات في دراسة السلاسل الزمنية، وخاصة من خلال علاقتها الوثيقة بالنظم الديناميكية.

يرتكز تحليل السلاسل الزمنية على ثلاثة ركائز تتمثل بثلاثة افتراضات رئيسية:
إن السلاسل الزمنية خطية Linear، أي يمكن تمثيلها بنموذج رياضي 厦 خطى.

إن السلاسل الزمنية تتوزع طبيعيا Normal، أي أنها تتوزع توزيعاً طبيعياً.
إن السلاسل الزمنية مستقرة Stationary، أي أن خصائصها الرياضية والإحصائية لا تعتمد على الزمن.

ان الافتراض الأول (الخطية) قد تم تجاوزه في العقد الثامن من القرن العشرين بعد ظهور العديد من النماذج اللاخطية (انظر Tong (1990)). أما الافتراض الثاني فقد تم تخطيه من خلال بعض الدراسات التي ظهرت والمتعلقة بالسلاسل الزمنية غير الطبيعية (Lewis et al., 1989)، وأما الافتراض الثالث (المستقرة) فيبقى هو الافتراض الأصعب والأكثر إلحاحاً لإيجاد أساليب تتجاوزه، وذلك لأن اغلب السلاسل الزمنية الواقعية هي سلاسل غير مستقرة.

من الأهداف الأساسية للعلوم الإحصائية التقدير والتكمّن بالسلوك المستقبلي للظاهره قيد البحث، وقد أولى تحطيل السلسله الزمنيه اهتماماً كبيراً للتكمّن واقتصرت العددي من الأساليب لغرض إجراء التكمّن.

ومن الأساليب الحديثة التي أخذت اهتماماً ملحوظاً، وخاصة في مجال علوم الحاسوب، الشبكات العصبية الاصطناعية Artificial Neural Networks (ANNs)، إذ أن الفكرة الأساسية من هذا الأسلوب هو إنشاء نموذج معلومات يحاكي النظام البيولوجي العصبي. إن المفتاح الأساسي لهذا النموذج هو بناء هيكل جديد لنظام معالجة المعلومات الذي يقوم بربط وتنظيم العديد من عناصر المعالجة المرتبطة مع بعضها وهي (العصبونات) التي تعمل بشكل متوازن لحل المشكلة قيد الدراسة.

والشبكات العصبية الاصطناعية (ANNs) تتعلم بطريقة تشبه تعلم الإنسان من خلال الأمثلة والتدريب، والشبكات العصبية تهيأ وتنظم لتطبيقات محددة، مثل نموذج التمييز والإدراك أو تصنيف البيانات من خلال عملية التعلم. والتعلم في النظام البيولوجي يستخدم تكيف نقاط الاشتباك العصبي بين العصبونات، وهذه هي الفكرة الجوهرية في عمل الشبكات العصبية.

وفي المجال الإحصائي، ظهرت في الآونة الأخيرة اهتمامات خاصة بإدخال أسلوب الشبكات العصبية إلى التطبيقات الإحصائية. ولما كان استخدام أسلوب الشبكات العصبية لا يتطلب افتراضات عن طبيعة السلسلة الزمنية، كونها خطية أو طبيعية أو مستقرة، لذا يعتقد إن استخدام هذا الأسلوب قد يكون مجزياً في معالجة مسألة التكمّن.

لقد نشر الباحثان Zurada & Cholewo (1997) بحثاً تناولاً فيه الطائق الجديدة للتكمّن التي ظهرت في العقد الأخير من القرن الماضي ومنها الشبكات العصبية الاصطناعية (ANNs) وقما Finite Implse Elman Network Response Neural Network (FIR) والشبكة الدورية والشبكات المتطرفة منها. وأجريا التكمّن باستخدام التباين وتقدير الشرعية المتقاطع

اللخطي Nonlinear Cross Validation، وتوصلاً إلى أن أفضل شبكة للتكنن باستخدام بيانات Mackey-Atiya et al. (1999) الاقتصادية فقد كانت أفضل شبكة هي Elman Network Glass (1999). فقد نشروا بحثاً يهدف استخدام الشبكات العصبية لمسألة التكهن بتدفق المياه في نهر النيل، واستخدمت السلسلة الزمنية نموذجاً للمقارنة بين بعض الشبكات العصبية في التكهن، كما طبقت أربع طرائق مختلفة لعملية الإدخال للحصول على المخرجات باستخدام طرائق جديدة اقترحت كأساس لسلسلة فوريير المقاطعة.

وقدم Sansom & Saha (1999) بحثاً للتكنن بأسعار الكهرباء في استراليا واستخدماً الشبكات العصبية للتكنن وتوصلاً إلى أن الأسعار الأسبوعية ثابتة ولكنها تتغير كل ستة أشهر.

أما (Lotric and Dobnikar 2001) فقد قدموا بحثاً لتقليل حالة التشويش (noise) في التكهن للسلسلة الزمنية، وأستخدمت شبكات عصبية متعددة الطبقات مع وحدات تتعيم Smoothing، كما استخدمت طريقتان للمقارنة هما: التتعيم باستخدام الطرائق الإحصائية والتتعيم باستخدام خطأ التكهن كمقاييس. وتوصلاً إلى أن التكهن بالتشويش للسلسلة الزمنية التي استخدمت الشبكات العصبية متعددة الطبقات أفضل من النموذج الذي استخدم خطأ التكهن كأساس.


أما (Yao 2002) فقد قدم بحثاً عرض فيه دراسة شبكة عصبية للتكنن بحالة السوق وتوصل إلى أن الشبكة العصبية تفوق الطرائق الكلاسيكية في معظم حالات التكهن بالرغم من أن الشبكة العصبية تحتاج إلى تدريب طويل.

وعلى النطاق المحلي قدم كل من الناصر والعيدي سنة (2003) بحثاً لتوظيف الشبكات العصبية للتكنن بالقيم المستقبلية لظاهرة تتبع سلسلة زمنية غير منتظمة في طول الموسمية. وتوصلاً إلى أن الشبكات العصبية تتمكن من التعلم والتكييف ذاتياً مع أي نموذج وفورنت نتائج الشبكات العصبية مع طرائق التكهن الكلاسيكية للتعرف على سلوكيات الشبكات العصبية وجودتها.

2- الشبكات العصبية الاصطناعية

تعني الشبكة العصبية في حقل تقنية المعلومات، نظاماً من البرامج و هيكل البيانات التي تقارب عمل الدماغ البشري . تتضمن الشبكة العصبية عدداً كبيراً من المعالجات التي تعمل على التوازي. تبدأ الحالة الابتدائية للشبكة العصبية بعملية " التدريب "، أو تقييم كميات من البيانات والقواعد عن العلاقات بين تلك البيانات ثم يوجهها برنامج إلى كيفية الاستجابة إلى المؤثرات الخارجية والتي يمكن أن تكون مدخلات من الشخص الذي يستخدم النظام، أو يمكن أن يبدأ البرنامج ذاته بتنفيذ مهمة معينة.

إن المفتاح لنموذج الشبكة العصبية الاصطناعية هو الهيكل لنظام معالج المعلومات الذي يقوم بربط وتنظيم عدد كبير من عناصر المعالجة المرتبطة داخلياً (العصيوبونات) والتي تعمل بانسجام لحل مسائل معينة، وتمر الإشارات بين العقد (العصيوبونات) عبر خطوط ربط ويرفق كل خط وزن معين، وتضرب الإشارات الداخلة إلى العقدة (العصيوبون) بهذه الأوزان، وتجمع المدخلات الموزونة في العقد أو العصيوبونات وبعد ذلك تتم معالجة مخرجات كل عقدة بواسطة دالة غير خطية ذات عتبة معينة (Activation Function) تعرف بدالة التنشيط (Threshold Function). والشكل (1) يوضح شبكة عصبية اصطناعية بسيطة.



الشكل (1): جزء من الشبكة العصبية الاصطناعية.

يمكن تعريف التعلم بأنه عملية ضبط الأوزان لجعل الخلية تطلق إشارة استجابة للأمثلة من مجموعة معينة. كما هو معروف، فإن الشبكة العصبية هي مجموعة عصبونات Neurons وأوزان منظمة، والعصبونات منظمة في طبقات، وكل عصبون في كل طبقة له وزن مرتبط مع كل عصبون في الطبقة الآتية. والشبكات العصبية الاصطناعية تتعلم عن طريق وسائل معينة تغير قوة الربط الداخلي، وهذا يدعى "تكيف الوزن" ويحدث خلال عملية تدعى "مرحلة التدريب". ومجموعة الإدخال الخارجي تدعى "مجموعة التدريب للشبكة" أو (عينة التدريب) ونموذج الإدخال المنفرد يسمى "متجه التدريب" أو (المشاهدات) فضلاً عن أن الشبكة يمكن أن تستقبل عن طريق التغذية العكسية Feedback، أو يمكن أن تستخدم التغذية العكسية مع معلومات إضافية لتحديد حجم التغيير في الأوزان.

2-1 الشبكات العصبية ذات الانتشار العكسي

Backpropagation Neural Networks

إن شبكات التغذية الخلفية أو العكسية يمكنها أن تمتلك إشارات تتحرك أو تنتقل في كلا الاتجاهين، وهي شبكات حركية تتغير استقراريتها باستمرار إلى حين الوصول إلى نقطة التوازن، وتبقى في نقطة التوازن إلى أن يتغير الإدخال والعوامل الخارجية الأخرى وعندئذ تحتاج إلى إيجاد توازن جديد. تستند الشبكة العصبية ذات الانتشار العكسي للخطأ إلى مفهوم تدريب الشبكة المعتمد على متوسط مربع الخطأ، وذلك بإيجاد القيمة الصغرى لمربع الخطأ الكلي لقيمة المخرجات المحسوبة من قبل الشبكة اذ تحدث الأوزان بين الطبقات لحين الوصول إلى الأوزان المثلثي التي تحدث أفضل توفيق للنموذج (الناصر والعيدي، 2003). إن شبكة الانتشار العكسي للخطأ تستخدم التعلم بإشراف Supervised learning وهذا يعني تزويد الشبكة بمثال المدخلات والمخرجات المطلوب حسابها، ويحسب الخطأ (الفرق بين القيم الحقيقة والمتوقعة). وفكرة شبكة الانتشار العكسي هو تقليل الخطأ، إلى أن تتعلم الشبكة عن طريق التدريب، ويبدأ التدريب بأوزان عشوائية بهدف تكيف الشبكة إلى أن يصل الخطأ إلى أقل ما يمكن (Gershenson, 1998).

3- التكهن

إن الفكرة الأساسية للتكنهن بالسلسلة الزمنية هي إيجاد الصيغة الرياضية التي تولد سلسلة زمنية مثلى تقريباً حسب الصيغة السابقة لها (التاريخية)، وهناك طريقتان أساسيتان للتكنهن للسلسلات الزمنية حسب تقنيات Historical Self-Projecting on Time Series (بوكس-جينكنز هما: الاسقاط الذاتي للسلسلة الزمنية) لغرض توليد بيانات متكنه بها. أمّا التقنية الثانية فهي طريقة السبب والتأثير (Cause-and-Effect Approach) المستخدمة اعتماداً على بيانات السلسلات المعتمد بأنها سبب في سلوك السلسلة الأصلية. علمًا أن الطريقة الأولى تعد من ابرز سمات طريقة التكنهن لبوكس-جينكنز، اذ أن الهدف الأساسي لها هو إيجاد صيغة مناسبة للتكنهن بحيث يجعل الباقي (Residuals) أقل ما يمكن.

يعد التكنهن باستخدام الشبكات العصبية من الاساليب الحديثة التي لاقت اهتماماً واسعاً في مجالات متعددة منها التكنهن بأسعار العملات والموارد المالية، احوال الطقس، تدفق المياه في الانهار، واستهلاك الطاقة الكهربائية. واستخدمت بشكل واسع كونها لا تحتاج الى شروط صارمة ودقيقة لغرض التكنهن كما انه يمكن تفسير سلوك البيانات غير الخطى. ويمكن تلخيص عمل شبكة الانتشار العكسي للخطأ في التكنهن بالخطوات الآتية (Sinha, 2002) :

الخطوة الاولى: اختيار المتغيرات Variables Selection

اذ يجب اختيار المشاهدات للمتغيرات بحيث تمثل المشكلة تمثيلاً جيداً.

الخطوة الثانية: معالجة البيانات Data Processing

اجراء بعض العمليات على البيانات المستخدمة، مثل تحديد الاتجاه العام، التركيز على العلاقات بين المشاهدات، ايجاد توزيع البيانات.

الخطوة الثالثة: تقسيم البيانات الى مجاميع Divide data into Sets

تقسم البيانات المتوفرة الى المجاميع الآتية:

مجموعة التدريب **Training set**: مجموعة تعلم وتحديد نموذج للبيانات.

مجموعة الاختبار **Testing set**: والتي يمكن عن طريقها يتم تقيير مهارة الشبكة الافتراضية وامكانية استخدامها بصورة عامة.

مجموعة التحقيق **Validation set**: وهي مجموعة لاجراء اختبار نهائي لاداء الشبكة.

الخطوة الرابعة: نموذج (مثال) الشبكة العصبية Neural network paradigms

عند تحديد نموذج الشبكة العصبية يجب اختيار:

 عدد العصبونات للادخال الذي يساوي عدد المتغيرات المستقلة. 廈

 عدد الطبقات المخفية الذي يعتمد على قيمة الخطأ المستخدم في الشبكة. 廈

 عدد العصبونات المخفية الذي يحدد عن طريق التجربة. 廈

 عصبون الارجاع الذي عادة يساوي واحداً. 廈

الخطوة الخامسة: دالة التحويل Transfer function

الصيغة الرياضية لتحديد الارجاع والتي تمنع الارجاع من الوصول الى

قيمة عالية جداً وتستخدم احدى الصيغ او الدوال الآتية :

 廈 Linear

 廈 Threshold

 廈 Sigmoid

الخطوة السادسة: معيار التقويم Evaluation Criteria

ان المعيار المستخدم في شبكة الانتشار العكسي لتقييم الخطأ هو مجموع

مربعات الاخطاء .Mean Square Error (MSE)

الخطوة السابعة: تدريب الشبكة Neural Network Training

وتتضمن هذه الخطوة:

تعليم النموذج: تحديد مجموعة الاوزان بين العصبونات ومن ثم تحسين هذه الاوزان نتيجة التدريب والتي تحدد اقل قيمة لمربيع الخطأ للوصول الى اوزان تعطي نتائج دقيقة.

الخوارزمية: شبكة الانتشار الخلفي للخطأ تستخدم خوارزمية تدريب على الانحدار الميل.

الخطوة الثامنة: التنفيذ Implementation

وهي من اهم الخطوات، اذ تختبر الشبكة من حيث قدرة التكيف مع حالة التغير في الدورة وامكانية اعادة التدريب والوصول الى اقل مربيع خطأ عند تغيير البيانات الى الوصول الى حالة الاستقرار.


4- التكهن باستهلاك الطاقة الكهربائية في مدينة الموصل

إن البيانات التي نقوم بدراستها تمثل مقدار استهلاك الطاقة الكهربائية اليومية لمدينة الموصل (ميکاواط/ساعة) وللفترة من 15/6/2003 الى 25/9/2003 (البك، 2005). ولما كانت هذه البيانات تمثل مشاهدات مأخوذة بازمنة مختلفة وان قيمها تتغير بتغير الزمن، فمن الواضح انها تمثل بيانات لسلسلة زمنية ولتكن $\{P_t, t=0,1,2,\dots\}$ ، أي ان P_t تمثل مقدار استهلاك الطاقة الكهربائية (ميکاواط/ساعة) باليوم (t) في مدينة الموصل.


وصف السلسلة الزمنية

ان من اولى الخطوات التي تتبع لوصف او تحليل سلسلة زمنية هي رسماها بما يعرف بالرسم الزمني Time Series Plot ، اذ يمكن من خلال الرسم الاطلاع على طبيعة التذبذب فيها وملحوظة فيما اذا كانت تتضمن اتجاهًا عاماً ام لا؟ اذ أن معرفة الاتجاه العام يفيد كثيرا في التأكد من استقرارية السلسلة الزمنية فضلاً عن علاقته الوثيقة بالتكهن.

يبين الشكل (2) رسم السلسلة الزمنية التي نحن بصددها، ويلاحظ ان تذبذب السلسلة يبدأ بالهبوط التدريجي، ثم يأخذ بالصعود التدريجي وبشكل قطع مكافئ من الدرجة الثانية مما يدل على عدم استقرارية هذه السلسلة. من ناحية اخرى نلاحظ ان هناك شتتاً واضحاً حول التباين، مما يؤكّد وجود تأثيرات عشوائية واضحة ومؤثرة في هذه السلسلة.




الشكل (2): الرسم الزمني لمشاهدات استهلاك الطاقة الكهربائية في مدينة الموصل.
أما الشكل (3) فيوضح مقدراً دالة الارتباط الذاتي ACF للمشاهدات الخام فضلاً عن حد النسبة confidence limits لهذه الدالة بمستوى معنوية 5% والممثلة بالرسم بخطين افقيين متوازيين ومنقطتين.




الشكل (3): دالة الارتباط الذاتي Autocorrelation للمشاهدات الخام.

ولتحويل السلسلة الزمنية الى سلسلة مستقرة، اذ يشترط في التكهن بالطرائق الكلاسيكية أن تكون السلسلة مستقرة. لقد تم إجراء التحويل اللوغارتمي لمشاهدات السلسلة الأصلية ($X_t = \ln(p_t)$ ، اذ انها غير مستقرة بالتباعين، ثم تمأخذ الفروقات (ΔX_t) وبدأ بالفرق الأول (ΔX_t) ثم الفرق الثاني ($\Delta^2 X_t$). ولما كان الاتجاه العام تربيعياً كما هو متوقع فقد اعطى الفرق الثاني $Y_t = \Delta^2 X_t$ تذبذباً قريباً من التذبذب المستقر.


بعد الحصول على المستقرة في سلوك السلسلة (الشكل 4) فقد تم العمل من أجل تحديد النموذج الملائم ورتبتة، وذلك من خلال حساب دالة الارتباط الذاتي (ACF)، الموضحة في الشكل (5)، فضلاً عن حساب دالة الارتباط الذاتي الجزئي (PACF)، الموضحة في الشكل (6).



الشكل (4): سلوك المشاهدات بعد تحويل السلسلة الزمنية الى سلسلة مستقرة.



الشكل (5): دالة الارتباط الذاتي للسلسلة المستقرة $\{Y_t\}$.



الشكل (6): دالة الارتباط الجزئي للسلسلة المستقرة $\{Y_t\}$.

يتبيّن من الشكلين (5) و (6) ان النموذج المناسب للسلسلة $\{Y_t\}$ هو نموذج ARMA(2,1). وبعد أن تمت ملائمة النموذج والتأكّد من صلاحيته يتم توظيفه الان لغرض التكهن. لو كتبنا النموذج الملائم بالشكل الآتي:

$$Y_t + a_1 Y_{t-1} + a_2 Y_{t-2} = \varepsilon_t + b_1 \varepsilon_{t-1}$$

لذا فان

$$Y_{t+1} = -a_1 Y_t - a_2 Y_{t-1} + \varepsilon_{t+1} + b_1 \varepsilon_t$$

وبأخذ التوقع الشرطي للطرفين معطى Y_t, Y_{t-1}, \dots مع ملاحظة أن $E(\varepsilon_{t+1}|Y_t, Y_{t-1}, \dots) = 0$

$$\hat{Y}_{t+1} = -a_1 Y_t - a_2 Y_{t-1} + b_1 \varepsilon_t \quad (1)$$

حيث إن \hat{Y}_{t+1} هو المتكهّن بقيمة Y_{t+1} .

وبعد حساب \hat{Y}_{t+1} يمكن، بشكل تقريري حساب \hat{X}_{t+1} . فلما كانت

$$Y_t = \Delta^2 X_t = X_t - 2X_{t-1} + X_{t-2}$$

لذا نستنتج

$$\hat{X}_{t+1} = Y_{t+1} + 2X_t - X_{t-1}$$

وحيث إن $(P_t = e^{X_t})$ وهذا يقود إلى أن المتكون بقيمة P_{t+1} سوف يكون $\hat{P}_{t+1} = e^{\hat{X}_{t+1}}$.

5- استخدام الشبكات العصبية في التكهن

من الامور التي تشجع استخدام الشبكات العصبية في معالجة السلسلة الزمنية التي نحن بصددها هو ان هذه السلسلة ليست ذات مواصفات قياسية (كونها غير مستقرة)، كما ان عملية تحويلها باخذ الفروقات ليست محذنة دائما ما لم يكن التوزيع الاحتمالي للسلسلة الاصلية متوزعاً طبيعياً Normal. إن الشبكات العصبية يمكن استخدامها لمعالجة السلسل الزمانية غير الخطية، فضلا عن انه من المفيد من الناحية العلمية الاطلاع على هذا الاسلوب الحديث ومقارنته مع الاساليب الكلاسيكية للتعرف على امكانياته وكفاءته في اجراء التكهن.

لقد تم تصميم برنامج حاسوبي للحصول على قيم التكهن لسلسلة المشاهدات دون الحاجة الى معالجة عدم الاستقرارية، وان اول خطوة في استخدام البرنامج هي تحديد المدخلات للشبكة العصبية، اذ ان المدخلات هي الطاقة الكهربائية المستهلكة، وتحديد عدد العقد المخفية والذي يتحدد من خلال التدريب والذي يتضمن اجراء العديد من التجارب الحاسوبية، وكذلك يمكن حسابه من خلال المعادلة التي قدمها (Lin et al., 1995) اذ ذكرروا بان عدد العقد المخفية يمكن حسابه بالشكل الاتي:

$$N_{\text{hidden}} \leq \frac{N_{\text{train}} E_{\text{tolerance}}}{N_{\text{pts}} + N_{\text{output}}} \quad (2)$$

حيث ان: N_{hidden} يمثل عدد العقد المخفية.
 N_{train} يمثل عدد مرات التدريب.
 $E_{\text{tolerance}}$ يمثل مقدار الخطأ الاحتمالي.
 N_{pts} يمثل عدد البيانات التي تم اجراء التدريب عليها.
 N_{output} يمثل عدد عقد المخرجات.

وفي هذه الدراسة تم تثبيت مقدار الخطأ $E_{tolerance}$ كي يكون 0.01 وعدد مرات التدريب $N_{output} = 1$. وبتطبيق المعادلة (2) نجد ان :

$$N_{hidden} \leq \frac{5N_{pts}}{N_{pts} + 1}$$

لذا فان عدد العقد المخفية يجب ان يكون 4 للبيانات وحسب عدد مرات التدريب. وبما ان عدد البيانات المستخدمة في هذه الدراسة يبلغ (103) مشاهدات فقد اعتبر (13%) منها على انها مشاهدات اختبار Test لغرض الاختبار، واعتبر 15% من المشاهدات كمجموعة الشرعية Validation اما باقي المشاهدات فقد استخدمت للتدريب وتقدير المعايير الاحصائية.

6- المقارنة بين الطريقة الاحصائية وطريقة الشبكات العصبية

لغرض المقارنة بين الاسلوبين المستخدمين، وهما الاسلوب الكلاسيكي المتمثل باسلوب بوكس-جينكنز وأسلوب الشبكات العصبية فقد تم اعتماد المعايير الاحصائية الآتية في المقارنة:

معدل القيم المطلقة للاخطاء MAE.

معدل مربعات الخطأ MSE.

معدل القيم المطلقة لنسب الأخطاء MAPE.


والجدول الاتي يبين المعايير الاحصائية في المقارنة.

الجدول (1): المعايير الاحصائية للتکهن باستهلاک الطاقة الكهربائیة في مدينة

الموصى باستخدام الطرائق الاحصائية والشبكات العصبية.

MAE	MSE	MAPE	الطريقة المستخدمة
780.584	1065722	11.243	بوكس-جينكنز
238.577	97978.9	3.367	الشبكات العصبية

وكما هو واضح فان اسلوب الشبكات العصبية متفوق على طريقة بوكس-جينكنز ووفق المعايير الاحصائية الثلاثة. ويبيّن الشكل (7) قيم التکهن المحسوبة بالطريقتين المستخدمتين، ويتبّع من الشكل ان منحنى الشبكة العصبية هو الافضل في قيم التکهن.



الشكل (7) قيم التكهن المحسوبة بالطريقتين الكلاسيكية والشبكات العصبية.

يستخرج من ذلك تفوق الشبكات العصبية على الطرائق الكلاسيكية، اذ تم الحصول على نتائج ذات قيم اقل للمعايير الاحصائية المستخدمة لحساب أخطاء التكهن. لذلك تعتبر الشبكات العصبية الاصطناعية هي الطريقة الأفضل والأكثر دقة للتكنه بالقيم المستقبلية للسلسلة الزمنية قيد الدراسة، مما يشجع على استخدام هذا الأسلوب للتكنه بالسلسل الزمنية المختلفة. ونوصي بإجراء دراسات باستخدام شبكات عصبية اخرى غير شبكة الانشار العكسي للخطأ مثل شبكة المدرك Perceptron او الشبكة الدورية Recurrent Neural Network ومقارنة النتائج .

المصادر

1. البك، عزة حازم .(2005). "استخدام الشبكات العصبية في التكهن بالسلسلة الزمنية لاستهلاك الطاقة الكهربائية في محافظة نينوى". رسالة ماجستير غير منشورة، كلية علوم الحاسوب والرياضيات، جامعة الموصل.
2. الناصر، عبدالعزيز حمزة والعبدي، مروان عبدالحميد. (2003). "استخدام الشبكات العصبية للتتبؤ المستقبلي بقيم السلسلة الزمنية غير المنتظمة في طول الموسمية"، المجلة العراقية للعلوم الاحصائية، المجلد 3، العدد 6، كلية علوم الحاسوب والرياضيات، جامعة الموصل.
3. Atiya , A. F.; El-Shoura, S. M.; Shaheen, S. I. and El-Sherif, M. S. (1999). "**A Comparison Between Neural-Network Forecasting Techniques—Case Study: River Flow Forecasting**", IEEE Transactions On Neural Networks, Vol. 10, No. 2, March .
4. Box,G.P. and Jenkins,G.M.(1976)."Time Series Analysis Forecasting and Control" , Revised Edition Holden-Day Inc. San Francisco.
5. Gershenson , Carlos. (1998). "**Artificial Neural Networks for Beginners**", Sussex Academy, UK.

6. Lewis, P. A. W.; McKenzie, E. and Hugus, D. K. (1989). “**Gamma Processes**”, Commune Statistic, Stochastic Model, 5(1), 1-30.
7. Lin, Feng; Yu, Xing Huo; Gregor, Shirely and Irons, Richard. (1995). “**Time Series Forecasting with Neural Networks**”, Complexity International, Volume 02, ISSN 1320-0682, Australia.
8. Lotric, U. and Dobnikar , A. (2001). “**Wavelet Based Smoothing in Time Series Prediction with Neural Networks**”, University of Ljubljana, Faculty of Computer and Information Science, Slovenia.
9. Sansom , D. C. and Saha, T. K .Saha. (1999). “**Neural Networks For Forecasting Electricity Pool Price In A Deregulated Electricity Supply Industry**”, Department of Computer Science and Electrical Engineering, University of Queensland.
10. Sinha, H. (2002). “**Designing a Neural Network for forecasting Financial and Economic Time Series**”, June 4th, IND E 593.
11. Tong, Howell. (1990). “**Non-linear Time Series, A Dynamical System Approach**”, Institut of Mathematics and Statistics, University of Kent at Canterbury, Clarendon Press Oxford.
12. Whittle, P. (1963). “**Prediction and Regulation**”. English University Press, London, UK.
13. Zurada, Jacek M.and Cholewo ,Tomasz J.(1997). “**Sequential Network construction for Time Series Prediction**”, In Proceedings of the IEEE International Joint Conference on Neural Networks, pp. 2034–2039, Houston, Texas, USA.