

استخدام الشبكات العصبية في التكهّن للسلاسل الزمنية بتطبيق على استهلاك الطاقة الكهربائية في محافظة نينوى

رسالة مقدمة الى

مجلس كلية علوم الحاسبات والرياضيات بجامعة الموصل

وهي جزء من متطلبات نيل درجة ماجستير في

علوم الإحصاء

تقدمت بها

عزة حازم زكي امين بك

(بكلوريوس احصاء ، ١٩٨٥)

بإشراف

الأستاذ الدكتور باسل يونس الخياط

اقرار المشرف

اشهد أنّ إعداد هذه الرسالة جرى تحت اشرافي في كلية علوم الحاسبات والرياضيات -
جامعة الموصل وهي جزء من متطلبات نيل درجة الماجستير في علوم الاحصاء.

التوقيع :

اسم المشرف: أ. د. باسل يونس ذنون الخياط

المرتبة العلمية: استاذ

التاريخ : / / ٢٠٠٤

اقرار المقوم اللغوي

اشهد أنّ الرسالة الموسومة " استخدام الشبكات العصبية في التكهّن لسلاسل الزمنية
بتطبيق على استهلاك الطاقة الكهربائية في محافظة نينوى " قد تمت مراجعتها من الناحية
اللغوية بحيث اصبحت بعد التقويم خالية من الاخطاء ولاجله وقعت.

التوقيع :

الاسم : د. احمد ابراهيم خضر

المرتبة العلمية: مدرس

التاريخ : / / ٢٠٠٤

اقرار رئيس لجنة الدراسات العليا

بناءً على التوصيات التي تقدم بها المشرف والمقوم اللغوي، ارشح هذه الرسالة للمناقشة

رئيس لجنة الدراسات العليا

التوقيع :

الاسم : د. طالب شريف جليل

التاريخ : / / ٢٠٠٤

اقرار رئيس قسم الاحصاء

بناءً على التوصيات التي تقدم بها المشرف والمقوم اللغوي، ارشح هذه الرسالة للمناقشة

التوقيع :

الاسم : د. حسن محمد الياس

التاريخ : / / ٢٠٠٤

قرار لجنة المناقشة

نشهد اننا اعضاء لجنة التقويم المناقشة قد اطلعنا على هذه الرسالة الموسومة "استخدام الشبكات العصبية في التكهّن للسلاسل الزمنية بتطبيق على استهلاك الطاقة الكهربائية في محافظة نينوى" وناقشنا الطالبة عزة حازم زكي امين بك في محتوياتها وفيما له علاقة بها بتاريخ ١٢ / ٣ / ٢٠٠٥ وانها جديرة لنيل شهادة ماجستير في علوم الاحصاء.

التوقيع:	التوقيع:
الاسم: د. طالب شريف جليل	الاسم: د. ظافر رمضان مطر
المرتبة العلمية: استاذ مساعد	المرتبة العلمية: استاذ مساعد
التاريخ: / / ٢٠٠٥	التاريخ: / / ٢٠٠٥
رئيس اللجنة	عضو اللجنة

التوقيع:	التوقيع:
الاسم: د. عبدالستار محمد خضر	الاسم: د. باسل يونس ذنون
المرتبة العلمية: مدرس	المرتبة العلمية: استاذ
التاريخ: / / ٢٠٠٥	التاريخ: / / ٢٠٠٥
عضو اللجنة	عضو اللجنة (المشرف)

قرار مجلس الكلية

اجتمع مجلس كلية علوم الحاسبات والرياضيات بجلسته المنعقدة بتاريخ / / وقرر الاتي:

مقرر مجلس كلية علوم الحاسبات والرياضيات	عميد كلية علوم الحاسبات والرياضيات وكالة
د. ظافر رمضان مطر	د. ظافر رمضان مطر

j

اللَّهُ لَا إِلَهَ إِلَّا هُوَ الْحَيُّ الْقَيُّومُ لَا تَأْخُذُهُ
سِنَةٌ وَلَا نَوْمٌ لَهُ مَا فِي السَّمَاوَاتِ وَمَا فِي
الْأَرْضِ مَنْ ذَا الَّذِي يَشْفَعُ عِنْدَهُ إِلَّا بِإِذْنِهِ
يَعْلَمُ مَا بَيْنَ أَيْدِيهِمْ وَمَا خَلْفَهُمْ وَلَا يُحِيطُونَ
بِشَيْءٍ مِّنْ عِلْمِهِ إِلَّا بِمَا شَاءَ وَسِعَ كُرْسِيُّهُ
السَّمَاوَاتِ وَالْأَرْضَ وَلَا يَئُودُهُ حِفْظُهُمَا وَهُوَ
الْعَلِيُّ الْعَظِيمُ.

الله
العظيم

سورة البقرة (٢٥٥).

شكر وثناء

براً مني ووفاءً فاني أهدي عملي هذا إلى روح والدي الذي وافاه الأجل وأنا في مرحلة الأعداد لهذه الرسالة (رحمه الله واسكنه فسيح جناته)، والشكر كل الشكر إلى والدتي الكريمة (أطال الله في عمرها وحفظها من كل مكروه) لدعمها ومساندتها.

ولا يسعني وأنا اقدم عملي هذا إلا أن أتقدم بعظيم شكري وامتناني إلى عمادة كلية علوم الحاسبات والرياضيات والى أستاذي المشرف الأستاذ الدكتور باسل يونس ذنون الذي كان لتوجيهاته القيّمة وملاحظاته السديدة الأثر العميق في تذليل الكثير من الصعوبات، وفقه الله وجزاه خيرُ الجزاء.

وأتوجه بوافر شكري وامتناني إلى السيد رئيس قسم الإحصاء وكافة أساتذتي الأجلاء في قسم الإحصاء لما قدموه لي من علم وعون كريمين. كذلك اشكر الأستاذ المساعد صفاء يونس الصفاوي لما قدمه من تشجيع مستمر، والى كل زملائي وزميلاتي وكل مَنْ أعان بنصحٍ ببناء شكري وتقديري.

وعرفاناً بالجميل أتقدم بوافر شكري وعظيم امتناني إلى زملائي منتسبي مركز الحاسبة الإلكترونية في جامعة الموصل، والى كافة منتسبي كلية علوم الحاسبات والرياضيات لما أبدوه في تقديم التسهيلات. واقدم شكري أيضاً للدكتور احمد ابراهيم خضر المدرس في كلية الاداب لتقييمه الرسالة لغوياً.

وفق الله الجميع الى كل خير ومن الله التوفيق.

عزة

المستخلص

يُعدّ التكهّن بالسلوك المستقبلي للسلاسل الزمنية من الموضوعات الهامة في العلوم الإحصائية، وذلك للحاجة إليه في مجالات الحياة جميعاً، مثل التكهّن بالحالة الجوية ودرجات الحرارة، حالة السوق والأسعار، تدفق المياه، واستهلاك الطاقة الكهربائية. وقد تزايد الاهتمام بموضوع التكهّن خلال السنوات الأخيرة وظهرت أساليب حديثة خاصة في مجال علوم الحاسبات، 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 التكهّن الكلاسيكية المستخدمة حالياً مثل طريقة بوكس-جينكنز Box-Jenkins قد يصعب تشخيص السلسلة ونمذجتها لأنها تفترض شروط صارمة.

لذلك ظهرت الحاجة لمقارنة الطرائق الكلاسيكية المستخدمة في التكهّن بالسلاسل الزمنية مع أسلوب الشبكات العصبية لإيجاد الأسلوب الأكثر كفاءة في التكهّن، وكان هذا بالحقيقة يمثل الهدف الأساس لإجراء هذه الدراسة. لقد استخدمت بيانات خام عن استهلاك الطاقة الكهربائية في مدينة الموصل لإجراء المقارنة من خلال تطبيق برنامجي Minitab و Matlab للتحليل الإحصائي، وتم بناء برنامج بلغة ++C للشبكات العصبية الاصطناعية، ومن خلال التطبيق العملي وجدّ أن الشبكات العصبية. تعطي نتائج أفضل وأكثر كفاءة من الطريقة الكلاسيكية.

قائمة المحتويات

رقم الصفحة	الموضوع
	الفصل الاول: المقدمة
١	١-١ تمهيد.
٢	٢-١ التنبؤ والتكهن.
٣	٣-١ الاستعراض المرجعي.
٧	٤-١ الهدف من الدراسة والخطوط العريضة للرسالة.
	الفصل الثاني: الجانب النظري
٨	١-٢ مقدمة.
٨	٢-٢ العوامل التي تؤثر على تطور السلسلة الزمنية.
١١	٣-٢ التشويش الابيض.
١٢	٤-٢ دالتي التغيرات الذاتي والارتباط الذاتي.
١٢	٥-٢ السلاسل الزمنية المرحلية.
١٢	١-٥-٢ المرحلية التامة.
١٣	٢-٥-٢ المرحلية الضعيفة.
١٣	٦-٢ السلاسل الزمنية غير المرحلية.
١٤	٧-٢ تحليل الارتباط الذاتي.
١٥	٨-٢ الارتباط الذاتي الجزئي.
١٥	٩-٢ دالة كثافة الطيف.
١٦	١٠-٢ النماذج الرياضية للسلاسل الزمنية.
١٦	١-١٠-٢ نموذج الانحدار الذاتي.
١٧	٢-١٠-٢ نموذج الاوساط المتحركة.
١٨	٣-10-٢ النماذج المختلطة انحدار ذاتي واوساط متحركة.
١٩	١١-٢ مراحل بناء نماذج السلاسل الزمنية.
١٩	١-١١-٢ تحديد النموذج.
٢٠	٢-١١-٢ تقدير النموذج.
٢٠	٣-١١-٢ تدقيق التشخيص.
٢٠	٤-١١-٢ معيار اكيائي للمعلومات.
٢١	١٢-٢ الشبكات العصبية الاصطناعية.

رقم الصفحة	الموضوع
٢٣	١-١٢-٢ الخلفية التاريخية للشبكات العصبية.
٢٥	٢-١٢-٢ التعلم والتدريب.
٢٦	٣-١٢-٢ الشبكات العصبية ذات الانتشار العكسي.
٢٨	٤-١٢-٢ خوارزمية الشبكة العصبية ذات الانتشار العكسي.
٣٤	١٣-٢ علاقة الشبكات العصبية بعلم الاحصاء.
	الفصل الثالث : التكهّن
٣٦	١-٣ مقدمة.
٣٧	٢-٣ اساليب التكهّن.
٣٨	١-٢-٣ الاساليب النظامية في التكهّن.
٤٠	٢-٢-٣ الاساليب غير النظامية.
٤١	٣-٣ التكهّن بتقنيات بوكس-جينكنز.
٤٢	٤-٣ منهجية بوكس-جينكنز في التكهّن.
٤٤	٥-٣ التكهّن باستخدام الشبكات العصبية.
٤٦	٦-٣ عوامل انجاز الشبكة العصبية الاصطناعية.
	الفصل الرابع : التكهّن باستهلاك الطاقة الكهربائية في مدينة الموصل
٤٨	١-٤ مقدمة.
٤٨	٢-٤ وصف السلسلة الزمنية.
٥١	٣-٤ تقدير الاتجاه العام.
٥٧	٤-٤ استخدام الشبكات العصبية في التكهّن.
٦١	٥-٤ التطبيق العملي للشبكة العصبية ذات الانتشار العكسي للخطأ.
٦٤	٦-٤ المقارنة بين الطرق الاحصائية والشبكات العصبية.
	الفصل الخامس: الاستنتاجات والتوصيات
٦٦	١-٥ الاستنتاجات.
٦٦	٢-٥ التوصيات.
٦٧	المصادر
	الملاحق

قائمة الجداول

رقم الصفحة	العنوان	رقم الجدول
١٩	تحديد نموذج السلاسل الزمنية من خلال شكل دالة الارتباط الذاتي.	الجدول (١-٢)
4٣	بعض المصطلحات الاساسية في الشبكات العصبية وما يقابلها في علم الاحصاء.	الجدول (٢-٢)
٥٤	ملائمة النموذج $ARMA(p,q)$ للبيانات المحولة.	الجدول (1-٤)
٥٨	اختيار عدد العصبونات المخفية.	الجدول (٢-٤)
٥٩	اختيار عدد مرات التكرار.	الجدول (٣-٤)
٦٤	المعايير الاحصائية للتكهن باستهلاك الطاقة الكهربائية في مدينة الموصل باستخدام الطرق الاحصائية والشبكات العصبية.	الجدول (٤-٤)



قائمة الاشكال

رقم الصفحة	العنوان	رقم الشكل
٩	سلسلة زمنية ذات اتجاه عام موجب.	الشكل (١-٢)
١٠	التغيرات الموسمية للسلسلة الزمنية.	الشكل (٢-٢)
١٠	التغيرات الدورية للسلسلة الزمنية.	الشكل (٣-٢)
٢١	الشبكة البيولوجية Biological Networks.	الشكل (٤-٢)
٢٢	الشبكة العصبية الاصطناعية Artificial Neural Network.	الشكل (٥-٢)
٢٧	الشبكة العصبية ذات الانتشار العكسي.	الشكل (٦-٢)
٣٢	دالة Sigmoid.	الشكل (٧-٢)
٣٣	خوارزمية شبكة الانتشار العكسي للخطأ.	الشكل (٨-٢)
٣٧	اساليب التكهن.	الشكل (١-٣)
٤٣	مراحل النمذجة وفق اسلوب بوكس-جينكنز	الشكل (٢-٣)
٤٧	خطوات تدريب شبكة الانتشار العكسي	الشكل (٣-٣)
٤٩	الرسم الزمني لمشاهدات استهلاك الطاقة الكهربائية في مدينة الموصل.	الشكل (١-٤)
٤٩	دالة الارتباط الذاتي Autocorrelation للملاحظات الخام.	الشكل (٢-٤)
٥٠	المخطط الدوري للملاحظات الخام.	الشكل (٣-٤)
٥٢	سلوك المشاهدات بعد تحويل السلسلة الزمنية الى سلسلة مرحلية.	الشكل (٤-٤)
٥٣	دالة الارتباط الذاتي للسلسلة المرحلية $\{Y_t\}$.	الشكل (٥-٤)
٥٣	دالة الارتباط الجزئي للسلسلة المرحلية $\{Y_t\}$.	الشكل (٦-٤)
٥٥	دالة الارتباط الذاتي لبواقي النموذج ARMA(2,1).	الشكل (٧-٤)
٥٥	دالة الارتباط الذاتي الجزئي لبواقي النموذج ARMA(2,1).	الشكل (٨-٤)
٦٠	مستوى الخطأ المطلق للشبكة العصبية ذات الانتشار العكسي للخطأ.	الشكل (٩-٤)
٦٢	الشبكة العصبية ذات الانتشار العكسي للخطأ والاوزان التي تم الحصول عليها.	الشكل (١٠-٤)
٦٥	قيم التكهن المحسوبة بالطريقتين الكلاسيكية والشبكات العصبية.	الشكل (١١-٤)

الفصل الأول

المقدمة



١-١ تمهيد

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

يرتكز تحليل السلاسل الزمنية على ثلاث ركائز تتمثل بثلاثة افتراضات رئيسية:

- إن السلسلة الزمنية خطية Linear، أي يمكن تمثيلها بنموذج رياضي خطي.
- إن السلسلة الزمنية طبيعية Normal، أي أنها تتوزع توزيعاً طبيعياً.
- إن السلسلة الزمنية مرحلية Stationary، أي أن خصائصها الرياضية والإحصائية لا تعتمد على الزمن.

وكما أشرنا سابقاً فإن 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 (Lowis et al., 1989)، وأما الافتراض الثالث (المرحلية) فيبقى هو الافتراض الأصعب والأكثر إلحاحاً لإيجاد أساليب تتجاوزه، وذلك لأن أغلب السلاسل الزمنية الواقعية هي سلاسل غير مرحلية.

من الأهداف الأساسية للعلوم الإحصائية التوقع والتكهّن بالسلوك المستقبلي للظاهرة قيد البحث. حيث نجد يومياً، ومن خلال وسائل الاعلام، الاهتمام اليومي بالتكهّنات الجوية والمتغيرات الاقتصادية المختلفة. وقد أولى تحليل السلاسل الزمنية اهتماماً كبيراً للتكهّن واقتُرحت العديد من الأساليب لغرض إجراء التكهّن.

ومن الأساليب الحديثة التي أخذت اهتماماً ملحوظاً، وخاصة في مجال علوم الحاسبات، الشبكات العصبية الاصطناعية (Artificial Neural Networks (ANNs)، حيث أن الفكرة الأساسية من هذا الأسلوب هو إنشاء نموذج معلومات يحاكي النظام البيولوجي العصبي، مثل الدماغ، ومعالجة المعلومات. إن المفتاح الأساس 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 متناسق لحل المشكلة قيد الدراسة.

والشبكات العصبية الاصطناعية (ANNs) تتعلم بطريقة تشابه 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 تكييف نقاط الاشتباك العصبي بين العصبونات، وهذه هي الفكرة الجوهرية في عمل الشبكات العصبية. وفي المجال الإحصائي، ظهرت في الآونة الأخيرة اهتمامات خاصة لإدخال أسلوب الشبكات العصبية إلى التطبيقات الإحصائية. ولما كان استخدام أسلوب الشبكات العصبية لا يتطلب افتراضات عن طبيعة السلسلة الزمنية، كونها خطية أو طبيعية أو مرحلية، لذا يُعتقد إن استخدام هذا الأسلوب قد يكون مجزياً في معالجة مسألة التكهن التي نحن بصددنا بهذه الدراسة.

٢-١ التنبؤ والتكهن

مما لا شك فيه أن عملية تقدير السلوك المستقبلي لأي ظاهرة أو متغير تعد من الأهداف الأساسية للعلوم الإحصائية، وذلك لأن لهذه العملية أهمية كبيرة في عملية التخطيط للظاهرة أو المتغير قيد الدراسة وان التخطيط هو المفتاح لعملية اتخاذ القرار السليم. لقد أولت الحكومات والمؤسسات المختلفة اهتمامات كبيرة لتقدير السلوك المستقبلي للعديد من الظواهر الطبيعية والصناعية والاقتصادية، وأنشأت المراكز والوحدات المختلفة لهذا الغرض. وفي مجال تحليل السلاسل الزمنية، نجد أن موضوع تقدير السلوك المستقبلي للسلاسل الزمنية يعد محورياً رئيساً أولى له الباحثون اهتمامات كبيرة، وعلى وجه الخصوص نجد أن هناك نظرية رياضية قد أفردت لذلك يطلق عليها Prediction Theory (انظر Whittle (1963)). من ناحية أخرى نجد أن هناك العديد من الأساليب قد طورت لأغراض إجراء التكهن للقيم المستقبلية للسلسلة الزمنية يطلق عليها Forecasting.

ونجد أن العديد من الباحثين يطلقون تسمية "تنبؤ" على المصطلحين Prediction و Forecasting في حين إن للمصطلحين معنيان مختلفان من الناحية العلمية. كما نجد أن هناك اجتهادات مختلفة في مجال التعريب. فعلى سبيل المثال نجد أن المجمع العلمي العراقي يطلق على عملية التنبؤ بعملية "استشراف" كون العملية هي استشرافاً للمستقبل.

وعلى غرار كلمتي Probability و Likelihood نجد أن كلمتي Prediction و Forecasting يحملان المعنى نفسه تقريباً من الناحية اللغوية. أما من الناحية العلمية فنجد أن عملية إيجاد قيم مستقبلية لسلسلة زمنية من خلال تعابير رياضية محددة وصريحة يطلق عليها عادة كلمة Prediction (انظر (Whittle 1963))، وسوف نستخدم المصطلح العربي " تنبؤ" لتعريب كلمة Prediction كون هذا المصطلح شائع على نطاق واسع. وبالرجوع إلى المصادر الأساسية لتحليل السلاسل الزمنية نجد أن الباحثين Box-Jenkins (1970) قد قدموا خوارزمية تعاقبية لحساب القيم المستقبلية من سلسلة زمنية منفصلة الزمن والتي تحقق نماذج خطية عدد معالمها محدود وأطلقا على ذلك " Forecasting" (انظر (Priestley 1981)). وسوف نستخدم المصطلح " تكهن" لتعريب المصطلح الأخير وتمييزه عن المصطلح السابق. ويمكن إجمال ما سبق بان مصطلح تنبؤ Prediction يستخدم عندما يكون لدينا تعابير محددة وصريحة للقيم المستقبلية، في حين إن مصطلح تكهن Forecasting يستخدم عندما نقوم بحساب القيم المستقبلية عددياً.

٣-١ الاستعراض المرجعي

تزداد أهمية التكهن في السلاسل الزمنية بشكل مطرد وذلك لعلاقته الوثيقة بعجلة التطور لمختلف العلوم. وفي السنوات الأخيرة نجد أن اهتمامات الباحثين قد تزايدت في تطوير أساليب التكهن وذلك باستخدام مختلف التقنيات الحديثة، مثل الشبكات العصبية. ففي سنة (١٩٩٥) قدم الباحث Portugal بحثاً تضمن تدريب الشبكة في التكهن الاقتصادي باستخدام السلاسل الزمنية التقليدية مثل ARIMA والشبكات العصبية الصناعية ANN واختبر الناتج المحلي الشهري لمنطقة Rio Grand في البرازيل واعطى وصفاً لمدخلات الأداء النسبي وطرق التكهن المختلفة، وبينت النتائج إن استخدام الشبكات العصبية أعطت تكهن أكثر دقة من نماذج ARIMA الشائعة.

ونشر الباحثان Zurada & Cholewo (1997) بحثاً تناولوا فيه الطرائق الجديدة للتكهن التي ظهرت في العقد الأخير من القرن الماضي ومنها الشبكات العصبية الاصطناعية Artificial Neural Networks (ANNs) وقدما تطبيقاً لاختيار حجم الشبكات العصبية الشائعة، ومنها شبكة Finite Impulse Response Neural Network (FIR) والشبكة الدورية Elman Network والشبكات المتطورة منها. وأجريا التكهن باستخدام التباين وتقدير

الشرعية المتقاطع اللاخطي Nonlinear Cross Validation، وتوصلا إلى أن افضل شبكة للتكهن باستخدام بيانات Wolfer هي شبكة FIR، أما فيما يخص بيانات Mackey-Glass الاقتصادية فقد كانت افضل شبكة هي Elman Network.

أما (1999) Atiya et al. فقد نشروا بحثاً يهدف استخدام الشبكات العصبية لمسألة التكهن بتدفق المياه في نهر النيل، واستخدمت السلسلة الزمنية كنموذج للمقارنة بين بعض الشبكات العصبية في التكهن، كما طبقت أربع طرائق مختلفة لعملية الإدخال للحصول على المخرجات باستخدام طرق جديدة اقترحت كأساس لسلسلة فورير المتقطعة.

وقدم (1999) Sansom & Saha بحثاً للتكهن بأسعار الكهرباء في استراليا واستخدما الشبكات العصبية للتكهن وتوصلا إلى أن الأسعار الأسبوعية ثابتة ولكنها تتغير كل ستة اشهر. قدم (2000) Kneale et al. بحثاً للمقارنة بين تسعة تقييمات لدرجة حرارة الكون ونموذجين للتكهن واستخدموا الشبكة العصبية ذات الانتشار العكسي للخطأ Backpropagation Neural Network (BPNNs) وشبكة Time Delay (TDNNs) للتكهن وتوصلوا إلى أن الشبكة (TDNNs) هي الأفضل إلا أنها لاتعد كافية للعمل في هذا المجال.

وفي العام نفسه نشر (2000) Lendass et al. بحثاً طوروا فيه طريقة للتكهن بالسلاسل الزمنية غير الخطية، وهذه الطريقة تمتاز باستخدام اكبر عدد من المعلومات التي يمكن الحصول عليها وكبسها بنموذج غير خطي للحصول على متجه محدد الحجم يسهل عملية التكهن، واستخدمت الشبكة العصبية Radial Basis Function (RBF) للتكهن بحالة السوق المالية Bel 20 stock market.

وقام (2001) Tkacz بدراسة حالة السوق في كندا بهدف تحسين دقة التكهن بحالة السوق باستخدام نموذج الشبكات العصبية واستخدام بيانات فصلية Seasonal Time Series وتوصل إلى أن الشبكات العصبية أعطت اقل قيم معدل مربع خطأ للتكهن.

أما (2001) Lotric and Dobnikar فقد قدما بحثاً لتقليل حالة التشويش (noise) في التكهن للسلاسل الزمنية، وأستخدمت شبكات عصبية متعددة الطبقات مع وحدات تنعيم Smoothing، كما استخدمت طريقتان للمقارنة هما: التنعيم باستخدام الطرائق الإحصائية والتنعيم باستخدام خطأ التكهن كمقياس. وتوصلا إلى أن التكهن بالتشويش للسلسلة الزمنية التي

استخدمت الشبكات العصبية متعددة الطبقات افضل من النموذج الذي استخدم خطأ التكهّن كأساس.

واستخدم (2001) Wang التكهّن بالسلاسل الزمنية على الخط "on-line" واعتمد على نموذج متطور من الشبكة العصبية المضببة Fuzzy Neural Networks EfuNN-T التي نوقشت بصورة موسعة والتطور في المنهجية والعوامل ليلائم البيانات واستخدمت هذه الطريقة للتكهّن بالسلاسل الزمنية.

قدم الباحثان (2002) Moisaio and Pires بحثاً ذكر فيه إن التكهّن بقيم السلاسل الزمنية يُعدّ مشكلة شائعة واستخداماً نوعين من الشبكات العصبية هما Self Organizing Recurrent Neural Network (RNN) وFeatures Map (SOM) والشبكات الدورية للشبكات العصبية للتكهّن بحالة السوق لمدة يوم واحد، يومين، وسبعة أيام بالاعتماد على بيانات سابقة واثبتا تفوق الشبكات العصبية على الطرق الكلاسيكية مثل الطرائق الإحصائية الاعتيادية نظراً لقدرة الشبكات على التعامل مع البيانات غير الدقيقة، المضببة، أو البيانات غير الكافية.

قام الباحثان (2002) Zhou and Tang بدراسة العلاقة بين عناصر وأدوات الشبكات العصبية لتحليل الـ kphv والتصنيف Classification and Regression.

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

ونشر (2002) Ennett and Frize بحثاً استخدموا فيه الشبكة العصبية ذات الانتشار العكسي للخطأ Backpropagation Neural Networks (BPNNs) لدراسة حالة المرضى

واستخدما التاريخ المرضي للمريض كإدخال أما الإخراج فبُين مقدار نسبة الموت للتدريب وللاختبار.

وقام الباحثان (Bone and Assaad (2003 بتكييف صيغة رياضية للتكهن بالقيم المستقبلية للسلاسل الزمنية باستخدام الشبكات العصبية الدورية، ووضحا بان خوارزمية تحسين الأداء Boosting algorithm أدت إلى نتائج جيدة وبيننا أن الوسيط الموزون أفضل للتعليم من الوسط الحسابي الموزون.

وعلى النطاق المحلي فقد قدمت بحوث في هذا المجال نذكر منها الشخلي و الكيلاني سنة (٢٠٠٣) حيث استخدمنا نماذج الشبكات العصبية لنمذجة نظام رياضي ديناميكي لاخطي يعكس نشاط المبيعات الذي يتضمن التحليل والتقييم والتحكم والتكهن بالطاقة الكهربائية المستلمة والطاقة المباعة والنقد المستلم لنشاط المبيعات في الشركة العامة لتوزيع كهرباء بغداد. وقدم كل من الناصر والعبيدي سنة (٢٠٠٣) بحثا لتوظيف الشبكات العصبية للتكهن بالقيم المستقبلية لظاهرة تتبع سلسلة زمنية غير المنتظمة في طول الموسمية. وتوصلا إلى أن الشبكات العصبية تتمكن من التعلم والتكيف ذاتيا مع أي نموذج وقورنت نتائج الشبكات العصبية مع طرائق التكهن الكلاسيكية للتعرف على سلوكية وجودة الشبكات العصبية.

٤-١ الهدف من الدراسة والخطوط العريضة للرسالة:

تهدف هذه الدراسة بشكل رئيس إلى دراسة استخدام أسلوب الشبكات العصبية في تحليل السلاسل الزمنية، وعلى وجه الخصوص مقارنة أسلوب الشبكات العصبية مع الأساليب الكلاسيكية في تحليل السلاسل الزمنية في مجال التكهن.

يضم الفصل الأول من هذه الدراسة مقدمة عن السلاسل الزمنية والتكهن ويتم التطرق إلى بعض البحوث التي تناولت استخدام الشبكات العصبية في التكهن من خلال الاستعراض المرجعي.

أما الفصل الثاني فيتضمن بعض المفاهيم المهمة في تحليل السلاسل الزمنية والطرائق الكلاسيكية في التكهن مع التطرق إلى الشبكات العصبية ونشؤها ثم الدخول إلى شبكة الانتشار الخلفي للخطأ بصورة مفصلة وذلك لأهمية هذه الشبكة واستخدامها في التكهن. واما الفصل الثالث فيتضمن طرق التكهن الاعتيادية واختيار افضل نموذج للتكهن.

لقد تم تخصيص الفصل الرابع للجانب العملي والذي يشمل طريقة تحليل السلاسل الزمنية والتكهن باستخدام الطريقتين الكلاسيكية والشبكات العصبية وإجراء مقارنة بين الطريقتين باستخدام بيانات لاستهلاك الطاقة الكهربائية في مدينة الموصل، للوصول إلى افضل طريقة في تقدير المعالم الإحصائية المعروفة. وختاماً فإن الفصل الخامس يتضمن أهم الاستنتاجات والتوصيات المستنتجة من هذه الدراسة.

الفصل الثاني

الجانب النظري

THEORETICAL SIDE



- ١-٢ مقدمة.
- ٢-٢ العوامل التي تؤثر على تطور السلسلة الزمنية.
- ٣-٢ التشويش الابيض.
- ٤-٢ دالتي التغيرات الذاتي والارتباط الذاتي.
- ٥-٢ السلاسل الزمنية المرحلية.
- ٦-٢ السلاسل الزمنية غير المرحلية.
- ٧-٢ تحليل الارتباط الذاتي.
- ٨-٢ الارتباط الذاتي الجزئي.
- ٩-٢ دالة كثافة الطيف.
- ١٠-٢ النماذج الرياضية للسلاسل الزمنية.
- ١١-٢ مراحل بناء نماذج السلاسل الزمنية.
- ١٢-٢ الشبكات العصبية الاصطناعية.
- ١٣-٢ علاقة الشبكات العصبية بعلم الاحصاء.

٢-١ مقدمة

إن السلسلة الزمنية هي عبارة عن مجموعة من البيانات المسجلة لظاهرة معينة خلال فترة زمنية سابقة لبعض الحالات الاقتصادية أو الاجتماعية أو الإحصائية وتكون مرتبة بشكل متسلسل حسب الزمن، وعادة تكون الفترات الزمنية بين مشاهدة وأخرى متساوية.

وتعرف **السلسلة الزمنية** رياضياً بأنها متتابعة من المتغيرات العشوائية معرفة ضمن فضاء الاحتمالية متعددة المتغيرات ومؤشرة بالدليل t والذي يعود إلى مجموعة دليلية T ويرمز للسلسلة الزمنية عادة $\{X(t); t \in T\}$ أو اختصاراً $\{X(t)\}$. وإذا كانت t تأخذ قيماً مستمرة فإن السلسلة الزمنية تسمى "**مستمرة الزمن**" ويرمز لها $\{X(t); -\infty \leq t \leq \infty\}$ أو $\{X(t)\}$. أما إذا كانت t تأخذ قيماً متقطعة $t=0, \pm 1, \pm 2, \dots$ فإن السلسلة تسمى "**متقطعة الزمن**" ويرمز لها $\{X_t; t=0, \pm 1, \pm 2, \dots\}$ أو $\{X_t\}$ (العبيدي، ١٩٨٩).

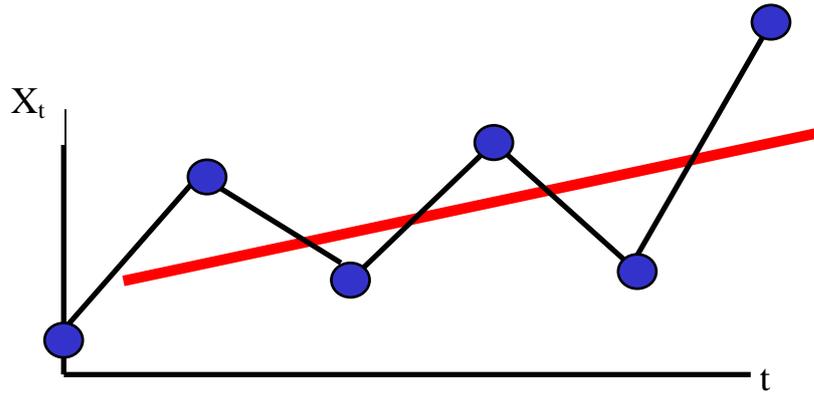
أما Viond (1993) فيعرف السلسلة الزمنية: بأنها إذا كانت X_t تمثل مشاهدة من السلسلة الزمنية $\{X_t\}$ ، فإن المتتابعة Sequence من المتغيرات العشوائية المرتبة Order Random Variables $[X_{-2}, X_{-1}, X_0, X_1, X_2, \dots]$ معرفة في فضاء احتمالية متعدد الأبعاد Multidimensional Probability Space (Ω, ε, P) تسمى العملية التصادفية Stochastic Process. حيث إن المجموعة $T = \{\dots, -2, -1, 0, 1, 2, \dots\}$ هي مجموعة دليلية Index set، والتي عندما تمثل الزمن Time فعندئذ تسمى العملية العشوائية "سلسلة زمنية".

٢-٢ العوامل التي تؤثر على تطور السلسلة الزمنية

إن تطور الظواهر المسجلة في السلسلة الزمنية قد تكون نتيجة لعوامل كثيرة ومنها عوامل اقتصادية وعوامل طبيعية وعوامل موسمية. إن بعض هذه العوامل قد تؤثر على الاتجاه العام للسلسلة الزمنية في الأجل الطويل بينما تسبب البعض الآخر في تكوين الذبذبات القصيرة الأجل (Heizer, 2003).

٢-٢-١ Trend (T_t) الاتجاه العام

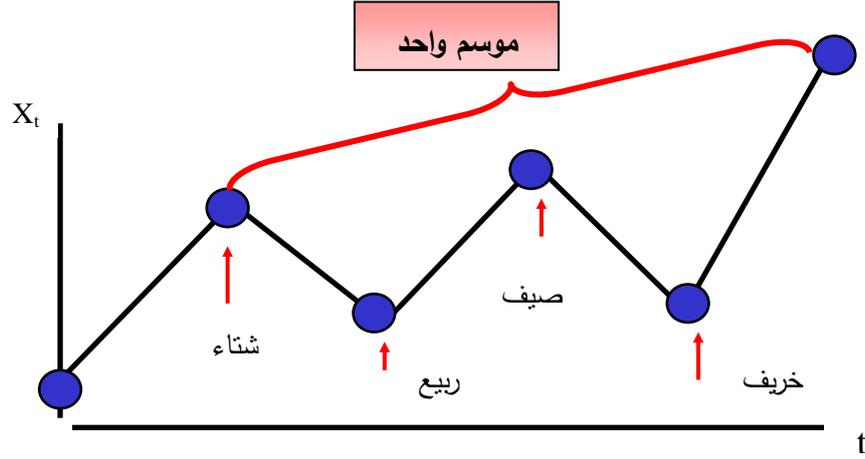
إن الاتجاه العام، بصرف النظر عن كونه اتجاهًا صعودياً أو نزولياً، للظاهرة المدروسة يعكس تطور الظاهرة خلال فترة طويلة من الزمن. ويلخص الاتجاه العام التغيرات الأساسية في الحياة الاقتصادية في الأجل الطويل. لذا يفضل أن تكون المشاهدات المدروسة للسلسلة الزمنية تغطي فترة زمنية طويلة لكي يتمكن من كشف الاتجاه العام لها بشكل واضح.



الشكل (١-٢): سلسلة زمنية ذات اتجاه عام موجب.

٢-٢-٢ تغيرات موسمية (S_t) Seasonal Variations

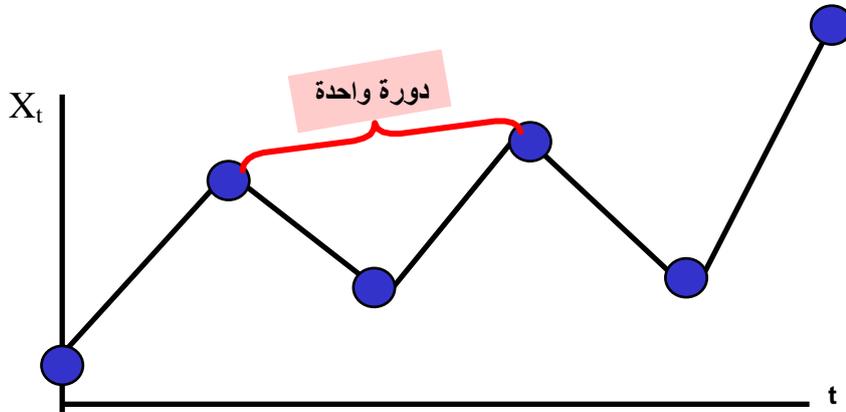
يقصد بها التغيرات في مواسم أو فصول السنة، والتغيرات الموسمية تكرر نفسها عادة ولكن درجة هذا التغير قد تختلف من وقت لآخر. فالعوامل المناخية والتقاليد الاجتماعية من أهم العوامل التي تسبب التغيرات الموسمية، كما أن اختلاف المناخ في فصول السنة يعد أحد الأسباب الرئيسية في التغيرات الموسمية للسلع الزراعية والصناعات المترتبة عليها. ومن الأمور المهمة إجراء التكهّن بهذه التغيرات عند اتخاذ القرارات، وإن إيجاد الحلول الممكنة لهذه المشكلات تعتمد على دراسة طبيعة هذه التغيرات والتكهّن بها بدقة، كما أن دراسة التغيرات الموسمية مهمة في ذاتها، إلا أنه يجب تقديرها لاستبعاد تأثيرها على السلسلة الزمنية حتى يمكن دراسة التغيرات نتيجة الدورات وتعيين توقيتاتها بدقة.



الشكل (٢-٢): التغيرات الموسمية للسلسلة الزمنية.

٣-٢-٢ تغيرات دورية (C_t) Cycle Variations

إن الدورات تسبب تذبذبات في نشاط السلسلة الزمنية وتتكون الدورة من فترة توسع يتبعها فترة انكماش، وان هذه التغيرات الدورية تكون عادة متكررة الحدوث ولكنها لا تحدث على فترات منتظمة وقد تستغرق من سنة إلى ١٠ أو أكثر.



الشكل (٣-٢): التغيرات الدورية للسلسلة الزمنية.

٤-٢-٢ تغيرات عشوائية (e_t) Random Variations

هي تلك التذبذبات التي تكون نتيجة عوامل عشوائية خارج نطاق السيطرة وهذه التغيرات لا يمكن التكهّن بها وان التذبذبات العشوائية لا تؤثر على الاتجاه العام للظاهرة قيد الدراسة، وهي غير مهمة نسبيا بالرغم من صعوبة تفسيرها، إلا انه يمكن إظهار تأثيرها وهي تظهر كتذبذبات صغيرة منتظمة في بيانات السلسلة الزمنية.

ملاحظة: تمثل السلاسل الزمنية عادة بنموذجين عامين:

• النموذج الجمعي

يفترض هذا النموذج أن قيمة الظاهرة X_t عند نقطة زمنية معينة هي عبارة عن مجموع العناصر الأربعة وهي الاتجاه العام والتغيرات الموسمية والتغيرات الدورية والتغيرات العشوائية. أي أن

$$X_t = T_t + S_t + C_t + e_t \quad (2.1)$$

• النموذج الضربي

يفترض هذا النموذج أن قيمة الظاهرة X_t في فترة زمنية معينة هي عبارة عن حاصل ضرب العناصر الأربعة آنفة الذكر.

$$X_t = T_t \times S_t \times C_t \times e_t \quad (2.2)$$

ويلاحظ انه بأخذ لوغاريتم طرفي المعادلة (2,2) فان النموذج الضربي يتحول إلى

نموذج جمعي.

٢-٣ التشويش الأبيض White Noise

إن العملية العشوائية $\{\varepsilon_t\}$ تدعى بعملية التشويش الأبيض (White Noise Process) إذا كانت تمثل متتابعة Sequence من المتغيرات العشوائية غير المترابطة مع بعضها البعض Uncorrelated والتي معدلها يساوي صفر وتباينها محدود σ_ε^2 (Vinod, 1999)، أي أن:

$$E(\varepsilon_t) = 0$$

$$\text{Var}(\varepsilon_t) = \sigma_\varepsilon^2$$

$$\text{Cov}(\varepsilon_t, \varepsilon_{t+k}) = 0, \quad \forall k \neq 0.$$

٢-٤ دالتي التغير الذاتي والارتباط الذاتي

إن $\gamma_k = \text{Cov}(X_t, X_{t+k})$ تسمى دالة التغاير الذاتي بإبطاء k Autocovariance Function of lag k للسلسلة الزمنية $\{X_t; t \in T\}$ ولها الخواص الآتية (Tong, 1990):

$$1- \text{ لجميع قيم } k \text{ فإن } |\gamma_k| \leq \gamma_0$$

$$2- \text{ Var}(X_t) = \gamma_0$$

3- إذا كانت $\{X_t\}$ هي سلسلة زمنية حقيقية Real Time Series فإن الدالة γ_k

تكون متناظرة حول الصفر. أي أن $\gamma_{-k} = \gamma_{+k}$ لجميع قيم k .

4- لجميع قيم $t_1, t_2, \dots, t_n \in T$ ولأي عدد موجب n ولجميع المتغيرات الحقيقية

$$z_1, z_2, \dots, z_n \text{ فإن } \sum_{r=1}^n \sum_{s=1}^m \gamma_{t_r - t_s} z_r z_s \geq 0$$

إن النسبة $\rho_k = \gamma_k / \gamma_0$ تسمى دالة الارتباط الذاتي بإبطاء k

Autocorrelation Function of lag k للسلسلة الزمنية $\{X_t; t \in T\}$. إن خصائص ρ_k

هي مماثلة للخصائص (2)-(4) لـ γ_k بعد إبدال ρ بدل γ . أما الخاصية (1) فيمكن أن نستنتج

بسهولة أن $|\rho_k| \leq 1$ لجميع قيم k .

2-5 السلاسل الزمنية المرحلية Stationary Time Series

إن رسم السلسلة الزمنية في الفترة $[t, t+h]$ قد يكون في بعض الأحيان مطابقاً لرسم السلسلة في فترة أخرى $[s, s+h]$ وهذا يدل على أنه هناك تجانس زمني في سلوك السلسلة، والذي يسمى مرحلية Stationarity. إن شرط المرحلية بالرغم من عدم واقعته في العديد من التطبيقات، إلا أنه شرط يوضع لغرض تسهيل التعامل الرياضي مع السلاسل الزمنية (Viond, 1999).

2-5-1 المرحلية التامة Strictly Stationary

يقال أن السلسلة الزمنية $\{X_t\}$ مرحلية تامة إذا كان التوزيع الاحتمالي المشترك

للمتغيرات $X_{t_1}, X_{t_2}, \dots, X_{t_n}$ هو نفس التوزيع الاحتمالي المشترك للمتغيرات $X_{t_1+k},$

$X_{t_2+k}, \dots, X_{t_n+k}$ لجميع النقاط الزمنية المختارة t_1, t_2, \dots, t_n ولأي ثابت k .

إن شرط المرحلية التامة هو شرط صعب التطبيق من الناحية العملية وذلك لكونه

يتطلب اختبار تماثل توزيعات احتمالية، لذا يستعاض عنه عادة بشرط أخف وبدلالة العزوم،

ذلك هو المرحلية الضعيفة Weak Stationary.

٢-٥-٢ المرحلة الضعيفة Weak Stationary

إن مفهوم المرحلة الضعيفة يسمح للتوزيع الاحتمالي المشترك للمتغيرات $X_{t1}, X_{t2}, \dots, X_{tn}$ بالتغير لحد ما مع الزمن، ولكن يتطلب أن يكون الوسط والتباين ثابتين، كذلك يتطلب أن يكون التغير $Cov(X_t, X_{t+h})$ دالة لفترات الإبطاء للفترة h فقط، ولا يعتمد على الزمن t .

وكحالة خاصة يقال للسلسلة الزمنية $\{X_t\}$ بأنها مرحلة من الرتبة الأولى First-order Stationary إذا كانت: $E(X_t) = \mu$ كمية ثابتة غير معتمدة على t ، كما يقال للسلسلة الزمنية $\{X_t\}$ بأنها مرحلة من الرتبة الثانية Second-order Stationary إذا حققت الشروط الآتية (Priestley, 1981):

- ١- $E(X_t) = \mu$ ، حيث أن μ كمية ثابتة غير معتمدة على t .
- ٢- $Var(X_t) = \sigma^2$ ، حيث أن σ^2 كمية ثابتة غير معتمدة على t .
- ٣- $Cov(X_{t1}, X_{t2}) = \gamma(t_2 - t_1)$ دالة بدلالة $|t_2 - t_1|$ فقط .

٦-٢ السلاسل الزمنية غير المرحلة Non-Stationary Time Series

قد لا نكون مغالين إذا قلنا إن أغلب السلاسل الزمنية الواقعية هي سلاسل غير مرحلة. فعلى سبيل المثال نجد أن المتغيرات الاقتصادية غالباً ما تعتبر سلاسل زمنية غير مرحلة كونها تسير بصفة عامة في اتجاه عام، لذلك لا بد من تحويلها إلى سلاسل زمنية مرحلة يسهل نمذجتها، وغالباً ما يمكن تحويلها إلى سلسلة مرحلة بإحدى الطرائق الآتية (Hamilton, 1994):

١- إجراء تعديل الفروق وتوليد سلسلة زمنية جديدة

تقتضي هذه الطريقة طرح قيم المشاهدات من بعضها البعض لفترات إبطاء

(lags)، فمثلاً الفرق من الرتبة الأولى يكون كالآتي:

$$W_t = \Delta X_t = X_t - X_{t-1}$$

أما الفرق من الرتبة الثانية

$$\begin{aligned} Z_t &= \Delta W_t = W_t - W_{t-1} \\ &= \Delta X_t - \Delta X_{t-1} \\ &= (X_t - X_{t-1}) - (X_{t-1} - X_{t-2}) \end{aligned}$$

$$\therefore Z_t = X_t - 2X_{t-1} + X_{t-2}$$

ويمكن إجراء أكثر من فرق، ولكن عادة يُعدّ الفرق الأول أو الثاني كافياً (المعهد العربي للتخطيط، ٢٠٠٠).

٢- في حالة عدم ثبات التباين

من الوسائل المستخدمة في تثبيت التباين أخذ اللوغاريتيم أو اخذ الجذر التربيعي لبيانات السلسلة الزمنية، أما فيما يخص البيانات سالبة الإشارة فيمكن إضافة ثابت مناسب لتحويل البيانات إلى موجبة الإشارة قبل إجراء التحويلات، وهذا الثابت يطرح فيما بعد من نموذج التكهّن.

٣- التخلص من الموسمية

لتجريد السلسلة من المركبة الموسمية تستخدم طريقة الفرق الموسمي Seasonal Differences وذلك بطرح القيم من بعضها البعض حسب فترات الإبطاء lags وهناك، على سبيل المثال:

$$- \text{الفرق ربع السنوي } Y_{1t} = X_t - X_{t-4}$$

$$- \text{الفرق الشهري } Y_{2t} = X_t - X_{t-12}$$

٢-٧ تحليل الارتباط الذاتي Autocorrelation Analysis

تستخدم دوال الارتباط الذاتي كمقياس للعلاقات الخطية بين السلاسل الزمنية، كما تستخدم في دراسة العلاقة بين حاضر السلسلة وماضيها. وكما هو معروف فان دالة الارتباط الذاتي Autocorrelation function تقيس درجة الارتباط بين المشاهدات المتسلسلة في السلسلة الزمنية، ولو كانت مشاهدات السلسلة الزمنية $\{x_t; t=1,2,\dots,n\}$ فان مقدّر دالة الارتباط الذاتي يمكن تقديره حسب المعادلة الآتية (Makridakis et al., 1998):

$$r_k = \frac{\sum_{t=k+1}^n (x_t - \bar{x})(x_{t-k} - \bar{x})}{\sum_{t=1}^n (x_t - \bar{x})^2} ; k=1,2,\dots,n-1. \quad (2.3)$$

حيث أن r_k يمثل الارتباط الذاتي بين X_t و X_{t-k} . ومن المعروف انه في حالة السلاسل الزمنية غير المترابطة فإن r_k يتوزع طبيعياً بمعدل صفر وتباين $\frac{1}{n}$. أي أن

$$E(r_k) = 0$$

$$\text{Var}(r_k) = \frac{1}{n}$$

٨-٢ الارتباط الذاتي الجزئي Partial Autocorrelation Function

إن دالة الارتباط الذاتي الجزئي ϕ_{kk} لفترة k تقيس الارتباط بين X_t و X_{t-k} بثبوت قيمة $\{X_t\}$ في بقية الفترات، وتعرف كما يأتي:

$$\phi_{kk} = \text{Cov}(X_t, X_{t+k} / X_{t-1}, \dots, X_{t+k-1}) \quad (2.4)$$

٩-٢ دالة كثافة الطيف Spectral Density Function

إن الدالة الطيفية لسلسلة زمنية مستقرة هي عبارة عن تحويل فوريير Fourier Transformation لدالة الارتباط الذاتي، ويستخدم تقدير دالة الطيف لوصف التوزيع بناءً على التكرار معتمداً على عدد محدد من المشاهدات. وبصورة عامة يمكن تمثيل السلسلة بدالة كثافة الطيف، وعلى النحو الآتي:

$$f(\omega) = \frac{1}{2\pi} \sum_{k=-\infty}^{\infty} \rho_k e^{-i\omega k} ; \quad -\pi \leq \omega \leq \pi \quad (2.5)$$

١٠-٢ النماذج الرياضية للسلاسل الزمنية Mathematical Models for Time Series

١٠-٢-١ نموذج الانحدار الذاتي Autoregressive Model

يقال للعملية التصادفية $\{X_t ; t=0, \pm 1, \pm 2, \dots\}$ بأنها عملية انحدار ذاتي برتبة p (Autoregressive Process of order p)، والذي يرمز له $AR(p)$ ، إذا حققت المعادلة الآتية:

$$X_t = a_1 X_{t-1} + a_2 X_{t-2} + \dots + a_p X_{t-p} + \varepsilon_t \quad (2.6)$$

حيث أن

Autoregressive parameters : a_1, \dots, a_p معالم الانحدار الذاتي

ε_t : الخطأ العشوائي عند الزمن t ، وهو عملية عشوائية مجردة (تشويش ابيض).

وباستخدام معامل الإزاحة الخلفي B والذي يعرف كما يأتي (Makridakis et al., 1998):

$$BX_t = X_{t-1}, B^2 X_t = X_{t-2}, \dots, B^p X_t = X_{t-p} \quad (2.7)$$

فيمكن إعادة كتابة المعادلة السابقة بالشكل الآتي:

$$(1 - a_1 B - a_2 B^2 - \dots - a_p B^p) X_t = \varepsilon_t \quad (2.8)$$

ومن خصائص هذا النموذج إذا كانت $\{X_t\}$ مرحلية (Chatfield, 1980):

$$1- \text{إن } E(X_t) = 0$$

$$2- \text{إن } \text{Var}(X_t) = \sigma_x^2 = \frac{\sigma_\varepsilon^2}{1 - a_1 - a_2 - \dots - a_p}$$

٣- إن دالة الارتباط الذاتي لعملية $AR(P)$ المعرفة في المعادلة (2.6) $\{\rho_k\}$ تحقق المعادلة الفرقية الآتية:

$$\rho_k = a_1 \rho_{k-1} + a_2 \rho_{k-2} + \dots + a_p \rho_{k-p}$$

وإن دالة الارتباط الذاتي $\{\rho_k\}$ تضمحل نحو الصفر بهبوط أو على شكل موجات جيبيية.

٤- إن دالة الارتباط الذاتي الجزئي تنقطع بشدة بعد فترة p والتي تحدد رتبة النموذج. كما أن هذه الدالة لهذا النموذج تتميز بأنها لاتساوي صفرًا للفترات $m=1, 2, \dots, p$ وتساوي صفر لقيمة $m > p$ (Box and Jenkins, 1976).

٥- أما دالة كثافة الطيف لنموذج الانحدار الذاتي فتكون كما يأتي (Priestley, 1981):

$$f(w) = \frac{\sigma_\varepsilon^2}{2\pi |1 + a_1 e^{-iw} + \dots + a_p e^{-ipw}|^2}, \quad -\pi \leq w \leq \pi$$

٢-١٠-٢ نموذج الأوساط المتحركة Moving Average Model

يقال للعملية التصادفية $\{X_t; t=0, \pm 1, \pm 2, \dots\}$ بأنها عملية أوساط متحركة برتبة q

(Moving Average of order q) ويرمز لها $MA(q)$ ، إذا كانت تحقق المعادلة الآتية:

$$X_t = \varepsilon_t + b_1 \varepsilon_{t-1} + b_2 \varepsilon_{t-2} + \dots + b_q \varepsilon_{t-q} \quad (2.9)$$

حيث أن

Moving average parameters : b_1, \dots, b_q معاملات الأوساط المتحركة

ε_t : الخطأ العشوائي.

ويمكن كتابة المعادلة باستخدام معامل الإزاحة الخلفي B بالشكل الآتي:

$$X_t = (1 + b_1 B + b_2 B^2 + \dots + b_q B^q) \varepsilon_t \quad (2.10)$$

(Makridakis et al., 1998)

ومن خصائص هذا النموذج إذا كانت $\{X_t\}$ مرحلية فان (Chatfield 1980):

$$-١ \text{ إن } E(X_t) = 0$$

$$-٢ \text{ إن } \text{Var}(X_t) = \sigma_x^2 = \sigma_\varepsilon^2 \sum_{k=0}^q b_k^2$$

-٣ إن دالة الارتباط الذاتي لهذا النموذج تكون كما يأتي:

$$\rho_k = \begin{cases} \frac{\sum_{s=k}^q b_s b_{s-k}}{\sum_{k=0}^q b_k^2} & ; k = 1, \dots, q \\ 1 & ; k = 0 \\ 0 & ; k > q \\ r_{-k} & ; k < 0 \end{cases}$$

وان دالة الارتباط الذاتي ρ_k تنقطع عند الصفر عندما تكون $k > q$ ، لذا فان اخر حد تنقطع عنده الدالة عند الصفر يحدد رتبة النموذج.

-٤ أما دالة كثافة الطيف لنموذج $MA(q)$ فهي كما يأتي (Priestley, 1981):

$$f(w) = \frac{\sigma_\varepsilon^2}{2\pi} \cdot |b_1 e^{-iw} + \dots + b_q e^{-iqw}|^2, \quad -\pi \leq w \leq \pi$$

إن دالة الارتباط الذاتي الجزئي (PAC) لهذه العملية تكون على شكل موجات جيبيية منخفضة وغير منتهية وهي تشبه دالة الارتباط الذاتي لنماذج AR(p)، وكحالة خاصة عندما q=1، أي أن النموذج MA(1)، فتكون دالة الارتباط الذاتي (Priestley, 1981) :

$$\rho_k = \begin{cases} 1 & ; k = 0 \\ \frac{b}{1+b^2} & ; k = \pm 1 \\ 0 & ; \text{Otherwise} \end{cases} \quad (2.11)$$

٢-10-٣ النماذج المختلطة انحدار ذاتي وأوساط متحركة

Autoregressive Moving Average Models (ARMA)

إن العناصر الأساسية لنموذج الانحدار الذاتي والأوساط المتحركة يمكن أن تدمج للحصول على تشكيلة من النماذج تسمى ذاتية الانحدار ذات أوساط متحركة برتبة p و q و ARMA(p,q) وتكون بالشكل الآتي:

$$X_t = a_1 X_{t-1} + \dots + a_p X_{t-p} + \varepsilon_t + b_1 \varepsilon_{t-1} + \dots + b_q \varepsilon_{t-q} \quad (2.12)$$

ويمكن كتابتها باستخدام عامل الإزاحة الخلفية

$$(1 - a_1 B - \dots - a_p B^p) X_t = (1 - b_1 B - \dots - b_q B^q) \varepsilon_t \quad (2.13)$$

وهذا النموذج يشترط المرحلية في المتوسط والتباين. أما إذا كانت السلسلة غير مرحلية فيستخدم عادة نماذج الانحدار الذاتي والأوساط المتحركة التكاملية Autoregressive Integrated Moving Average ARIMA(p,d,q) وتكون المعادلة في أبسط حالتها، ARIMA(1,1,1) بالشكل الآتي (Makridakis et al., 1998):

$$(1 - a_1 B)(1 - B) X_t = (1 - b_1 B) \varepsilon_t \quad (2.14)$$

$\uparrow \quad \uparrow \quad \uparrow$
 AR(1) الفرق الاول MA(1)

١١-٢ مراحل بناء نماذج السلاسل الزمنية

هناك ثلاث مراحل لبناء نموذج رياضي لسلسلة زمنية وذلك من خلال الخوارزمية التي وضعها Box-Jenkins في بناء السلاسل الزمنية والتي حددا فيها مراحل بناء النموذج بالمرحلة الآتية:

١- تحديد النموذج Model Identification

٢- تقدير النموذج Model Estimation

٣- تدقيق التشخيص Diagnostic- Checks

١-١١-٢ تحديد النموذج Model Identification

من أولى خطوات بناء نموذج Box-Jenkins هي تحديد مرحلة السلسلة من عدمه، وفي حالة المرحلة فهل هناك تغيرات موسمية؟ وبعد التأكد من مرحلة السلسلة تبدأ مرحلة تشخيص النموذج الملائم للبيانات ويتم ذلك من خلال دراسة دالة الارتباط الذاتي والارتباط الذاتي الجزئي عن طريق رسم هاتين الدالتين والتي تظهر بشكل اضمحلال تدريجي بطيء. والجدول (١-٢) يبين استخدام دالة الارتباط الذاتي في تحديد النموذج (Engineering Statistics Handbook, 2001).

الجدول (١-٢): تحديد نموذج السلاسل الزمنية من خلال شكل دالة الارتباط الذاتي.

شكل دالة الارتباط الذاتي	تحديد النموذج
أسي، يضمحل إلى الصفر	نموذج انحدار ذاتي، ويستخدم رسم دالة الارتباط الذاتي الجزئي لتحديد رتبة النموذج.
التعاقب بين الموجب والسالب والاضمحلال إلى الصفر	نموذج انحدار ذاتي، ويستخدم رسم دالة الارتباط الذاتي الجزئي لتحديد رتبة النموذج.
تقلطح واحد أو أكثر ، والباقي صفر	نموذج أوساط متحركة، تتحدد الرتبة حيثما يصل الرسم إلى الصفر.
اضمحلال، ثم بداية بعد فترات إبطاء قليلة	نموذج مختلط انحدار ذاتي وأوساط متحركة
الجميع صفر، أو تقترب من الصفر (تقع ٩٥% منها بين $\pm \frac{2}{\sqrt{n}}$)	البيانات عشوائية تماماً.
قيم عالية عند فترات محددة	يحتوي على ارتباط ذاتي موسمي.
لا يضمحل إلى الصفر	السلسلة غير مرحلية.

٢-١١-٢ تقدير النموذج Model Estimation

إن تقدير المعاملات لنموذج Box-Jenkins هي عملية معقدة وصعبة بعض الشيء خاصة مع السلاسل الزمنية غير الخطية. وتستخدم الطرائق الاتية لتقدير معاملات النموذج

- أ - معادلات Yule-Walker.
- ب- طريقة المربعات الصغرى.
- ج- طريقة الإمكان الأعظم.

٣-١١-٢ تدقيق التشخيص Diagnostic- Checks

يقصد بتدقيق التشخيص اختبار صحة النموذج واختبار حد الخطأ وان البواقي Residuals يجب أن تكون تشويشاً ابيضاً (مستقلة وتتبع التوزيع الطبيعي) ويُعدّ النموذج مناسباً إذا تحققت هذه الشروط، ولكن هذا ليس كافياً حيث يجب الحصول على نموذج أكثر تخصصاً، ويتوجب إعادة تشخيص النموذج ومحاولة الحصول على نموذج افضل. لذلك ظهرت الحاجة إلى استخدام معايير أخرى للتأكد من دقة النموذج ومنها معيار اكيائي للمعلومات Akaike's Information Criterion (AIC) (Chatfield, 1980).

٤-١١-٢ معيار اكيائي للمعلومات Akaike's Information Criterion

ظهرت في بداية السبعينات بعض المعايير لتشخيص النموذج المطلوب دون الاعتماد على دوال الارتباط، فقد اقترح العالم الياباني Akaike معياراً عاماً في تطوير ونمذجة السلاسل الزمنية يدعى (AIC) Akaike's Information Criterion ، ويستخدم هذا المعيار في تشخيص رتب نماذج السلاسل الزمنية، (العبيدي، ١٩٨٩). كما يمكن استخدامه في مجالات احصائية أخرى. وتحسب قيمة AIC كما يأتي:

$$AIC(k) = n \ln(\sigma_{\epsilon}^2) + 2k \quad (2.15)$$

حيث أن:

n: حجم العينة

σ_{ϵ}^2 : تباين البواقي Residuals Variance.

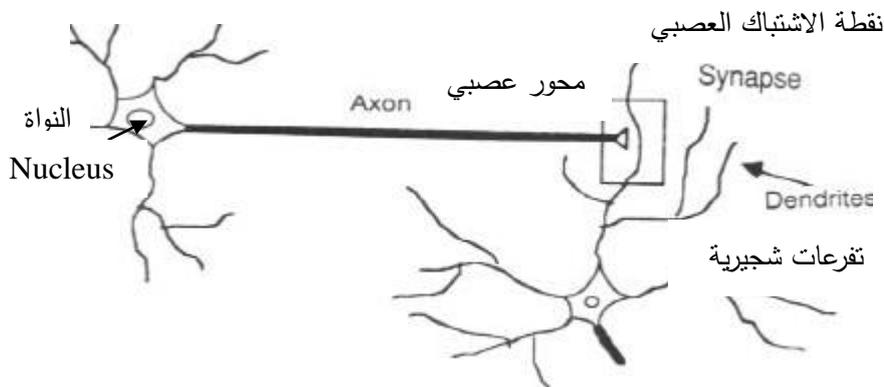
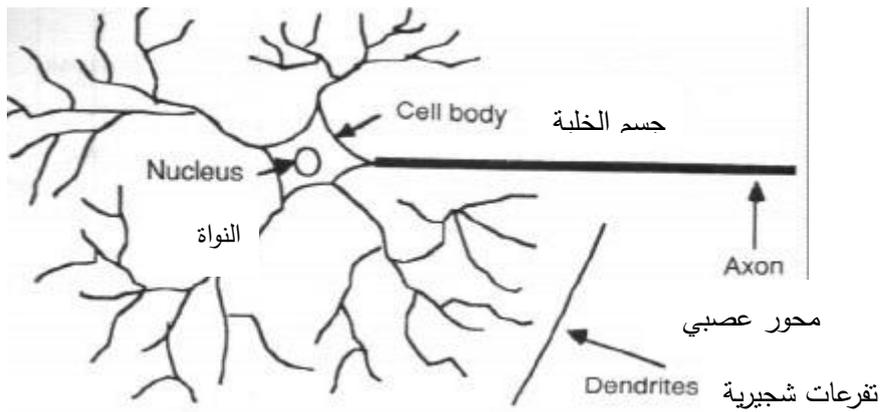
k: عدد معاملات النموذج المقدر.

١٢-٢ الشبكات العصبية الاصطناعية

Artificial Neural Networks (ANN)

تعني الشبكة العصبية في حقل تقنية المعلومات، نظام من البرامج وهياكل 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 تلقي 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 (الموسوعة العربية للانترنت، ٢٠٠٤).

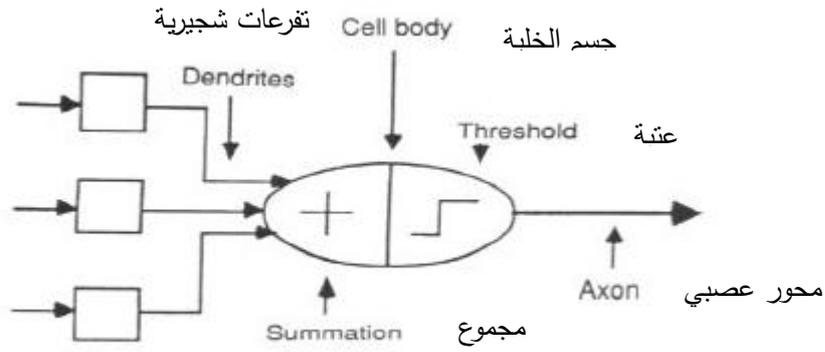
إن الشبكات العصبية تستند على نماذج رياضية بسيطة لها مميزات أداء معينة بأسلوب يحاكي الشبكات العصبية البيولوجية (النظام العصبي) مثل الدماغ، معالج المعلومات. والشكل (٤-٢) يوضح مخططاً بسيطاً للشبكة العصبية البيولوجية.



جسم الخلية

الشكل (٢-٤) : الشبكة البيولوجية Biological Networks.

إن المفتاح لنموذج الشبكة العصبية الاصطناعية هو الهيكل لنظام معالج المعلومات الذي يقوم بربط وتنظيم عدد كبير من عناصر المعالجة المرتبطة داخليا (العصبونات) والتي تعمل بانسجام لحل مسائل معينة، وتتمر الإشارات بين العقد (العصبونات) عبر خطوط ربط ويرفق كل خط بوزن معين، وتضرب الإشارات الداخلة إلى العقدة (العصبون) بهذه الأوزان، وتجمع المدخلات الموزونة في العقد أو العصبونات وبعد ذلك يتم معالجة مخرجات كل عقدة بواسطة دالة غير خطية ذات عتبة معينة (Threshold) تعرف بدالة التنشيط Activation Function. والشكل (٢-٥) يوضح شبكة عصبية اصطناعية بسيطة.



الشكل (٢-٥): الشبكة العصبية الاصطناعية Artificial Neural Network.

إن الشبكات العصبية أعطت حلولاً ذات كفاءة عالية للكثير من التطبيقات في العديد من المجالات منها:

- تمييز الأنماط والتعرف على الصور.
- القدرة على التعرف على الصور المشوهة.
- إكمال الصور التي فقدت جزء منها، مثل الصور المرسلّة بواسطة الأقمار الصناعية.
- عمليات التصنيف إلى عدد من الفئات.

مميزات نظم الشبكات العصبية (Stergiou and Siganos, 2001):

- ١- القدرة على تفسير البيانات المشوشة أو غير الكاملة.
- ٢- القدرة على مواجهة المشكلات ذات النوعيات الجديدة .
- ٣- المعالجة على التوازي.
- ٤- مرونة وسهولة صيانة النظام.

نواحي القصور في نظم الشبكات العصبية (Stergiou and Siganos, 2001):

- ١- الارتفاع الكبير في تكاليف تصميم و تشغيل و صيانة النظام .
- ٢- أن المعارف المنشودة قد لا تكون متوافرة دائما أو يصعب استخدامها .
- ٣- أن منهج حل المشكلة قد يختلف من خبير إلى آخر رغم صحته في الحالتين .
- ٤- احتمال تعارض القواعد الجديدة التي تضاف إلى القاعدة مع القواعد السابقة.
- ٥- أن بعض القواعد تفقد قيمتها عند وضعها في غير التطبيق الأصلي الذي نشأت في ظلها.

٢-١٢-١ الخلفية التاريخية للشبكات العصبية

إن أولى الشبكات العصبية الاصطناعية قدمت عام (١٩٤٣) من قبل الباحث في علم الوظائف العصبية Warren Mc. Culloch والباحث في علم المنطق Watter Pits ولكن التقنيات المتاحة في تلك الفترة لم تسمح لهما لعمل أشياء أكثر من ذلك. وفي عام (١٩٤٩) اكتشف العالم النفسي دونالد هيب اكتشافا كبيرا حيث قدم مبدأ عاما للتعلم بسيط جدا ولكنه للأسف غير معروف للكثيرين، حيث توصل إلى أن توصيلات إدخال المعلومات إلى الخلية العصبية متصلة بتوصيلات خروج البيانات من الخلايا العصبية الأخرى في الشبكة العصبية. وتقوم هذه الخلية بإرسال الإشارة التي تحفز الخلايا الأخرى عندما يتجاوز إجمالي المداخل قيمة الحد الأدنى، وتأخذ الإشارة التي ترسلها الخلية العصبية شكل انفجار عشوائي من النبضات، ويؤدي ذلك إلى سلوك معقد للشبكة برمتها، وهو سلوك معقد ومن الصعب تحليله. وحتى اليوم ما زلنا نحتاج إلى محاكاة شبكات صغيرة جدا لاكتشاف ما يمكن أن يكون عليه سلوكها.

إن أهم ميزة في المخ البشري، والتي لا تقتصر على كونها شبكات عصبية هائلة، هي التعلم. ويرى العالم هيب أن أي إدخال يكون نشطا عندما تتلقى الخلية العصبية إشارة من الخلايا

الأخرى حيث يقوى وتصبح الخلية أكثر حساسية لأي إشارات أخرى قادمة في المستقبل. وهذه العملية "التي لا يوجد تصور لكيفية حدوثها" هي التي تؤدي إلى حدوث عملية التعلم. ويمكن إرجاع كل قواعد تعلم الشبكات إلى قاعدة هيب أو شيء ما مرتبط بها.

وفي البدايات الأولى ثارت ضجة كبيرة عن أول شبكات عصبية بسيطة وعندما أُثبت أنها غير كافية لأداء المهام المطلوبة منها، ثارت ضجة أخرى وشكك الكثيرون في جدوى هذا الأسلوب. وكانت الشبكات العصبية الأولى بسيطة للغاية حيث كانت عبارة عن طبقة واحدة من الخلايا العصبية، وفي الواقع أن عملية التعلم حدثت في أغلب الحالات في خلية عصبية صناعية أطلق عليها الخلية المدركة (Perceptron)، وبالطبع هناك أشياء لا تستطيع أن تتعلمها الطبقة الواحدة من الخلايا العصبية. وكان من الصعب جدا أن تقوم بتوسيع الطبقات لتشمل عدة طبقات لعدم وجود وسيلة واضحة أو مفهوم محدد لكيفية التعامل مع هذه الطبقات لجعلها تتعلم أي شيء.

في بداية الثمانينات أُكتشفت خوارزمية يساعد الشبكات متعددة الطبقات على التعلم، وتجدد البحث في الموضوع مرة أخرى ويطلق على خوارزمية التعلم اسم منحني التعلم الكبير، وهو عبارة عن تطبيق لبعض طرق الامثلية القياسية Standard Optimization Methods. إن الفكرة الأساسية لهذه الخوارزمية بسيطة للغاية، فالخلية العصبية عبارة عن إشارات داخلية هي D_1, D_2 وكل إشارة يتم ضربها في الوزن W_1, W_2 وتكون النتيجة هي مجموع كل هذا، ويُعدّ الوزن العامل الذي يحدد حساسية الخلية العصبية لإشارة داخلية معينة، والإشارة الخارجة من الخلية عبارة عن الإجمالي الموزون للإشارات الداخلة وعادة ما يمثل هذا الإجمالي الحد الأدنى الذي ينتج إشارة خارجة في حالة زيادة إجمالي الإشارات الداخلة وتخطيها لهذا الحد الأدنى. وهذا يعني أن الخلية العصبية لا تطلق إشارة إلا في حالة وصول استثارة الإشارة الداخلة إلى مستوى عال جدا.

وفكرة هذه الخوارزمية هي الفكرة المستخدمة نفسها لتعديل أوزان الخلية العصبية الفردية أي تغيير الأوزان حتى تجعل النتائج تتحرك نحو القيمة المطلوبة، وفي حالة الشبكة العصبية لابد أن تحدد الأوزان وخلاياها العصبية وكذلك الأوزان التي ينبغي تعديلها. ويجب استخدام وظيفة تتيح لنتائج الخلية العصبية الانتقال بسلاسة من "عدم إطلاق إشارة" إلى "إطلاق إشارة"، ومن خلال جعل هذه الوظيفة تعمل على الانتقال المفاجئ من الحد الأدنى تحتفظ الخلية بخصائصها في التشغيل والإيقاف أو "الإطلاق وعدم الإطلاق"

وعندما تستخدم الخلية العصبية من هذا النوع يمكن تطبيق لوغاريتم التعلم بغض النظر عن تعقيد الشبكة أو سهولتها وذلك عبر الخطوات الآتية (الموسوعة العربية للكمبيوتر والانترنت، ٢٠٠٣):

- ١- تطبيق الناتج بالنتيجة المطلوبة (مخرجات البيانات).
- ٢- حساب ناتج الخلية العصبية وحساب الخطأ الحالي.
- ٣- نقل قيمة إجمالي الخطأ إلى كل خلية عصبية في الشبكة بالتناسب مع أوزانها الحالية، وتوصيل هذه الخلية بخلية الناتج .
- ٤- استخدام الخطأ المحدد لكل خلية عصبية في تدريبها بالطريقة المعتادة والتفاصيل الخاصة بهذه الإجراءات أو الخطوات معقدة جدا ، لأن مقدار الخطأ المنقول إلى كل خلية يعتمد على شكل وظيفة الحد الأدنى، وهذه هي الفكرة العامة في هذه الخطوات، ومن أكثر الأسماء شيوعاً التي تطلق على هذه العملية "التفاعل العكسي" لأن الأخطاء تعود من خلال الشبكة بالطريقة نفسها وعبر نفس الخطوات إلى الخلايا تماماً مثلما تتطور البيانات الداخلة وتتفاعل باتجاه الناتج أو البيانات الخارجة.

٢-١٢-٢ التعلم والتدريب Training and Learning

يمكن تعريف التعلم بأنه عملية ضبط الأوزان لجعل الخلية تطلق إشارة استجابة للأمثلة من مجموعة معينة. وكما هو معروف، فإن الشبكة العصبية هي عبارة عن مجموعة عصبونات Neurons واوزان 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 "تكييف الوزن" ويحدث خلال عملية تدعى "مرحلة التدريب". ومجموعة الإدخال الخارجي تدعى "مجموعة التدريب للشبكة" أو (عينة التدريب) ونموذج الإدخال المنفردة 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 التغير في الأوزان.

تتعلم الشبكة عن طريق إعطائها مجموعة من الأمثلة، التي يجب أن تكون مختارة بعناية، لأن ذلك سيساهم في سرعة تعلم الشبكة. وتنقسم طرق تعليم شبكة عصبية إلى قسمين حسب فئة التدريب التي تعرض على الشبكة. وهما:

- التعليم بواسطة معلم Supervised Learning:

في هذه الطريقة تحتاج الشبكات إلى مدرب ليعلم الشبكة بالمخرجات المرغوب بها Desired وتكون فئة التدريب عبارة عن زوجين من المتجهات، متجه المدخلات وهو عبارة عن القيم المدخلة للشبكة، ومتجه المخرجات وهو عبارة عن القيم التي يجب أن تخرجها الشبكة ومنها شبكة الانتشار العكسي للخطأ Backpropagation Network.

• التعليم بدون معلم Unsupervised learning:

في هذه الطريقة تتكيف الشبكة بسهولة في الاستجابة للمدخلات، وتتعلم أن تختار الهيكلية من المدخلات فقط وتكون فئة التدريب عبارة عن متجه المدخلات فقط (Smith, 2003).

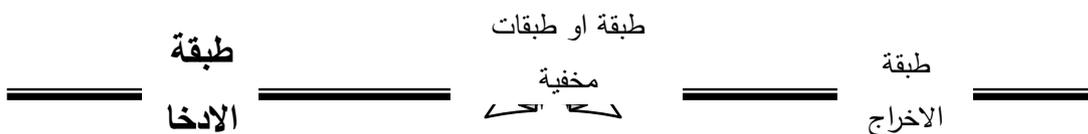
٢-٢١-٣ الشبكات العصبية ذات الانتشار العكسي

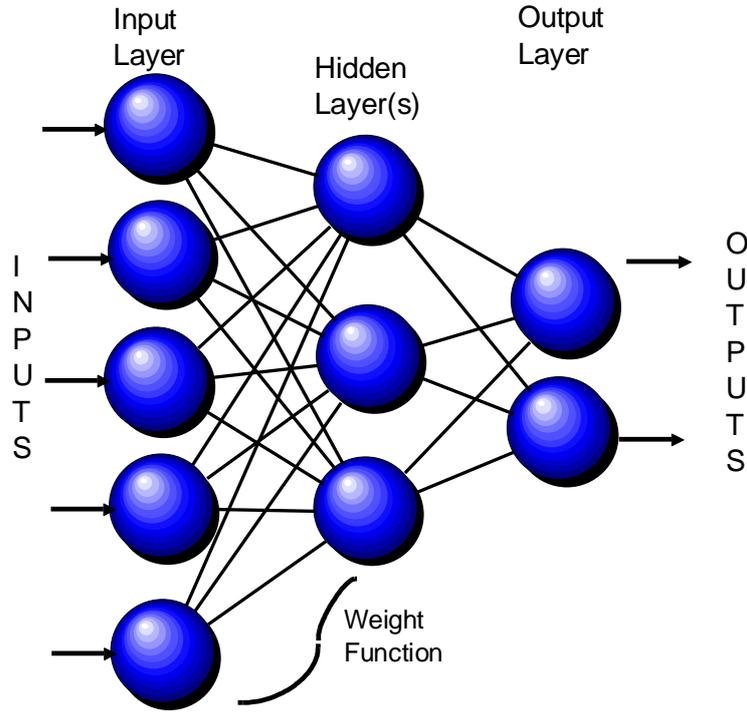
Backpropagation Neural Networks

إن شبكات التغذية الخلفية أو العكسية يمكنها أن تمتلك إشارات تتحرك أو تنتقل في كلا الاتجاهين بواسطة دارات Metroduding في الشبكة، إن شبكات التغذية العكسية قوية جدا وهي معقدة جدا، وهي شبكات حركية تتغير استقراريتها باستمرار إلى حين الوصول إلى نقطة التوازن، وتبقى في نقطة التوازن إلى أن يتغير الإدخال وعندئذ تحتاج إلى إيجاد توازن جديد (Stergiou and Siganos, 2001). والشكل (٦-٢) يوضح شكل الشبكة العصبية ذات

الانتشار العكسي Backpropagation Neural Network.

تستند الشبكة العصبية ذات الانتشار العكسي للخطأ على مفهوم تدريب الشبكة المعتمد على متوسط مربع الخطأ، وذلك بإيجاد القيمة الصغرى لمربع الخطأ الكلي لقيمة المخرجات المحسوبة من قبل الشبكة حيث تحدّث الأوزان بين الطبقات لحين الوصول إلى الأوزان المثلى التي تحدث افضل توفيق للنموذج (الناصر والعبيدي، ٢٠٠٣).





الشكل (٦-٢): الشبكة العصبية ذات الانتشار العكسي.

إن شبكة الانتشار العكسي للخطأ تستخدم التعلم بإشراف Supervised learning وهذا يعني تزويد الشبكة بمثال الإدخال والإخراج المطلوب حسابه، ويحسب الخطأ (الفرق بين القيم الحقيقية والمتوقعة). وفكرة شبكة الانتشار العكسي هو تقليل الخطأ، إلى أن تتعلم الشبكة عن طريق التدريب، ويبدأ التدريب بأوزان عشوائية بهدف تكييف الشبكة إلى أن يصل الخطأ إلى أقل ما يمكن (Gershenson, 1998).

٢-١٢-٤ خوارزمية الشبكة العصبية ذات الانتشار العكسي

إن خوارزمية شبكة الانتشار العكسي للخطأ من أهم خوارزميات شبكات التدريب بإشراف، واسمها مشتق من حقيقة أن الخطأ الناتج يرجع عكسياً خلال الشبكة من طبقة إلى أخرى. خوارزمية شبكة الانتشار العكسي للخطأ تعتمد على اختيار دالة خطأ مناسبة، والتي تتحدد قيمها بالنتائج الحقيقية Actual والقيم المطلوب الحصول عليها Desired والتي تعتمد أيضاً على معالم الشبكة مثل الأوزان والعتبة.

$$u = \sum_{i=1}^N w_i x_i \quad (2.16)$$

$$y = f(u - \theta) \quad (2.17)$$

حيث أن:

x_1, x_2, \dots, x_N تمثل المدخلات

w_1, w_2, \dots, w_N تمثل الأوزان

u : يمثل حساسية العصبون

θ : تمثل العتبة

y : تمثل مخرج الشبكة.

$f(\cdot)$: تمثل دالة الحساسية.

ويمكن إعادة صياغة المعادلتين السابقتين وذلك بجعل قيمة $w_0 = \theta$ و $x_0 = 1$ حيث ستكون

المعادلة:

$$\sum_{i=1}^N w_i x_i - \theta = \sum_{i=0}^N w_i x_i \quad (2.18)$$

و

$$y = f\left(\sum_{i=0}^N w_i x_i\right) \quad (2.19)$$

أما دالة التنشيط المستخدمة في شبكة الانتشار العكسي للخطأ فهي دالة Sigmoid والمعرفة

بالمعادلة (Ampazis, 1998):

$$f(u) = \frac{1}{1 + \exp(-au)} \quad (2.20)$$

حيث أن a هي معامل الميل slope parameter.

في خطوة الانتقال الأمامي Forward Pass للشبكة، متجه الإدخال $y^{(p)}$ وكل عصبون مخفي z يستقبل مدخلات الشبكة وحسب المعادلة الآتية:

$$x_j^{(p)} = \sum_k w_{jk} y_k^{(p)} \quad (2.21)$$

حيث w_{jk} يمثل الوزن بين العصبون المخفي z وعصبون الإدخال k . هذا العصبون z ينتج المخرجات حسب المعادلة الآتية:

$$y_j^{(p)} = f(x_j^{(p)}) = f\left(\sum_k w_{jk} y_k^{(p)}\right) \quad (2.22)$$

كل عصبون اخراج i يستلم

$$x_i^{(p)} = \sum_j w_{ij} y_j^{(p)} = \sum_j w_{ij} f\left(\sum_k w_{jk} y_k^{(p)}\right) \quad (2.23)$$

حيث أن w_{ij} يمثل الوزن بين عصبون الاخراج i والعصبون المخفي z . عليه فان الناتج النهائي يكون بالصيغة الآتية:

$$y_i^{(p)} = f(x_i^{(p)}) = f\left(\sum_j w_{ij} y_j^{(p)}\right) = f\left(\sum_j w_{ij} f\left(\sum_k w_{jk} y_k^{(p)}\right)\right) \quad (2.24)$$

إن خوارزمية الانتشار العكسي للخطأ يمكن أن تنفذ بطريقتين: on-line mode و batch mode ، في نموذج on-line فان دالة الخطأ تحسب بعد كل نموذج إدخال وإشارة الخطأ تبتث رجوعاً خلال الشبكة وتعديل الأوزان قبل تمثيل النموذج الآتي، ودالة الخطأ المحسوبة هي متوسط مربعات الخطأ Mean Square Error (MSE) بين القيم الحقيقية والقيم المرغوب بها، والأوزان الجديدة تستخدم في حساب النموذج الآتي، وتمثيل جميع النماذج يسمى التكرار Iteration.

أما نموذج Batch mode فان إشارة الخطأ يعاد حسابها لكل إدخال والأوزان تعدل وتُكَيَّف عندما يتم إدخال القيم جميعاً، ودالة الخطأ تحسب مجموع الخطأ MSE لكل الإشارات ولجميع النماذج قبل تمثيل النموذج الاتي، مما يعني أن هذا النموذج يقوم بحساب MSE لكل وحدات المخرجات i ولجميع النماذج p (Ampazis, 1998).

وتتضمن خوارزمية الشبكة على أربع خطوات:

١- حساب سرعة تغيير الخطأ عندما تتغير وحدة الاخراج وهذا الخطأ (EA) هو الفرق بين الاخراج الواقعي والإخراج المرغوب فيه (Stergiou and Signos, 2001)

$$EA_j = \frac{\partial E}{\partial y_j} = y_j - d_j \quad (2.25)$$

إن الخطأ E يحسب وفقاً للمعادلة الاتية:

$$E = \frac{1}{2} \sum_j (y_j - d_j)^2$$

حيث أن:

y_j : تمثل الطبقة النشطة من الوحدات j في الطبقة الأولى.

d_j : الاخراج المرغوب فيه من الطبقة j .

٢- حساب سرعة تغيير الخطأ عندما يستلم إدخال جديد ينتج من تغيير في وحدات الاخراج هذه الكمية (EI) هي ناتج الخطوة الأولى مضروبة في نسبة تغيير وحدة الاخراج عندما

تتغير وحدات الإدخال

$$EI_j = \frac{\partial E}{\partial x_j} = \frac{\partial E}{\partial y_j} * \frac{dy_j}{dx_j} = EA_j y_j (1 - y_j) \quad (2.26)$$

٣- حساب التغير في الأخطاء عندما يتغير وزن الربط عند التغير في وحدات الاخراج، هذه الكمية (EW) هي ناتج الخطوة الثانية مضروبة في مستوى الفعالية في الوحدة المرتبطة

$$EW_{ij} = \frac{\partial E}{\partial W_{ij}} = \frac{\partial E}{\partial x_j} * \frac{dx_j}{dW_{ij}} = EI_j y_i \quad (2.27)$$

٤- حساب التغير في الخطأ عندما تتغير فعالية الوحدة في المستوى السابق. هذه الخطوات تعطي إمكانية تطبيق شبكة الانتشار العكسي على أنها شبكة متعددة المستويات. فعندما تتغير فعالية الوحدة في المستوى السابق فإنها تؤثر على فعاليات جميع وحدات الاخراج التي تكون مرتبطة. لذلك فلحساب جميع التأثيرات على الخطأ تجمع هذه التأثيرات المنفصلة في وحدات الاخراج.

$$EA_j = \frac{\partial E}{\partial y_i} = \sum_j \frac{\partial E}{\partial x_j} * \frac{\partial x_j}{\partial y_i} = \sum_j EI_j W_{ij} \quad (2.28)$$

إن دالة التنشيط Activation Function للعصبونات في الشبكات العصبية تستخدم خوارزمية الانتشار العكسي وهو المجموع الموزون (مجموع الادخال مضروباً بالاوزان) وحسب المعادلة الآتية (Smith, 2003):

$$X_j = \sum_i y_i W_{ij}$$

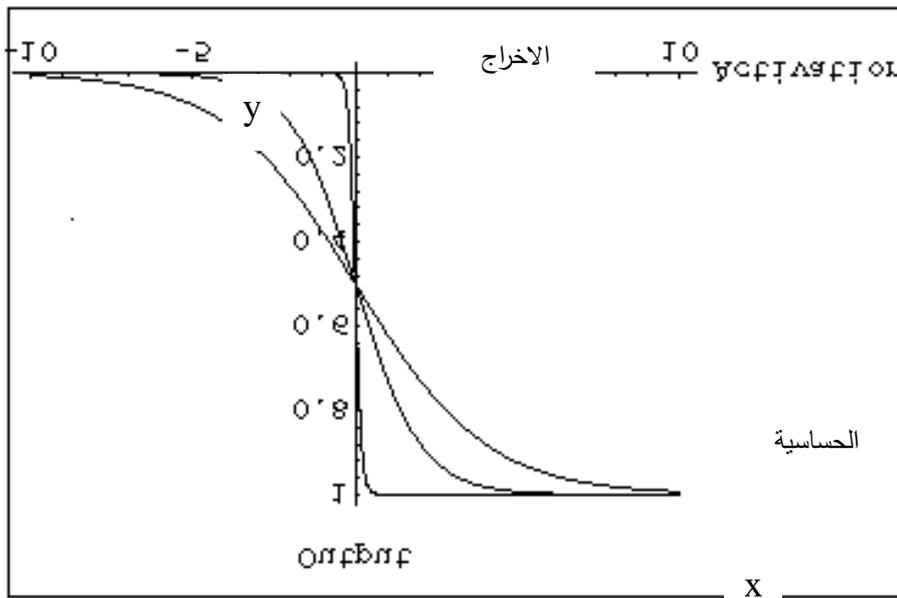
حيث أن:

y_i : مستوى الفعالية للوحدة j في الطبقة السابقة.

W_{ij} : وزن الارتباط بين العصبون i و العصبون j .

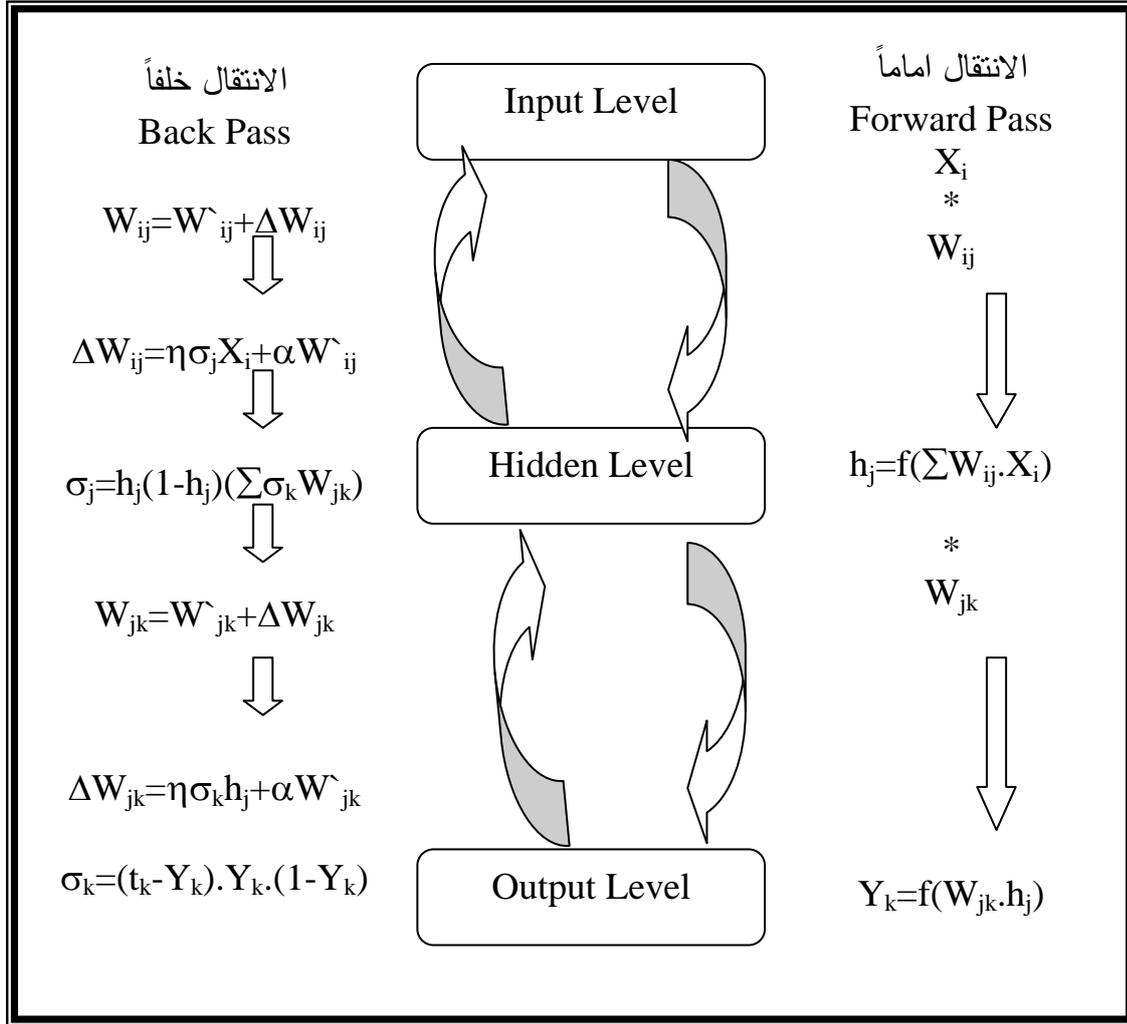
ويتبين من المعادلة إن التنشيط يعتمد على الأوزان والإدخال فإذا كانت دالة الاخراج identity أي (الاجراج = الحساسية) عندئذ يسمى العصبون خطي Linear ولكن مثل هذه الحالة لا تتحقق إلا بشروط صارمة. أما دالة الاخراج الشائعة الاستخدام بصورة واسعة هي دالة Sigmoid والتي تعطي انتقال سهل Smooth transition بين اقل واعلى قيمة للاخراج في العصبون، والشكل (٧-٢) يوضح دالة Sigmoid. وتحسب الدالة حسب المعادلة الآتية:

$$y_j = \frac{1}{1 + e^{-x_j}}$$



الشكل (٧-٢): دالة Sigmoid.

والشكل (٨-٢) يوضح عملية حساب تغير الوزن في الشبكة العصبية.



الشكل (٨-٢) : خوارزمية شبكة الانتشار العكسي للخطأ.

حيث أن:

X_i : مدخلات الشبكة

W_{ij} : أوزان مستوى المدخلات إلى المستوى المخفي.

h_j : مخرجات المستوى المخفي.

Y_k : مخرجات الشبكة العصبية.

ΔW_{ij} : التغير في وزن مستوى المدخلات إلى المستوى المخفي.

ΔW_{jk} : التغير في وزن المستوى المخفي إلى مستوى المخرجات.

\hat{W}_{jk} : التغير السابق في وزن المستوى المخفي إلى مستويات المخرجات.

t_k : قيمة المخرجات للوزن السابق.

η : معدل التعلم σ : مشتقة الخطأ α : الزخم (الشيخلي، ٢٠٠٣)

٢-١٣ علاقة الشبكات العصبية بعلم الإحصاء

بدأت في الآونة الأخيرة اهتمامات الباحثين في استخدام أساليب الشبكات العصبية في المعالجات الإحصائية، وبغية توضيح العلاقة بين الشبكات العصبية وعلم الإحصاء فقد تم إعداد الجدول (٢-٢) الآتي والذي يوضح مصطلحات الشبكات العصبية وما يقابلها في علم الإحصاء (Sandy et al., 2003).

الجدول (٢-٢) : بعض المصطلحات الأساسية في الشبكات العصبية وما يقابلها في علم الإحصاء.

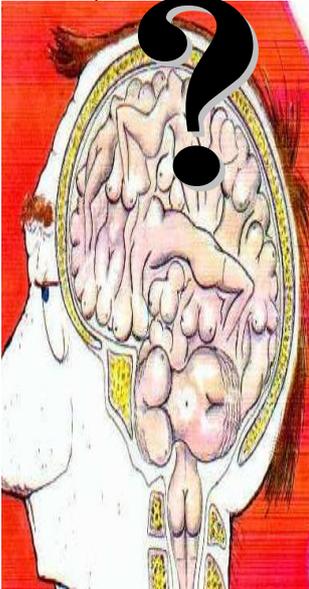
المصطلح في علم الإحصاء	مصطلح الشبكات العصبية
a class of flexible nonlinear regression and discriminant models, data reduction models, and nonlinear dynamical systems consisting of an often large number of neurons interconnected in often complex ways and often organized into layers صنف من نماذج الانحدار غير الخطي المرن ونماذج تمييز وتقليص بيانات، ونظم ديناميكية غير خطية مؤلفة من عدد كبير من العصبونات متصلة داخليا بطرق معقدة ومنظمة على شكل طبقات.	Neural networks الشبكة العصبية
a simple linear or nonlinear computing element that accepts one or more inputs, computes a function. هي عبارة عن عناصر الحساب الخطي البسيط أو اللاخطي والتي تقبل مدخل واحد أو أكثر، وتحسب دالة مباشرة.	Neuron, unit, node, processing element عصبون، عقدة، عنصر العملية
Computation of derivatives for a multilayer perceptron حساب المشتقات الطبقات متعددة ومدركة	Back propagation الانتشار العكسي
Dependent variables, Responses المتغيرات المعتمدة، المتغيرات المستجيبة	Training values قيم التدريب
Error term الخطأ	Noise التشويش

المصطلح في علم الإحصاء	مصطلح الشبكات العصبية
Estimation التقدير	Training التدريب
Hold-out sample عينة الاختبار	Validation set مجموعة شرعية
Independent variables, Explanatory variables المتغيرات المستقلة، المتغيرات المفسرة	Inputs المدخلات
Linear regression انحدار خطي	Statistical methods الطرائق الإحصائية
Model نموذج	Architecture Network معمارية الشبكة
Model fitting النموذج الملائم	Learning التعلم
Observation المشاهدات	Pattern, Vector, Example, Case نمط، متجه، مثال، حالة
Observed values القيم المشاهدة	Target values قيم الهدف
Optimization امتلية	Adaptation التكيف
Polynomial regression, Linear model with interaction terms. انحدار متعدد الحدود، نموذج خطي يتضمن حدود تفاعل.	Higher-order network شبكة من الدرجات العليا
Predicted values القيم المتنبأ بها	Outputs المخرجات
Prediction التنبؤ	Forward propagation الانتشار الأمامي
Quadratic regression الانحدار من الدرجة الثانية	Second-order network شبكة من الدرجة الثانية
Regression approximation الانحدار التقريبي	Mapping, Function دالة خارطة
Regression coefficients معاملات الانحدار	Weights الأوزان
Residuals البواقي	Errors الأخطاء
Sample عينة	Training set مجموعة التدريب

الفصل الثالث

التكهن

FORECASTING



١-٣ مقدمة.

٢-٣ اساليب التكهن.

٣-٣ التكهن بتقنيات بوكس-جينكنز.

٤-٣ منهجية بوكس-جينكنز في التكهن

٥-٣ التكهن باستخدام الشبكات العصبية

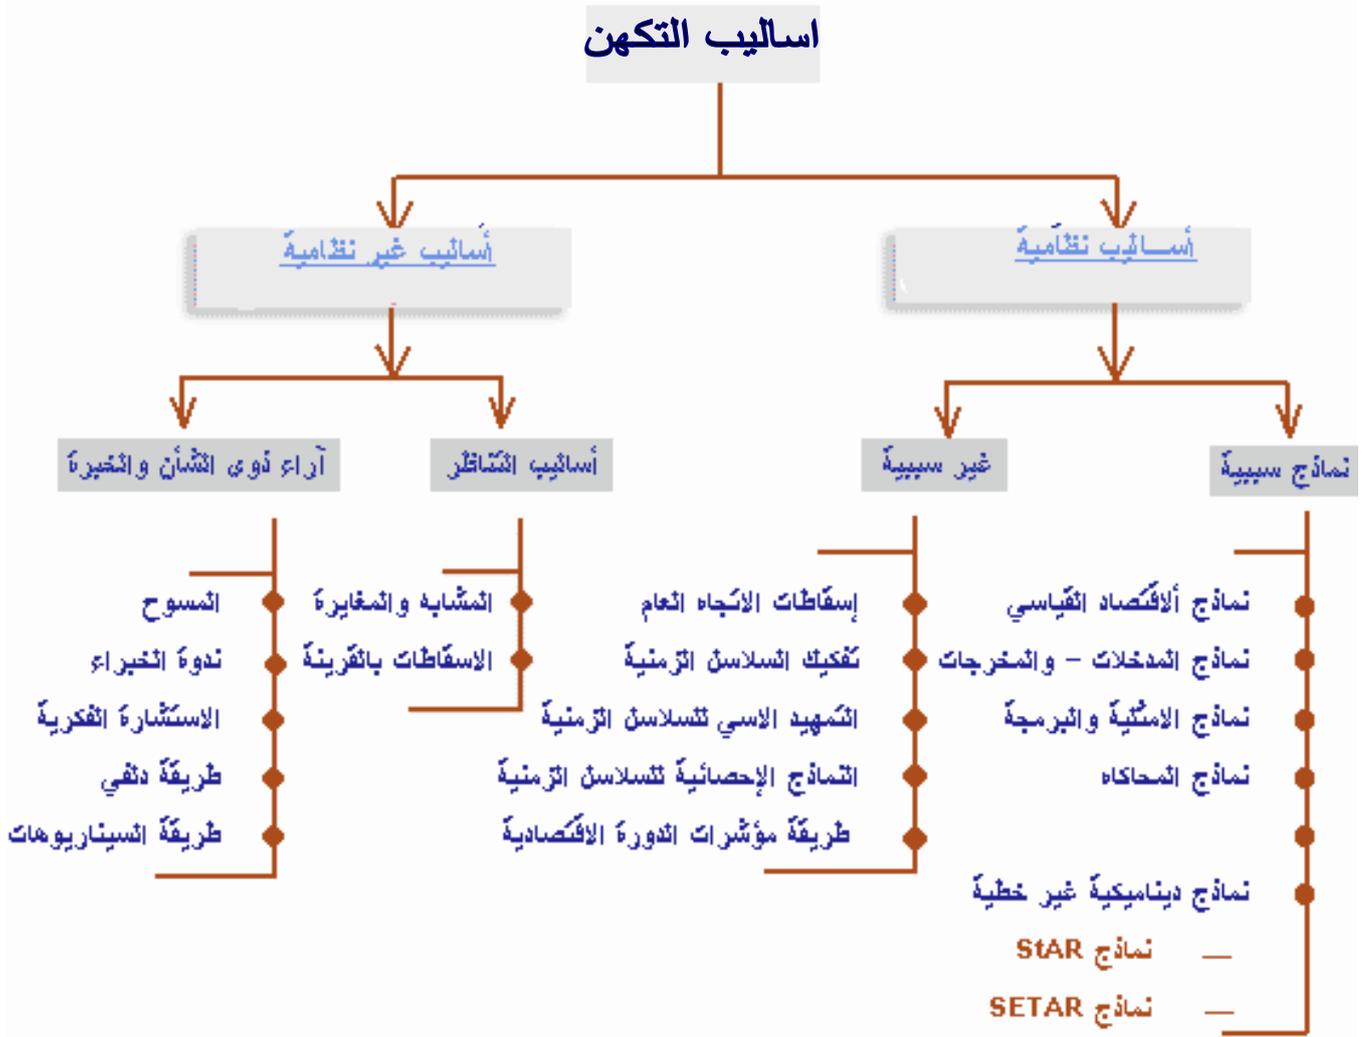
٦-٣ العوامل المؤثرة على كفاءة الشبكة العصبية الاصطناعية.

٣-١ مقدمة

تعد عملية التكهّن بالقيم المستقبلية من الاهداف الاساسية للعلوم الاحصائية، حيث ان للتكهّن اهمية كبيرة في عملية التخطيط واتخاذ القرارات في المجالات كافة، وعن طريق التكهّن نستطيع التعرف على الظروف والحالة المحيطة بالمشكلة قيد الدراسة قبل اتخاذ أي قرار، لذلك فان موضوع التكهّن لاقى ويلاقي اهتماماً كبيراً ومنتزاهاً من قبل الباحثين واصحاب القرارات. لقد اهتم الباحثون بتطوير الاساليب المختلفة لغرض اجراء التكهّن، ويعد التكهّن باستخدام الشبكات العصبية Neural Networks من احدث وسائل التكهّن على النطاق العالمي، حيث لازالت البحوث مستمرة في هذا المجال للتعرف على فعالية هذا الاسلوب. ويمكن القول أن الغاية الأساسية من طرائق السلاسل الزمنية تتمثل بالحصول على نماذج يمكن استعمالها لوصف المشكلة وبالنتيجة التكهّن بمستقبل الظاهرة المدروسة. أن مسألة التكهّن تعتمد أساساً على تقديرات معلمات النموذج الملائم لبيانات السلسلة الزمنية، ولمعرفة شكل النموذج الملائم أهمية خاصة باعتبار أن أي خطأ في تحديد نموذج يقود إلى تقديرات في غير محلها، ومن ثم تكهنات لا يعتمد عليها عند اتخاذ القرار. أن تحديد النموذج يعتمد هو الآخر على رتبة النموذج المختار كأن يكون نموذج الانحدار الذاتي (AR) من رتبة (p) أو نموذج المتوسطات المتحركة (MA) من الرتبة (q) ، أو أن يكون النموذج مختلطاً (ARMA) من الرتبة (p,q) (عبد وحسن، ٢٠٠٣).

٣-٢ اساليب التكهّن

تتقسم اساليب التكهّن تبعاً للمنهجية المعتمدة الى قسمين رئيسيين: الاول هو الاساليب غير النظامية، اما القسم الثاني فهو الاساليب النظامية، والمخطط الاتي يوضح الاساليب المستخدمة في التكهّن (حامد، ٢٠٠٣) :



الشكل (٣-١): اساليب التكهّن.

تعتمد على طرائق علمية لتفسير اية ظاهرة وتستند الى معالجة جميع المتغيرات المؤثرة من خلال نماذج رياضية قابلة للتقدير، وتكون نتائج التكهّنات بعيدة عن التاثر بالعوامل الذاتية. وتتقسم النماذج الرياضية للاساليب النظامية الى مجموعتين (حامد، ٢٠٠٣):

اولاً : نماذج سببية Causal Models

يعتمد المتغير موضوع البحث على متغيرات تفسيرية توضح سلوكه، ومحاولة التكهّن التي تعتمد على بيانات سلسلة يعتقد بانها سبب سلوك السلسلة الاصلية، ويتم صياغة العلاقة على شكل نموذج رياضي لغرض تقدير معلمات النموذج للتكهّن. ومن أهم النماذج السببية:

١- نماذج الاقتصاد القياسي

تتطلب هذه النماذج:

- تحديد النظرية الاقتصادية الخاصة بموضوع البحث.
- صياغة النموذج رياضياً.
- جمع البيانات الخاصة بمتغيرات النموذج.
- تقدير النموذج.
- اختبار النموذج.
- استخدام النموذج في التكهّن.

٢- نماذج المدخلات – والمخرجات Input-Output Models

تمثل العلاقة التبادلية بين مختلف السلاسل على شكل جداول مدخلات ومخرجات في فترة زمنية معينة (سنة)، من خلال توضيح مدخلات كل سلسلة، وتستخدم نماذج المدخلات والمخرجات في عملية التكهّن.

٣- نماذج الأمثلية والبرمجة الخطية

Optimization and Linear Programming Models

تُعَدُّ البرمجة الخطية من أهم نماذج الأمثلية، وتهتم بطريقة استخدام الموارد المتاحة في وصف العلاقة بين متغيرين أو أكثر من خلال تعظيم أو تصغير دالة



الهدف والتي تحتوي على متغيرات هيكلية يتم تحديد مستوياتها بشكل يحقق أكبر (أصغر) قيمة لدالة الهدف.

٤ - نماذج المحاكاة Simulation Models

لتفادي أية مشكلة قد تواجه الباحث عند إجراء التجارب على أي نظام حقيقي، يستخدم لذلك نماذج المحاكاة، وهي نماذج رياضية تمثل وتعكس جميع خصائص وسلوك النظام الحقيقي للتعرف على الآثار المحتملة لقرارات وسياسات إقتصادية معينة قد تؤثر على المسار المستقبلي لبعض المتغيرات، وكما تستخدم في المفاضلة بين عدد من السياسات الاقتصادية التي تحقق الهدف المنشود.

٥ - نماذج ديناميكية غير خطية Non-linear Dynamical Models

تم التركيز في السنوات الأخيرة على أنواع جديدة من النماذج الحتمية غير الخطية، حيث أتضح أنها قادرة على توصيف سلوك عدد كبير من السلاسل الزمنية التي لا تقدر النماذج التقليدية على توصيفها، ومن تلك النماذج نماذج الفوضى والكارثة (Chaos , Anarchy Models).

ثانياً : نماذج غير سببية Non-Causal Models

تعتمد تلك النماذج على القيم التاريخية للمتغير المراد التكهّن بقيمته المستقبلية ولا تحتاج إلى تحديد المتغيرات التي تفسر سلوكه. وهناك العديد من النماذج وان كان ابرزها واكثرها شيوعاً خاصة في التكهّنات طويلة المدى، هو نموذج إسقاط الاتجاه العام لسلسلة زمنية. ومن النماذج الاخرى المهمة:

١ - النماذج الإحصائية للسلاسل الزمنية

٢ - إسقاطات الاتجاه العام

٣-٢-٢ الاساليب غير النظامية

تعتمد على التقدير الذاتي، ولا تحتاج إلى قاعدة أو تحديد المتغيرات التي تفسر سلوك المتغير موضوع الاهتمام، إنما تعتمد على الخبرة والتقدير الشخصي. وتنقسم الى مجموعتين (حامد، ٢٠٠٣):

١ - أساليب التناظر والمقارنه :

يتم التكهّن بمسار متغير باستخدام المسار المحتمل لنفس المتغيرات في حالات متشابهة، مثل التعرف على أثر تخفيض عملة على التضخم ، وذلك من خلال التعرف على أثر تخفيض العملة لقطر مشابه جدا لاقتصاد البلد.

٢ - الأساليب المعتمده على آراء ذوي الشأن والخبرة

وتنقسم تلك النماذج إلى:

أ. المسوحات والإستقصاء: تهدف إلى التعرف على رأي ذوي الشأن والخبرة وتوقعاتهم في بعض الأنشطة الاقتصادية لغرض التكهّن ببعض المؤشرات الاقتصادية، مثال : التكهّنات باتجاهات السوق ومعدلات التضخم. تتم من خلال استطلاع عينة من المعنيين بذلك باستخدام استبيان خصص لذلك يوزع ويجمع إما عن طريق المراسلة أو بتكليف فريق عمل يقوم بجمع المعلومات الخاصة بالإستطلاع.

ب. ندوة الخبراء: تتمثل في إجراء حوار بين عدد من الخبراء والمفكرين لتبادل الأفكار في المواضيع الاقتصادية التي تُهم المجتمع بالدرجة الأولى وتقديم حلول لجميع المشكلات القائمة، وقد تؤدي هذه الطريقة إلى تصور محدد بشأن المستقبل.

ت. طريقة دلفي: من الطرق الشائعة في الولايات المتحدة واليابان ، والأساس في تلك الطريقة هو الاعتماد على رأي عدد من الخبراء تم جمعهم بدقة والمزج والتنسيق بين آرائهم بشأن تكهناتهم لموضوعات البحث ثم التوصل لرأي واحد لجميع القضايا المطروحة.

ث. طريقة السيناريوهات: السيناريو عبارة عن وصف أو سرد لمجموعة من الأحداث والتصرفات المحتملة وقوعها في المستقبل ووصف للقوى المؤدية إلى وقوعها، ويعد هذا الوصف بناء على ترتيب منطقي لتسلسل الأحداث، ومحاولة تحديد جميع الروابط القائمة بينها، بإعتبار أن هذه الأحداث لا تقع منعزلة عن بعضها البعض، وأنها ترتبط من خلال عملية ديناميكية ، أي أن السيناريو يتكون من عنصرين : الأحداث والتصرفات.

٣-٣ التكهّن بتقنيات بوكس-جينكنز:

Box - Jenkins Forecasting Techniques

إن الفكرة الأساسية للتكهّن بالسلسلة الزمنية هي إيجاد الصيغة الرياضية التي تولد سلسلة زمنية مثلى تقريباً حسب الصيغة السابقة لها (التاريخية Historical)، وهناك طريقتان أساسيتان للتكهّن للسلاسل الزمنية حسب تقنيات بوكس-جينكنز هما: الخطة الذاتية (Self-Projecting on Time Series) للسلسلة الزمنية التي تستخدم فقط بيانات السلاسل الزمنية الفعالة في مجال التكهّن لغرض توليد بيانات متكهّن بها. أمّا التقنية الثانية فهي طريقة السبب والتأثير (Cause-and-Effect Approach) المستخدمة اعتماداً على بيانات السلاسل المعتمد بأنها سبب في سلوك السلسلة الأصلية. علماً أن الطريقة الأولى تُعد من ابرز سمات طريقة التكهّن لبوكس-جينكنز، حيث أن الهدف الأساس لها هو إيجاد صيغة مناسبة للتكهّن بحيث تجعل البواقي (Residuals) اقل ما يمكن (الطائي، ٢٠٠٣).

٤-٣ منهجية طريقة بوكس-جنكنز في التكهّن

Box-Jenkins forecasting methodology

هناك أربع خطوات لا بد من إتباعها قبل البدء في استخدام نماذج بوكس-جنكنز في التكهّن وهي كما يأتي:

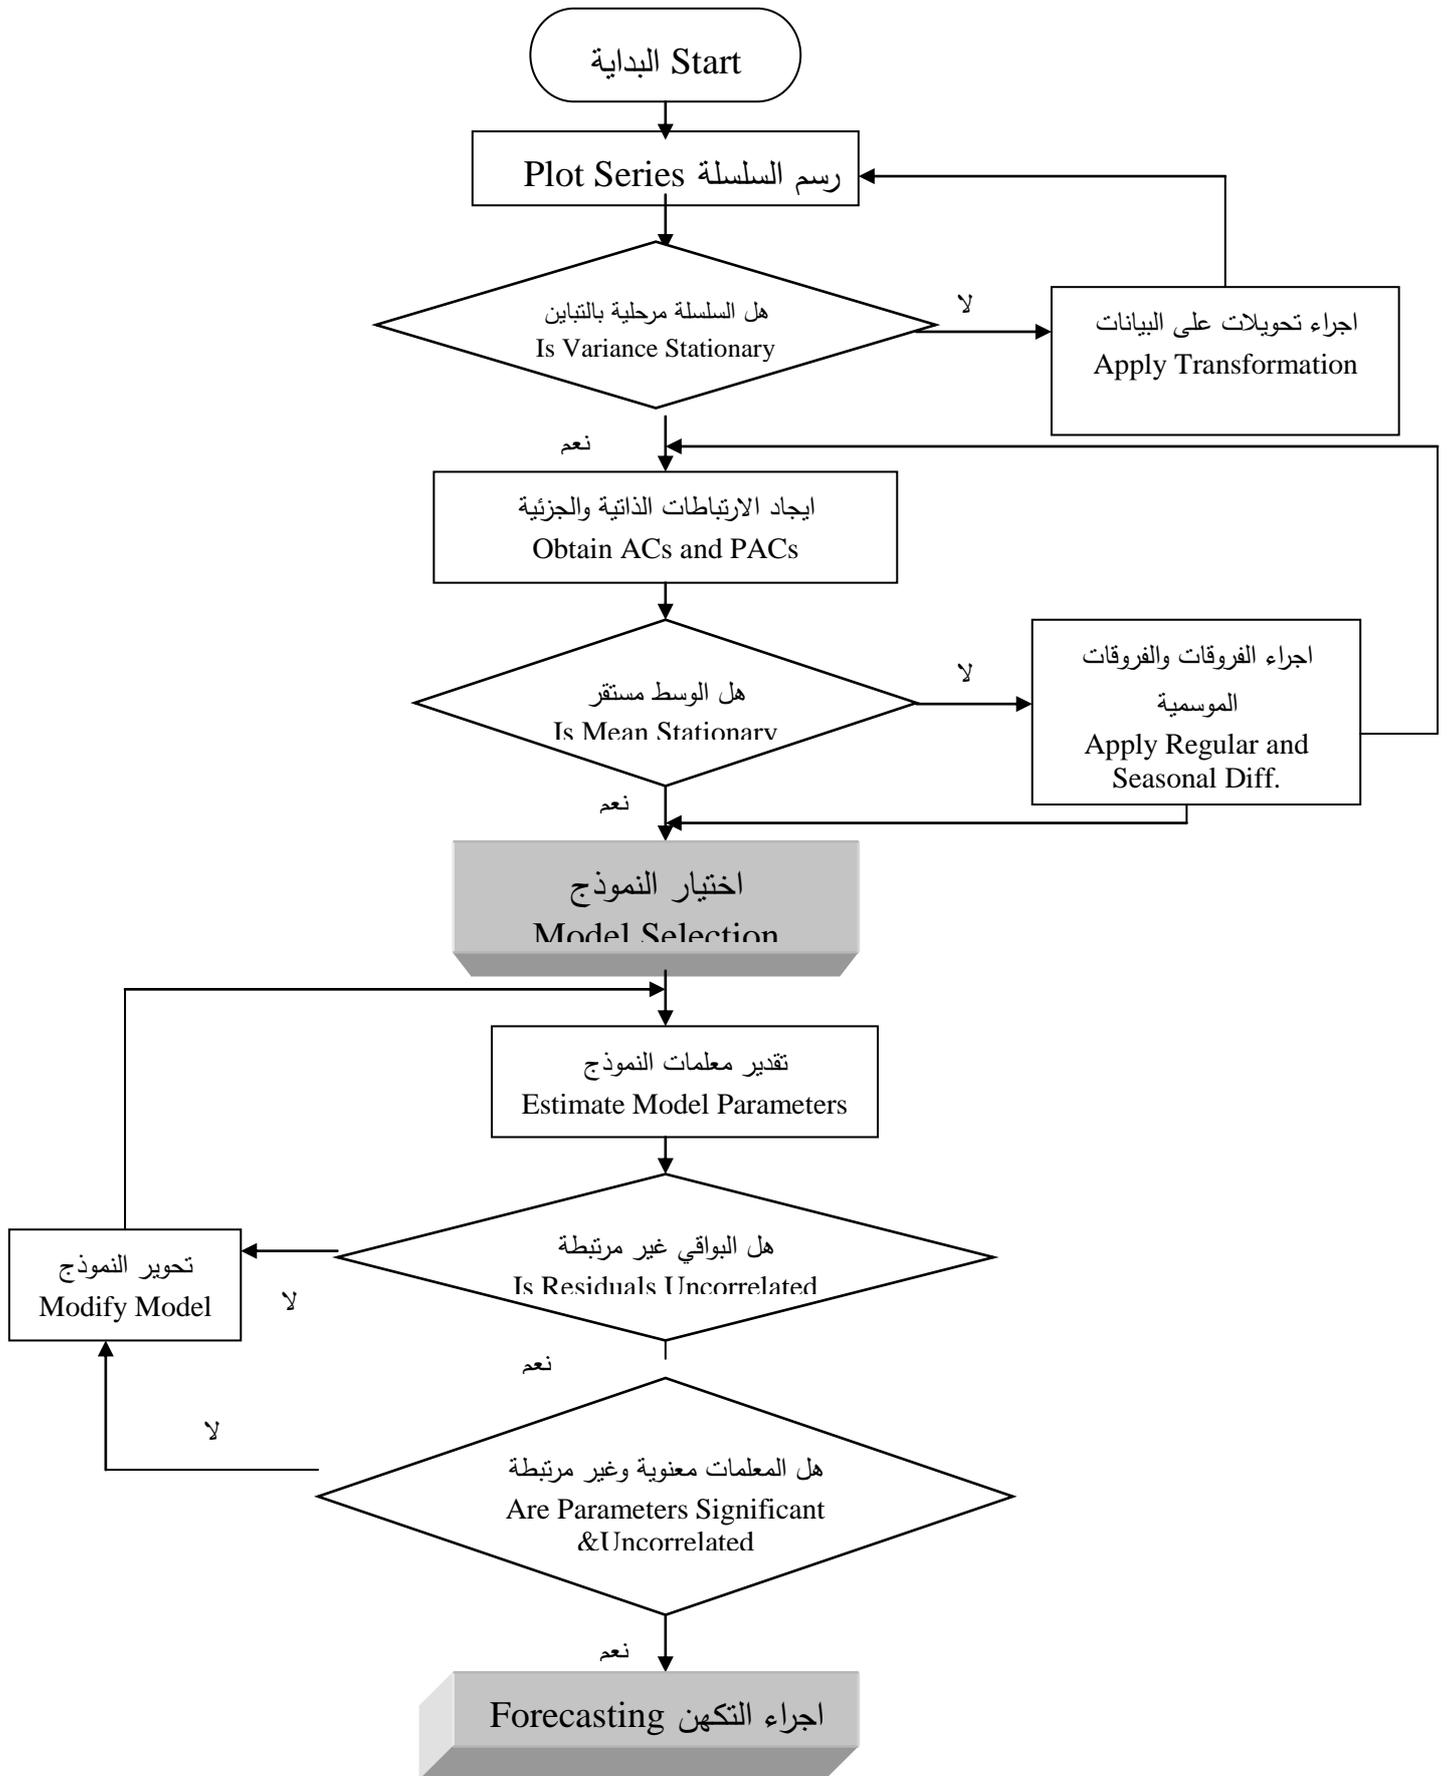
١. التأكّد من مرحلة السلسلة، والقيام بإجراء الفروقات عندما تكون السلسلة غير مرحلية.

٢. تمييز النموذج، هو تحديد الرتب لنماذج الانحدار الذاتي والمتوسط المتحرك ، وذلك باستخدام دالة الارتباط الذاتي ACF ودالة الارتباط الذاتي الجزئي PACF او اية طريقة اخرى.

٣. تقدير معالم النموذج والتأكّد من معنويتها إحصائياً.

٤. التأكّد من أن النموذج مناسباً ويمكن الاعتماد عليه في التكهّن.

ويوضح المخطط الآتي في الشكل (٣-٢) المراحل الأساسية للنمذجة وفق أسلوب بوكس-جينكنز والتي من ثمارها إجراء التكهّن (العبيدي، ١٩٨٩).



الشكل (٣-٢) : مراحل النمذجة وفق اسلوب بوكس-جينكنز.

٣-٥ التكهن باستخدام الشبكات العصبية

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

الخطوة الأولى: اختيار المتغيرات Variables Selection

حيث 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 تقدير مهارة الشبكة الافتراضية وامكانية استخدامها بصورة عامة.

مجموعة الشرعية **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 للدخال والذي يساوي عدد المتغيرات المستقلة.
- عدد الطبقات المخفية والذي يعتمد على قيمة الخطأ المستخدم في الشبكة.
- عدد العصبونات المخفية والذي يحدد عن طريق التجربة.
- عصبون الاخراج والذي عادة يساوي واحد.

الخطوة الخامسة: دالة التحويل **Transfer function**

الصيغة الرياضية لتحديد الاخراج والتي تمنع الاخراج من الوصول الى قيمة عالية جدا وتستخدم احدى الصيغ او الدوال الاتية :

- Linear
- Threshold
- Sigmoid

الخطوة السادسة: معيار التقييم **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: ايجاد مجموعة الاوزان بين العصبونات والتي تحدد اقل قيمة لمربع الخطأ.
- الخوارزمية: شبكة الانتشار الخلفي للخطأ تستخدم خوارزمية تدريب انحدار (تقليل) الميل.

الخطوة الثامنة: التنفيذ **Implementation**

وهي من اهم الخطوات، حيث تختبر الشبكة من حيث قدرة التكيف مع حالة التغير في الدورة وامكانية اعادة التدريب والوصول الى اقل مربع خطأ عند تغير البيانات.

Artificial Neural Network Performance Factors

ان جودة التكهّنات المستقبلية لظاهرة معينة التي يمكن الحصول عليها من الشبكة العصبية تعتمد على مدى كفاءة تدريب الشبكة العصبية ومن تلك العوامل (الشخلى، ٢٠٠٣):

١- عامل معدل التعلم (Learning Rate η)

يُعد معدل التعلم من العوامل المؤثرة على عملية تحديث الاوزان في الشبكة العصبية حيث معدل التعلم يحدد حجم الخطوة في عملية تعلم الشبكة العصبية ومقدار تغير الوزن.

٢- عامل العزم (Momentum α)

هو من العوامل المهمة الذي يجعل عملية التعلم متزنة ويجعل مقدار التغير في الوزن متزنا ومستقر نسبيا.

٣- عامل عدد المتجهات في الشبكة العصبية

Number of Exemplars in Neural Network

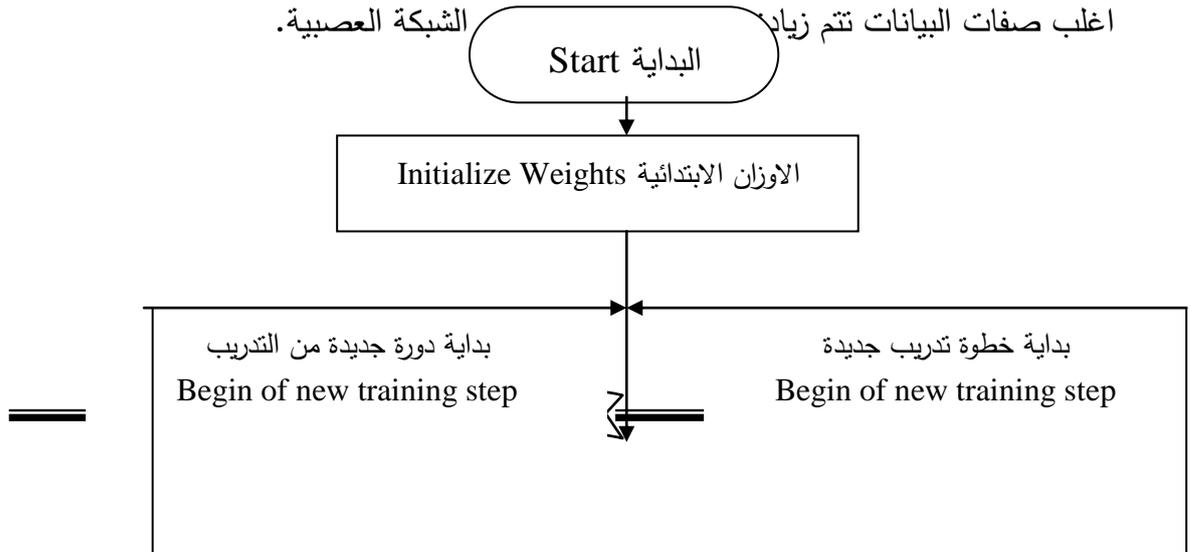
ان عدد المتجهات (Exemplars) يؤثر على اداء الشبكة بشكل مباشر، وذلك لانه يمثل المتغيرات المستقلة، فاذا كان عدد المتجهات مناسباً فان الشبكة العصبية بإمكانها استخلاص نموذج يمثل البيانات، اما اذا كانت مدخلات الشبكة على درجة من التعقيد فيجب زيادة عدد المتجهات لكي تتعلم الشبكة على سلوك البيانات.

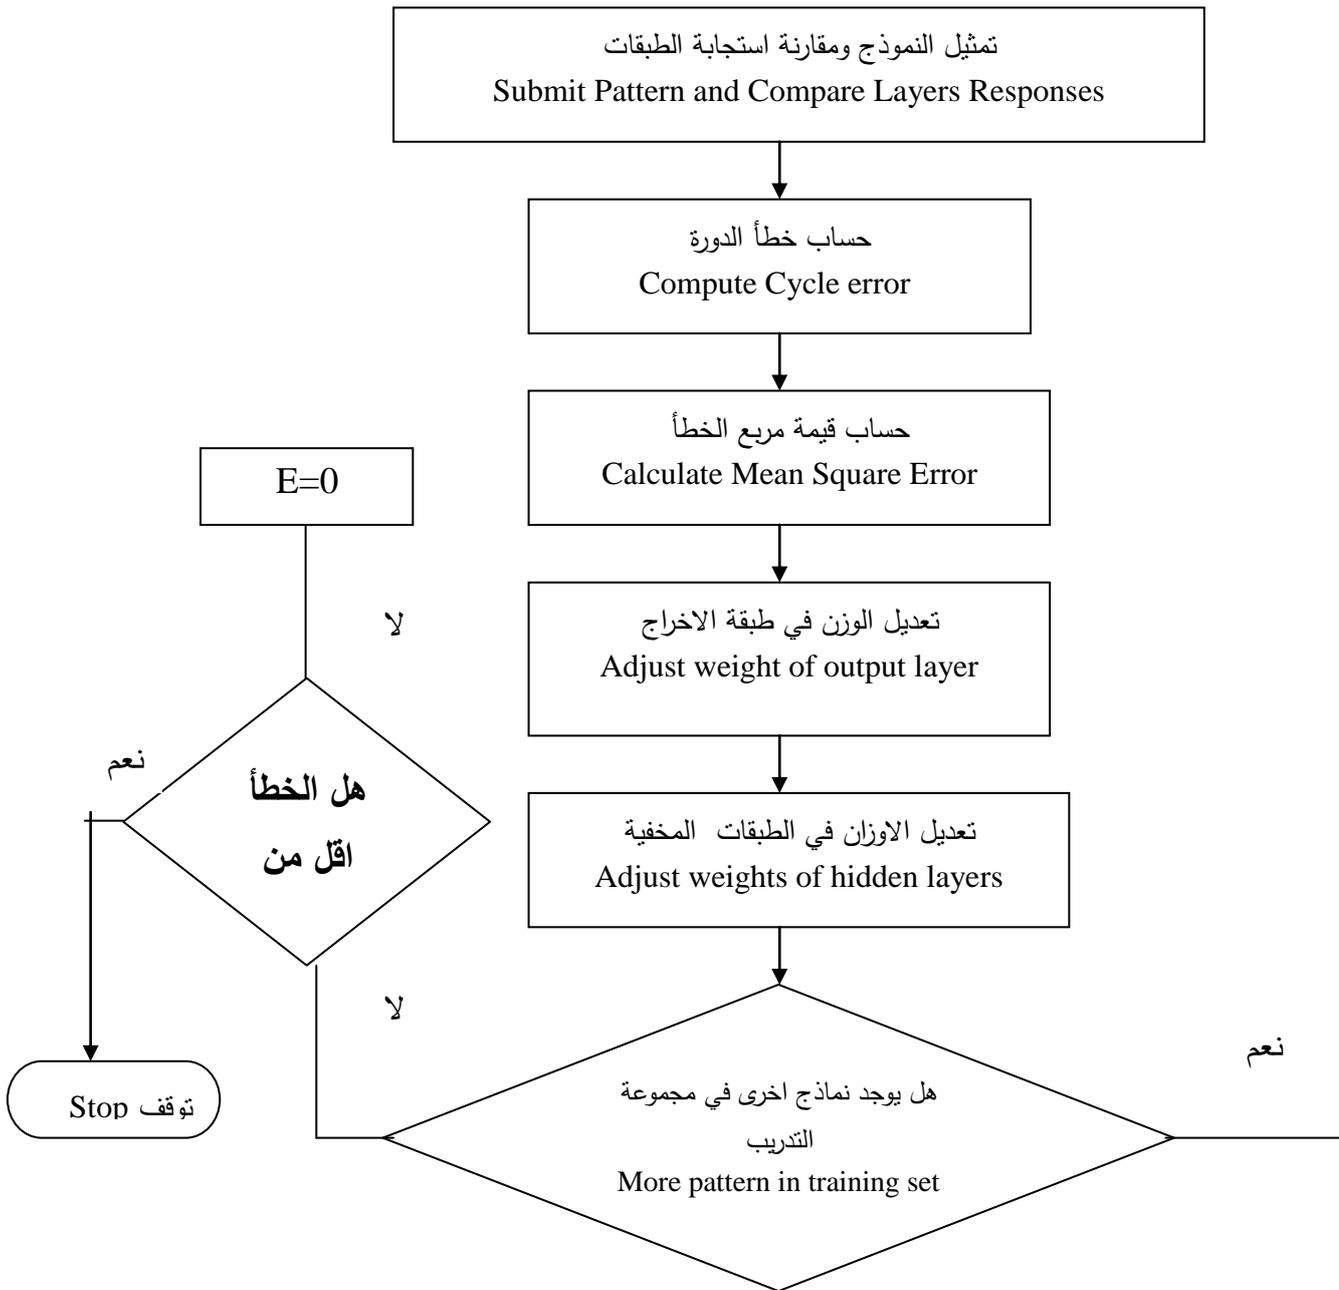
٤- عامل عدد العقد المخفية (Number of Hidden Nodes)

ان افضل طريقة في تحديد عدد العقد المخفية للشبكة العصبية هي اختيار عدد قليل من العقد المخفية عند البدء بتدريب الشبكة العصبية ثم ملاحظة النتائج وبعدها تزداد العقد المخفية الى ان تصل الى اقل مربع خطأ ممكن وافضل نتائج في معايير المقارنة.

٥- عامل عدد المستويات المخفية (Number of Hidden Levels)

هو من العوامل المهمة في كفاءة تدريب الشبكة العصبية، حيث يبدأ تدريب الشبكة العصبية بمستوى مخفي واحد وتستمر عملية التدريب او التعلم على صفات بيانات الشبكة العصبية، الى الوصول الى اقل مربع خطأ ممكن، وفي حالة عدم تعلم الشبكة العصبية على اغلب صفات البيانات تتم زيادة الشبكة العصبية.





الشكل (٣-٣): خطوات تدريب شبكة الانتشار العكسي.

الفصل الرابع

التكهن باستهلاك الطاقة الكهربائية في مدينة الموصل



١-٤ مقدمة.

٢-٤ وصف السلسلة الزمنية.

٣-٤ تقدير الاتجاه العام.

٤-٤ استخدام الشبكات العصبية

في التكهن.

٥-٤ التطبيق العملي للشبكة العصبية

ذات الانتشار العكسي للخطأ.

٦-٤ المقارنة بين الطرق الاحصائية

والشبكات العصبية.

٤-١ مقدمة

تم الاعتماد في هذا الفصل على تطبيق البرنامجين الحاسوبيين Matlab و Minitab على بيانات حقيقية اخذت من الشركة العامة لكهرباء الشمال والتي مركزها في محافظة نينوى، ويتلخص عمل الشركة باستلام الطاقة الكهربائية من الشركة العامة لتوليد الطاقة الكهربائية وايصالها الى المشتركين عبر محطات التحويل وشبكات التوزيع، وكذلك صيانة المحطات وشبكات التوزيع من خلال الصيانة الدورية والصيانة الطارئة عند تعرض الشبكة الى الحوادث الآتية.

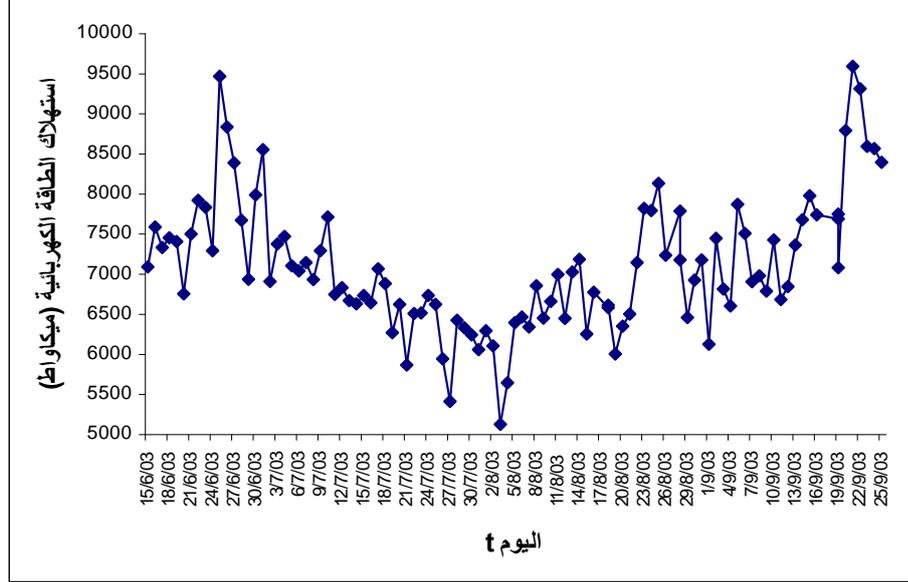
لقد تم استخدام بيانات لاستهلاك الطاقة لكونها تتبع نمودجا غير خطيا وذلك بسبب طبيعة العمل التي تؤدي الى الترابط بين الأيام، حيث يزيد استهلاك الطاقة الكهربائية في ايام الصيف نتيجة لاستخدام اجهزة التبريد والتكييف، ويقل نسبيا في الايام المعتدلة الحرارة. إن البيانات التي نقوم بدراستها تمثل مقدار استهلاك الطاقة الكهربائية اليومية لمدينة الموصل (ميكواواط/ساعة) وللفترة من ٢٠٠٣/٦/١٥ الى ٢٠٠٣/٩/٢٥ زدتنا بها مشكورة الشركة العامة لكهرباء الشمال. ولما كانت هذه البيانات تمثل مشاهدات مأخوذة بازمنة مختلفة وان قيمها تتغير بتغير الدليل الزمني، فمن الواضح انها تمثل بيانات لسلسلة زمنية ولتكن $\{P_t; t=0,1,2,\dots\}$ ، أي ان P_t تمثل مقدار استهلاك الطاقة الكهربائية (ميكواواط/ساعة) باليوم (t) في مدينة الموصل.

اما المشاهدات الواقعية التي حصلنا عليها والموضحة في الملحق (١) فيرمز لها $\{p_t; t=1,2,\dots,n\}$ حيث ان $n=103$ وان n تمثل عدد المشاهدات.

٤-٢ وصف السلسلة الزمنية

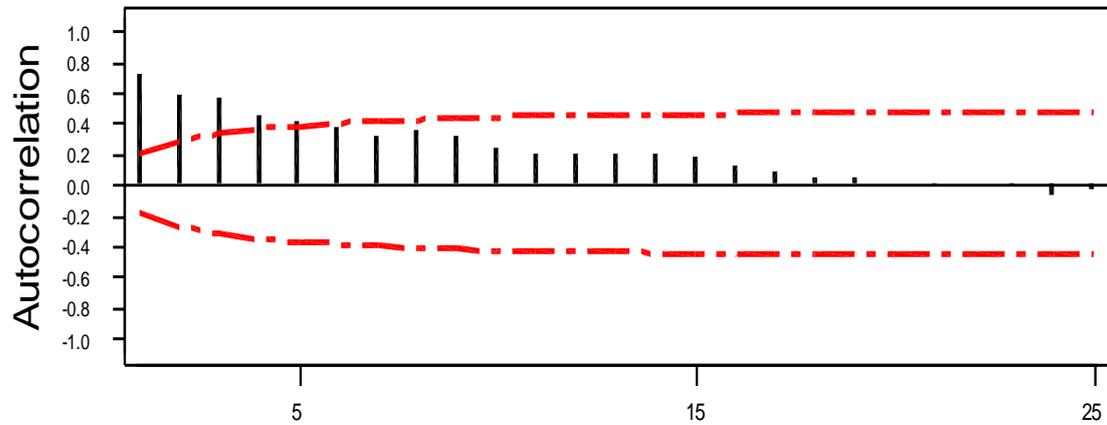
ان من اول الخطوات التي تتبع لوصف او تحليل سلسلة زمنية هو رسمها بما يعرف بالرسم الزمني Time Series Plot، حيث يمكن من خلال الرسم الاطلاع على طبيعة التذبذب فيها وملاحظة فيما اذا كانت تتضمن اتجاهاً عاماً Trend أم لا؟ حيث أن معرفة الاتجاه العام يفيد كثيرا في التأكد من مرحلة Stationarity السلسلة الزمنية فضلاً عن علاقته الوثيقة بالتكهن.

يبين الشكل (١-٤) رسم السلسلة الزمنية التي نحن بصدها، ويلاحظ ان تذبذب السلسلة يبدأ بالهبوط التدريجي، ثم يأخذ بالصعود التدريجي وبشكل قطع مكافئ من الدرجة الثانية مما



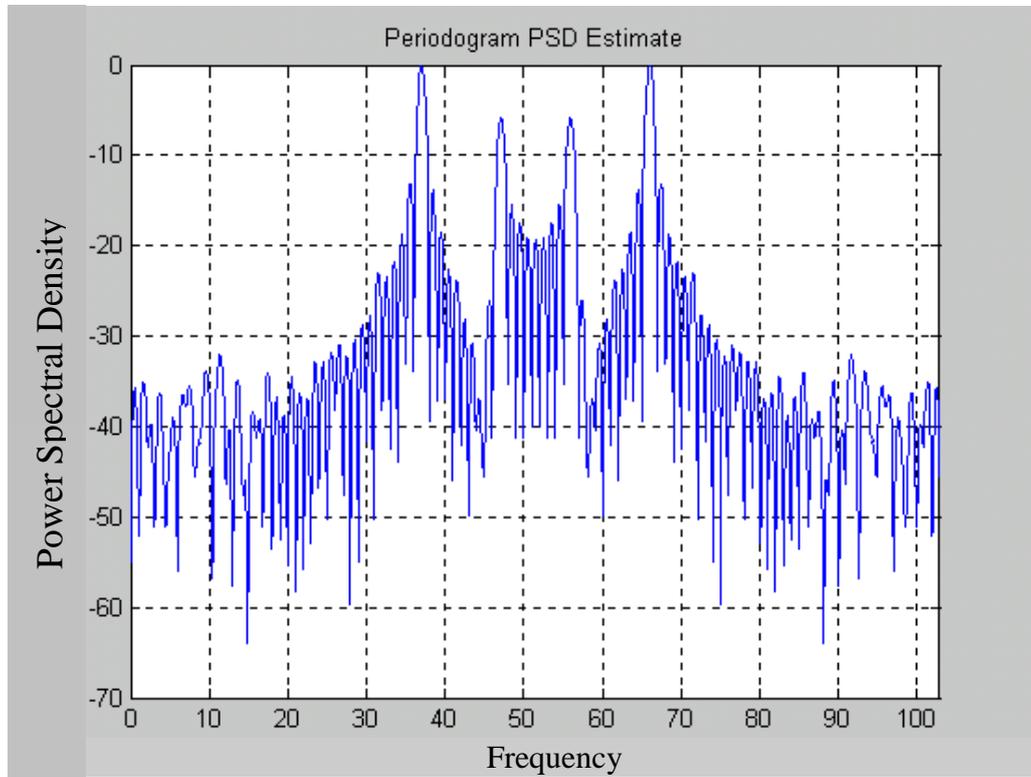
يدل على عدم مرحلية هذه السلسلة. من ناحية اخرى نلاحظ ان هناك تشتت واضح حول المسار العام للتذبذب، مما يؤكد وجود تأثيرات عشوائية واضحة ومؤثرة في هذه السلسلة. الشكل (١-٤): الرسم الزمني لملاحظات استهلاك الطاقة الكهربائية في مدينة الموصل.

أما الشكل (٢-٤) فيوضح مقدر دالة الارتباط الذاتي ACF للملاحظات الخام فضلاً عن حدي الثقة Confidence limits لهذه الدالة بمستوى معنوية ٥% والممثلة بالرسم بخطين أفقيين متوازيين ومنقطين.



الشكل (٢-٤): دالة الارتباط الذاتي Autocorrelation للملاحظات الخام.

ويلاحظ من الرسم ان دالة الارتباط الذاتي عند درجات الابطاء lags ١، ٢، ٣، ٤، و٥ موجبة وتقع جميعها خارج حد الثقة العلوي، لذا يستنتج بان فرضية العدم $H_0: \rho_k=0 ; k=1,2,3,4,5$ سوف تكون مرفوضة عند مستوى المعنوية ٥%، وهذا يؤكد وجود ترابط ايجابي معنوي بين حاضر هذه السلسلة وماضيها ولفترة امدها خمسة ايام. بعد تحليل هذه السلسلة في المنطق الزمني Time Domain يمكن استكمال هذا التحليل المبسط بتحليل اخر يعرف بالمنطق الترددي Frequency Domain. والشكل (٣-٤) يوضح المخطط الدوري Periodogram وكما هو واضح ان توزيع الطاقة ليس منتظما، مما يؤكد كون السلسلة ليست تشويشاً ابيضاً.



الشكل (٣-٤): المخطط الدوري للملاحظات الخام.

٤-٣ تقدير الاتجاه العام

لو اعتبرنا أن النموذج الرياضي للسلسلة الزمنية $\{X_t\}$ هو بالشكل:

$$X_t = h(t) + \varepsilon_t \quad (1a.4)$$

حيث أن

ε_t هو الخطأ العشوائي

$h(t)$ هو الاتجاه العام

وقد تم إجراء تقدير إحصائي للعديد من النماذج الرياضية للاتجاه العام لهذه السلسلة الزمنية وبالاعتماد على معيار متوسط مربع الخطأ (MSE) حيث تمت ملائمة نماذج رياضية للملاحظات الخام، وكما مبين في أدناه:

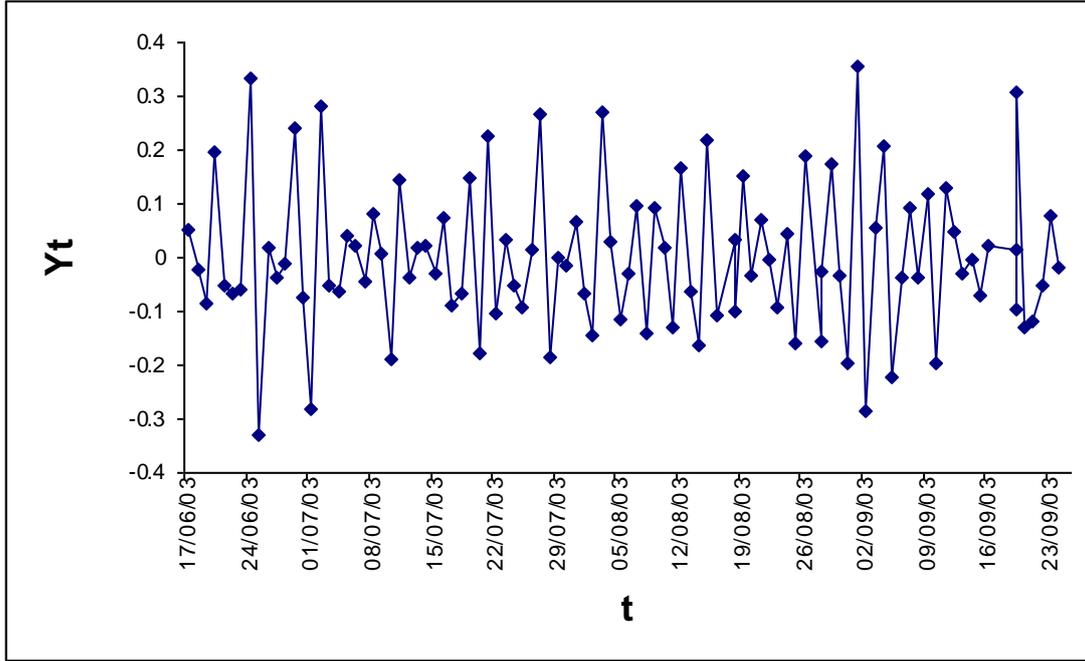
- لو اعتبرنا أن الاتجاه العام هو دالة خطية بشكل $h(t) = a_0 + a_1t$ فإن معدل مربع خطأ البواقي هو $MSE_L = 665910$.
- ولو اعتبرنا أن النموذج من الدرجة الثانية بشكل $h(t) = b_0 + b_1t + b_2t^2$ فإن معدل مربع خطأ البواقي هو $MSE_Q = 342354$.
- أما إذا اعتبرناه أسياً بالشكل $h(t) = e^{c_0 + c_1t}$ فإن معدل مربع الخطأ هو $MSE_E = 667528$.

وكما هو واضح فإن نموذج الاتجاه العام التربيعي هو الأفضل وفق معيار معدل مربع الخطأ من بين النماذج وهذه النتيجة تتسجم مع ما ذكر انفاً من أن الاتجاه العام لهذه السلسلة هو معادلة من الدرجة الثانية. إن النموذج النهائي المقدر للاتجاه العام هو النموذج التربيعي الآتي:

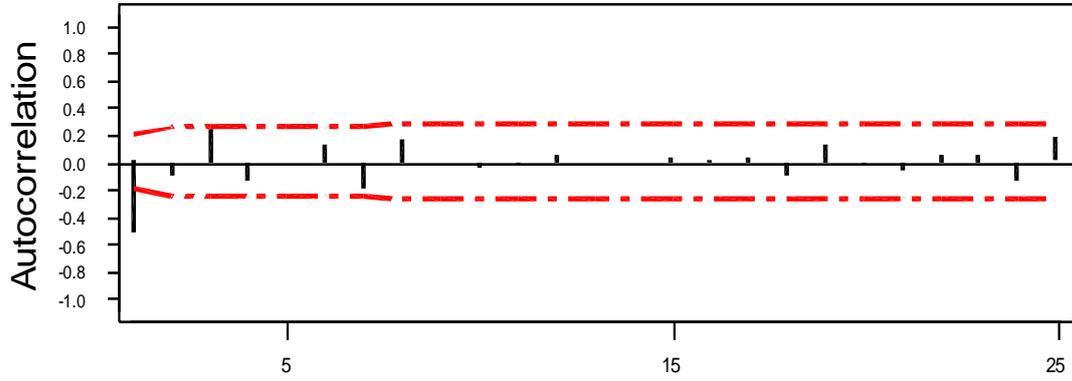
$$\hat{h}(t) = 8236.40 - 71.6092t + 0.71953t^2 \quad (1b.4)$$

وان مقدر تباين الخطأ العشوائي في (1a.4) هو $\hat{\sigma}_\varepsilon^2 = 345710$.

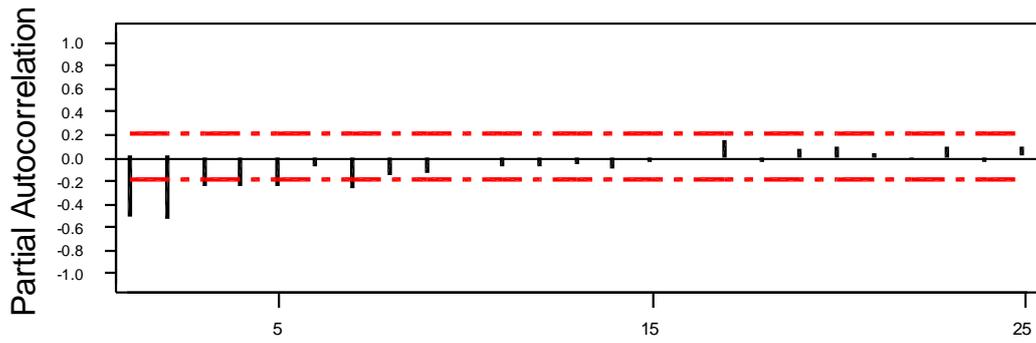
ولنحاول الآن تحويل السلسلة الزمنية الى سلسلة مرحلية، حيث يشترط في التكهّن بالطرائق الكلاسيكية أن تكون السلسلة مرحلية. لقد تم إجراء التحويل اللوغارتمي لمشاهدات السلسلة الأصلية $X_t = \ln(p_t)$ ، حيث انها غير مرحلية بالتباين، ثم تم أخذ الفروقات (Differences) وبدأً بالفرق الأول (ΔX_t) ثم الفرق الثاني $(\Delta^2 X_t)$. ولما كان الاتجاه العام تربيعياً كما هو متوقع فقد اعطى الفرق الثاني $Y_t = \Delta^2 X_t$ تذبذباً قريباً من التذبذب المرهلي. بعد الحصول على المرحلية في سلوك السلسلة (الشكل ٤-٤) فقد تم العمل من أجل تحديد النموذج الملائم ورتبته، وذلك من خلال حساب دالة الارتباط الذاتي (ACF)، الموضحة في الشكل (٤-٥) ، فضلاً عن حساب دالة الارتباط الذاتي الجزئي (PACF)، الموضحة في الشكل (٤-٦).



الشكل (٤-٤): سلوك المشاهدات بعد تحويل السلسلة الزمنية الى سلسلة مرحلية.



الشكل (٥-٤): دالة الارتباط الذاتي للسلسلة المرحلية $\{Y_t\}$.



الشكل (٦-٤): دالة الارتباط الجزئي للسلسلة المرحلية $\{Y_t\}$.

يتبين من الشكلين (٥-٤) و (٦-٤) ان النموذج المناسب للسلسلة $\{Y_t\}$ هو نموذج $ARMA(2,1)$ كذلك فقد استخدم معيار AIC لاختيار النموذج، والجدول (٢-٤) يوضح نتائج ملائمة مجموعة من نماذج $ARMA(p,q)$ ولقيم مختلفة من p و q وكذلك قيمة معيار AIC في كل حالة.

الجدول (١-٤): ملائمة النموذج $ARMA(p,q)$ للبيانات المحولة.

p	q	MSE	AIC	$\hat{\sigma}_\varepsilon^2$
٠	١	0.007314	-495.982	0.007223
٠	٢	0.007179	-496.686	0.007032
٠	٣	-	-	-
١	٠	0.01348	-433.976	0.013345
٢	٠	0.009625	-467.028	0.009432
٣	٠	0.009045	-472.337	0.008774
١	١	0.006782	-502.682	0.006627
١	٢	0.007292	-494.322	0.007057
١	٣	0.006360	-507.372	0.00608
٢	١	0.006243**	-510.221*	0.006029
٢	٢	0.006354	-507.262	0.006087
٢	٣	0.006344	-506.641	0.006004
٣	١	0.006366	-508.852	0.005992
٣	٢	0.006419	-505.406	0.006078
٣	٣	0.006444	-504.075	0.006038

*أقل قيمة لمعيار AIC.

** أقل قيمة لمعدل مربع الخطأ

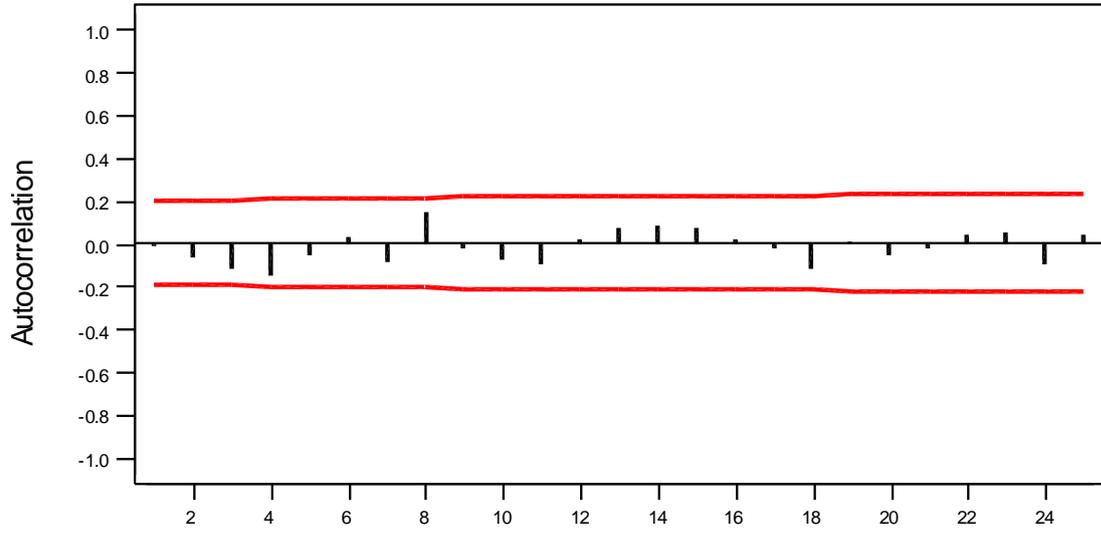
وكما هو واضح من الجدول فان قيمة AIC الصغرى عند النموذج ARMA(2,1) مما يعزز النتيجة السابقة بان هذا النموذج يمكن اعتباره الأفضل من هذه العائلة من النماذج الخطية، والنموذج النهائي المقدر مع الأخطاء المعيارية للمعاملات (المحددة بين قوسين) هو كما يأتي:

$$Y_t = 0.3942Y_{t-1} + 0.3245Y_{t-2} + \varepsilon_t + 0.008\varepsilon_t$$

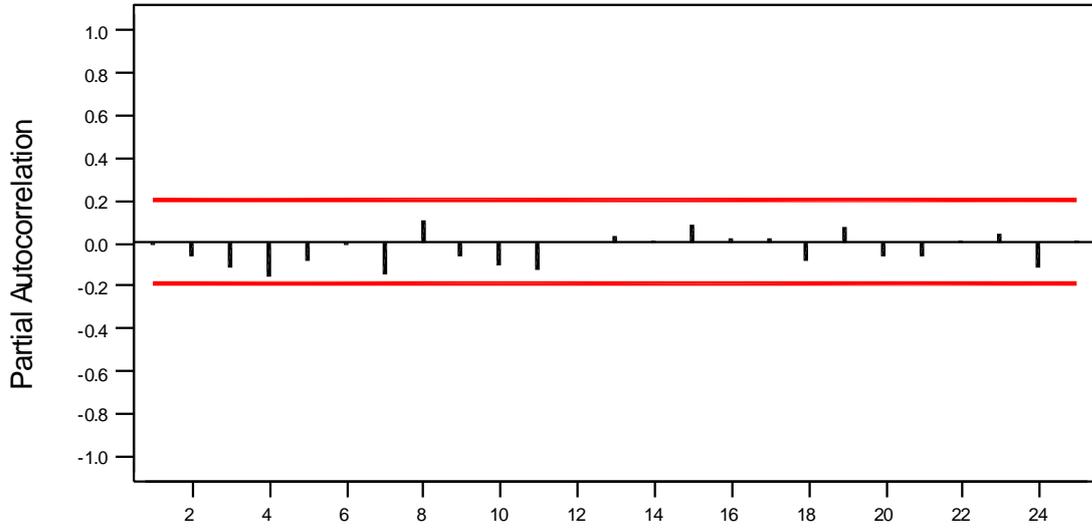
(0.0971) (0.0970) (0.0283)

حيث إن $\hat{\sigma}_\varepsilon^2 = 0.0060295$. وبمقارنة مقدرات المعاملات مع أخطائها المعيارية يتبين معنوية هذه المعاملات.

وللتأكد من صلاحية النموذج ARMA(2,1)، تم رسم دالة الارتباط الذاتي ودالة الارتباط الذاتي الجزئي للبواقي Residuals والموضحة في الشكلين (٧-٤) و(٨-٤) ووجد أنها تقع ضمن حدود الثقة، مما يشير إلى أن بواقي هذا النموذج غير مترابطة مع بعضها البعض.



الشكل (٧-٤): دالة الارتباط الذاتي لبواقي النموذج $ARMA(2,1)$.



الشكل (٨-٤): دالة الارتباط الذاتي الجزئي لبواقي النموذج $ARMA(2,1)$.

بعد أن تم ملاءمة النموذج والتأكد من صلاحيته يتم توظيفه الآن لغرض التكهّن.

لو كتبنا النموذج الملائم بالشكل

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

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} مع ملاحظة أن $E(\varepsilon_{t+1} | Y_t, Y_{t-1}, \dots) = 0$ نجد أن

$$\hat{Y}_{t+1} = -a_1 Y_t - a_2 Y_{t-1} + b_1 \varepsilon_t \quad (4.2)$$

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

وبعد حساب \hat{Y}_{t+1} يمكن، بشكل تقريبي 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 $X_t = \ln(P_t)$ لذا فان $P_t = e^{X_t}$ وهذا يقود إلى أن المتكهن بقيمة P_{t+1} سوف يكون

$$\hat{P}_{t+1} = e^{\hat{X}_{t+1}}$$

٤-٤ استخدام الشبكات العصبية في التكهّن

من الامور التي تشجع استخدام الشبكات العصبية في معالجة السلسلة الزمنية التي نحن بصدددها هو ان هذه السلسلة ليست ذات مواصفات قياسية (كونها غير مرحلية)، كما ان عملية تحويلها باخذ الفروقات ليست محبذة دائما ما لم يكن التوزيع الاحتمالي للسلسلة الاصلية طبيعيا Normal. إن الشبكات العصبية يمكن استخدامها لمعالجة السلاسل الزمنية 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 التكهّن.

لقد تم تصميم برنامج حاسوبي (انظر الملحق ٣) للحصول على قيم التكهّن لسلسلة المشاهدات دون الحاجة الى معالجة عدم المرحلية، وان اول خطوة في استخدام البرنامج هي تحديد المدخلات للشبكة العصبية، حيث ان المدخلات هي الطاقة الكهربائية المستهلكة (ميكواط/ساعة)، 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) حيث ذكروا بان عدد العقد المخفية يمكن حسابه بالشكل الاتي:

$$N_{\text{hidden}} \leq \frac{N_{\text{train}} E_{\text{tolerance}}}{N_{\text{pts}} + N_{\text{output}}} \quad (4.3)$$

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 $E_{\text{tolerance}}$ كي يكون ٠,٠١ وعدد مرات التدريب $N_{\text{train}}=500 \times N_{\text{pts}}$ و $N_{\text{output}}=1$. وبتطبيق المعادلة (4.3) نجد ان:

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

لذا فان عدد العقد المخفية يجب ان يكون 4 للبيانات وحسب عدد مرات التدريب. وحيث ان البيانات المستخدمة في هذه الدراسة يبلغ عددها (١٠٣) مشاهدة فقد اعتبر (١٣%) منها على

انها مشاهدات اختبار Test لغرض الاختبار، واعتبر ١٥% من المشاهدات كمجموعة الشرعية Validation اما باقي المشاهدات فقد استخدمت للتدريب وتقدير قيمة متوسط مربعات الخطأ (Mean Square Error MSE). واجريت عدة اختبارات لغرض الحصول على افضل النتائج وهي:

١- اختيار عدد العصبونات المخفية

استخدمت جميع المشاهدات، واجري الاختبار باستخدام شبكة الانتشار العكسي للخطأ وتم تدريب الشبكة باستخدام عدة عصبونات مخفية لاختيار افضلها وكان عددها بين ٢-٨. والجدول (٤-٢) يوضح مقدار الخطأ المطلق AE والذي يمثل الفرق بين قيم المخرجات للشبكة والايخراج المرغوب فيه. أي أن

$$AE = |y_i - d_i|$$

حيث إن:

y_i هو الاخراج الواقعي

d_i الاخراج المرغوب فيه

الجدول (٤-٢): اختيار عدد العصبونات المخفية.

عدد العصبونات المخفية Hidden neurons	التدريب Training	الشرعية Validation
	القيمة المطلقة للخطأ AE	القيمة المطلقة للخطأ AE
٢	٤٤٥,٥٨	٣٨٥,٥٩
٣	٤٤٥,١٧	٣٨٦,٠١٦
٤	٤٤٩,٤١٧	٣٧٠,٧٨٧*
٥	٤٥٠,٢٩	٣٧٦,٧٠١
٦	٤٤١,٨٣	٣٧٨,١٠٩
٧	٤٤٦,٩١٩	٣٧٢,٤١٢
٨	٤٤٦,٠٧	٣٧٣,٢٥٢

* اقل خطأ مطلق.

في هذا الاختبار تم تثبيت عدد مرات التدريب باعتبارها ٥٠٠٠ تكرار ، وقيمة متوسط مربع الاخطاء MSE بمقدار ٠,٠١ وكانت الاوزان بين [-5, 5]. وبذلك اعتبر ان افضل عدد

للعصبونات في الطبقات المخفية هو (٤) عصبونات، وذلك لان قيمة الخطأ المطلق للشرعية في هذه الحالة هو الأقل.

٢- اختيار عدد مرات التكرار

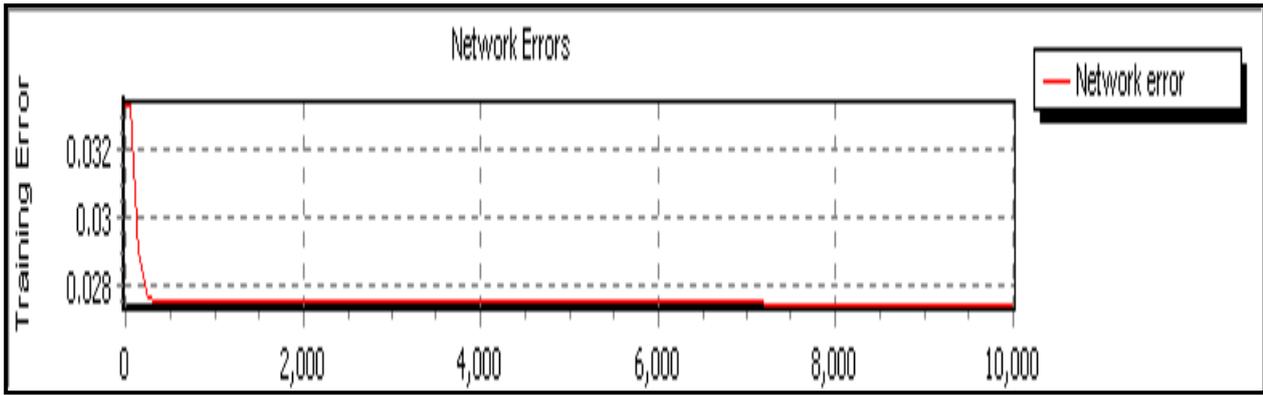
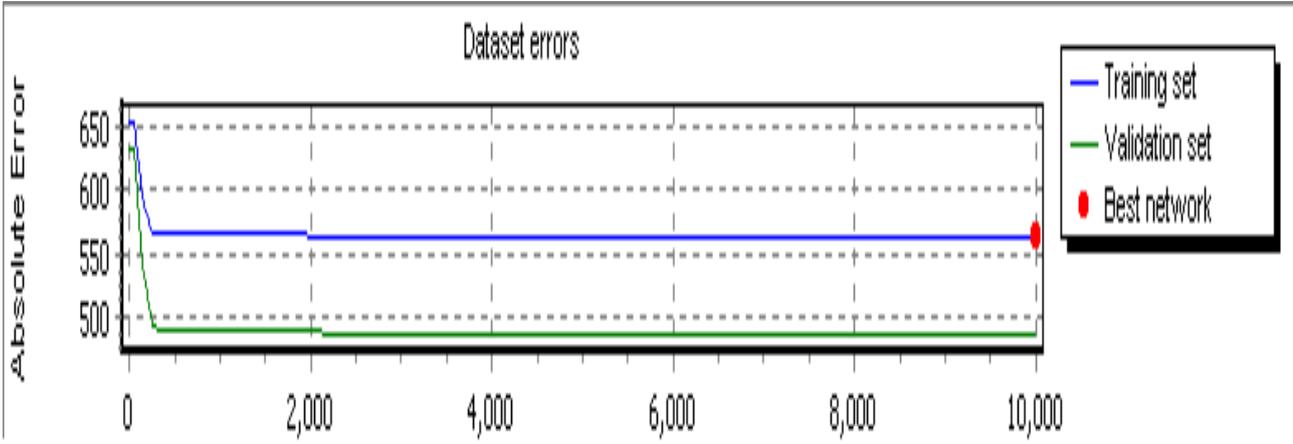
بعد اختيار افضل عدد للعصبونات، تم إجراء الاختبار الثاني وذلك لاختيار افضل عدد للتكرارات الذي يجعل قيمة الخطأ المطلق اقل ما يمكن. والجدول (٤-٣) يبين نتائج هذا الاختبار.

الجدول (٤-٣): اختيار عدد مرات التكرار

عدد مرات التدريب Number of Iteration	التدريب Training	الشرعية Validation
	القيمة المطلقة للخطأ	القيمة المطلقة للخطأ
١٠٠٠	٤٢٤,٤١٧	421.209
٢٠٠٠	٤٢٥,٦٦٣	٤٢١,٣٢٨
٣٠٠٠	٤٢٥,٧٥٦	٤٢١,٠٩٣
٤٠٠٠	٤٢٥,٣٧٨	٤٢١,٧٩٤
٥٠٠٠	٤٢٣,٠٥٠	٤١٩,٢٠
١٠٠٠٠	٤١٢,٣٥٣	٤١٤,٦٤٢*
٢٠٠٠٠	٤١٣,٧٣٧	٤٣٤,٢٩٣
٥٠٠٠٠	٣٧١,٩٧٧	٤٥٣,٩٧٢
١٠٠٠٠٠	٣٥٤,٥٩١	٤٧٢,١٨١

* اقل قيمة للخطأ المطلق.

في هذا الاختبار استخدمت شبكة عصبية ذات الانتشار العكسي للخطأ بعدد عصبونات (٤) و $MSE=0.01$. وبعد إجراء الاختبار، تم اختيار عدد مرات التكرار كي يكون (١٠٠٠٠٠) تكرار للحصول على اقل خطأ. الشكل (٤-٩) يوضح مستوى الخطأ المطلق للشبكة.



الشكل (٤-٩): مستوى الخطأ المطلق للشبكة العصبية ذات الانتشار العكسي للخطأ.

يتبين من الشكل إن افضل شبكة (Best Network) عند (١٠٠٠٠) عدد للتكرار، وان الشرعية سلكت نفس سلوك التدريب ولكن بخطأ مطلق اقل من التدريب. أما شكل منحنى الخطأ المطلق للشبكة فانه يأخذ بالتناقص مع زيادة عدد التكرار مقارنة مع خطأ التدريب.

٤-٥ التطبيق العملي للشبكة العصبية ذات الانتشار العكسي للخطأ

لقد تم استخدام برنامج حاسوبي مصمم بلغة ++C للتوصل إلى قيم التكهن وحساب المعلمات الاحصائية، وتم بناء شبكة عصبية ذات الانتشار العكسي للخطأ للمشاهدات الاصلية واستخدام (٤) عقد مخفية Hidden nodes وطبقتين مخفيتين Hidden Layers، حيث يبدأ التدريب باوزان عشوائية ثم تطبق الصيغ الخاصة بالانتقال الامامي الاتية:

$$XO_i = \text{seg}(X_i + I * w_i)$$

حيث ان:

XO_i : المخرجات من طبقة الادخال الى الطبقة المخفية.

X_i : المدخلات

I : التكرار

w_i : الاوزان الابتدائية.

ولحساب مخرجات الطبقات المخفية تستخدم الصيغة:

$$OL(J) = \text{seg}\left(\sum_{i=0}^N XO[i] * w[J][i]\right)$$

حيث ان:

J : الطبقة المخفية وفي هذا التطبيق تكون (١ و ٢)

N : عدد المشاهدات.

وتحسب المخرجات في طبقة الاخراج وفق الصيغة:

$$O = \text{seg}\left(\sum_{i=1}^4 OL(J,i) * WO_i\right)$$

حيث

$$WO_i = \eta * Z * OL(1,i)$$

حيث ان

η : معدل التعلم

OL : مخرجات الطبقة المخفية

WO : الاوزان في طبقة الاخراج

Z : تحسب وفق الصيغة الاتية:

$$Z = Od - O * \text{segD}(\text{out})$$

حيث ان

Od: الاخراج المتوقع

O: الاخراج الفعلي

segD: ما يكافئ مشتقة دالة Sigmoid

ويحسب الخطأ المطلق للانتقال الامامي بالصيغة الاتية:

$$e = |Od - O|$$

اما الانتقال الخلفي فيحسب وفق الصيغ الاتية:

$$OL_{2,i} = Z * WO_1 * \text{segD}(OL_{2,i})$$

$$W_{i,J} = W_{iJ} + \eta * OL_{1,i} * OL_{2,i}$$

$$OL_{1,i} = \sum_{J=1}^2 OL_{2,J} * W_{i,J} * \text{segD}(OL_{1,i})$$

$$WI_i = WI_i + \eta * OL_{1,i}$$

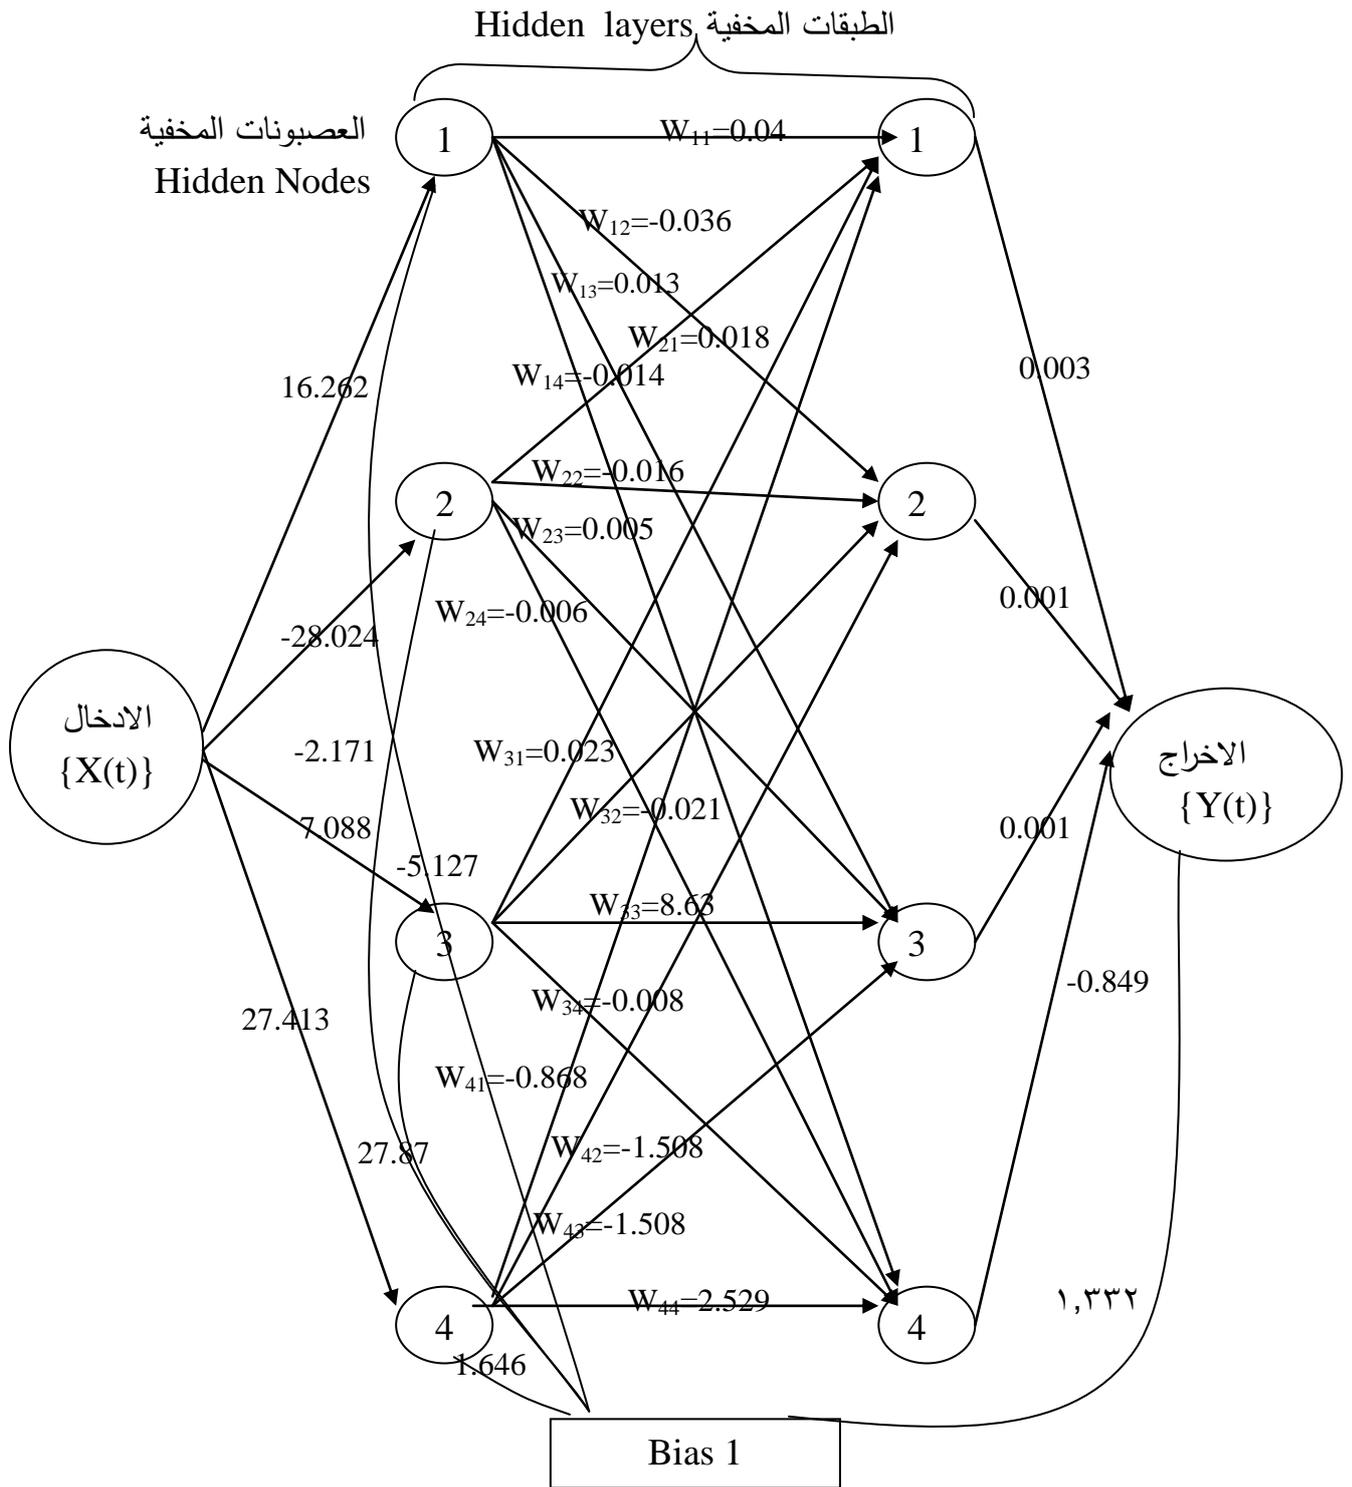
ويحسب الخطأ الكلي للشبكة كما يأتي:

$$E = e / \sum I$$

ويستمر التدريب للشبكة لحين الوصول الى قيمة الخطأ المحدد للشبكة (0,01). ومن

خلال تدريب الشبكة العصبية تم التوصل الى قيم التكهن وحساب المعلمات الاحصائية لغرض

المقارنة مع الطريقة الكلاسيكية والشكل (4-10) يمثل نتائج الشبكة العصبية والاوزان الناتجة.



الشكل (٤-١٠): الشبكة العصبية ذات الانتشار العكسي للخطأ والاوزان التي تم الحصول عليها.

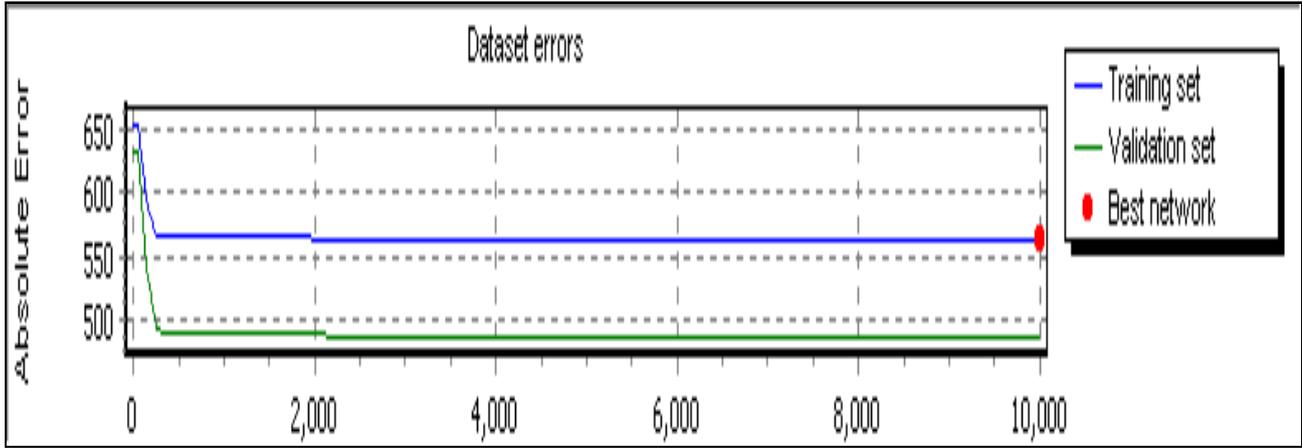
٤-٦ المقارنة بين الطريقة الاحصائية وطريقة الشبكات العصبية

لغرض المقارنة بين الاسلوبين المستخدمين، وهما الاسلوب الكلاسيكي المتمثل باسلوب بوكس-جينكنز واسلوب 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. والقيم المتكهن بها بالطريقتين الكلاسيكية والشبكات العصبية موضحة في الملحق (٢)، أما قيم المقارنة فهي مبينة في الجدول (٤-٤).

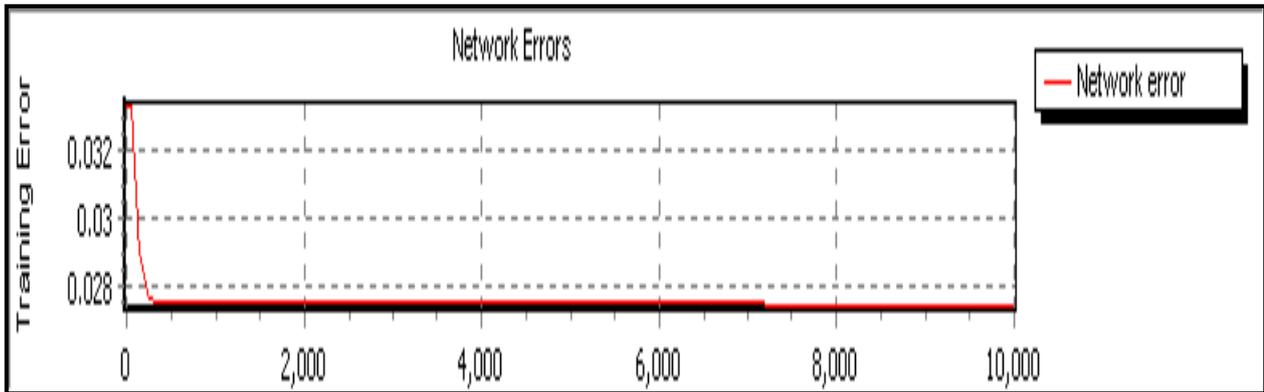
الجدول (٤-٤): المعايير الاحصائية للتكهن باستهلاك الطاقة الكهربائية في مدينة الموصل باستخدام الطرائق الاحصائية والشبكات العصبية.

MAE	MSE	MAPE	الطريقة المستخدمة
٧٨٠,٥٨٤	١٠٦٥٧٢٢	١١,٢٤٣	بوكس-جينكنز
٢٣٨,٥٧٧	٩٧٩٧٨,٩	٣,٣٦٧	الشبكات العصبية

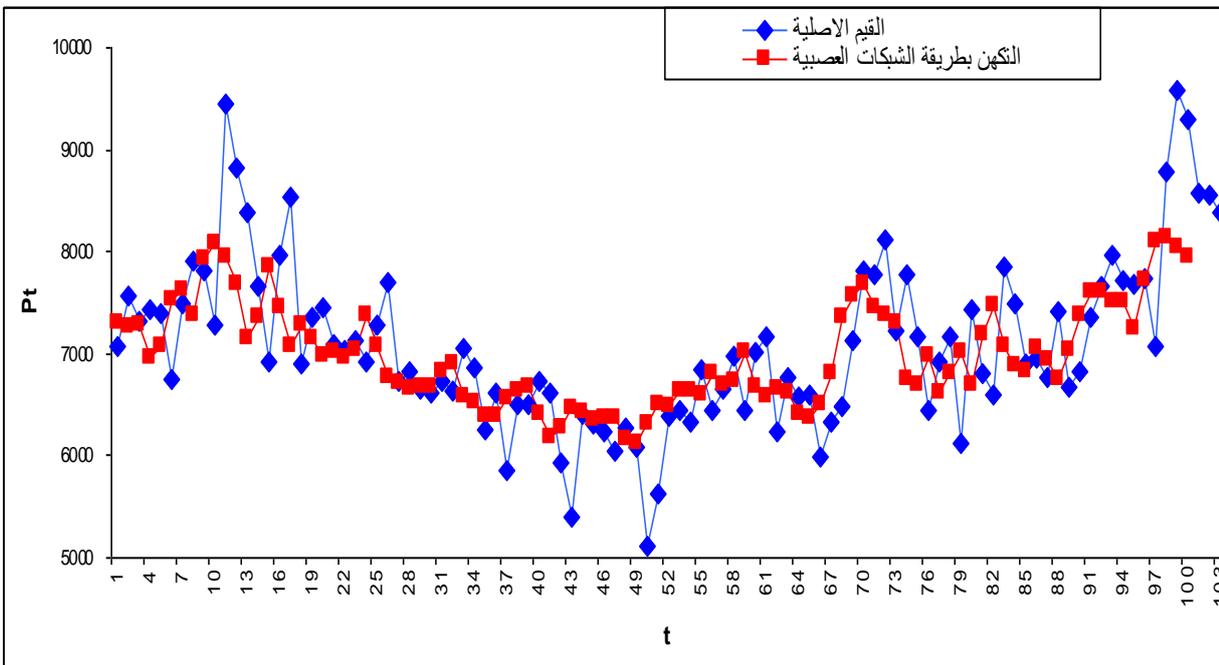
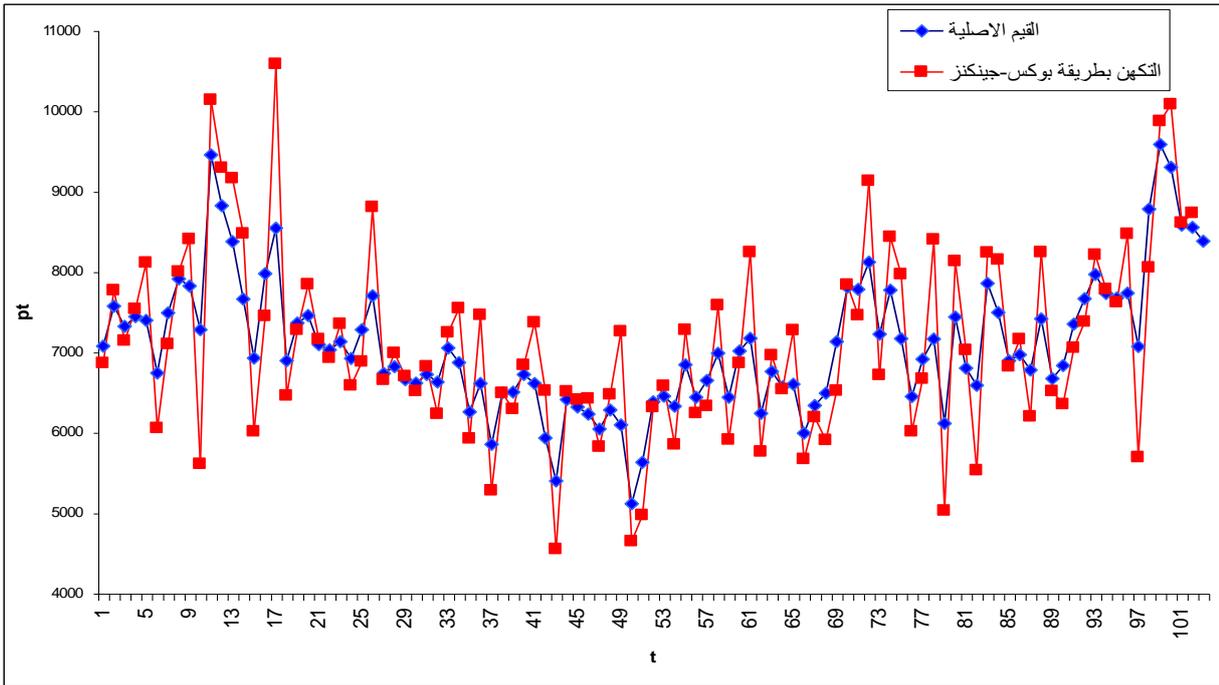
وكما هو واضح فان اسلوب الشبكات العصبية متفوق على طريقة بوكس-جينكنز ووفق المعايير الاحصائية الثلاثة. ويبين الشكل (٤-١١) قيم التكهن المحسوبة بالطريقتين المستخدمتين، ويتضح من الشكل ان منحى الشبكة العصبية هو الافضل في قيم التكهن.



عدد التكرارات



عدد التكرارات

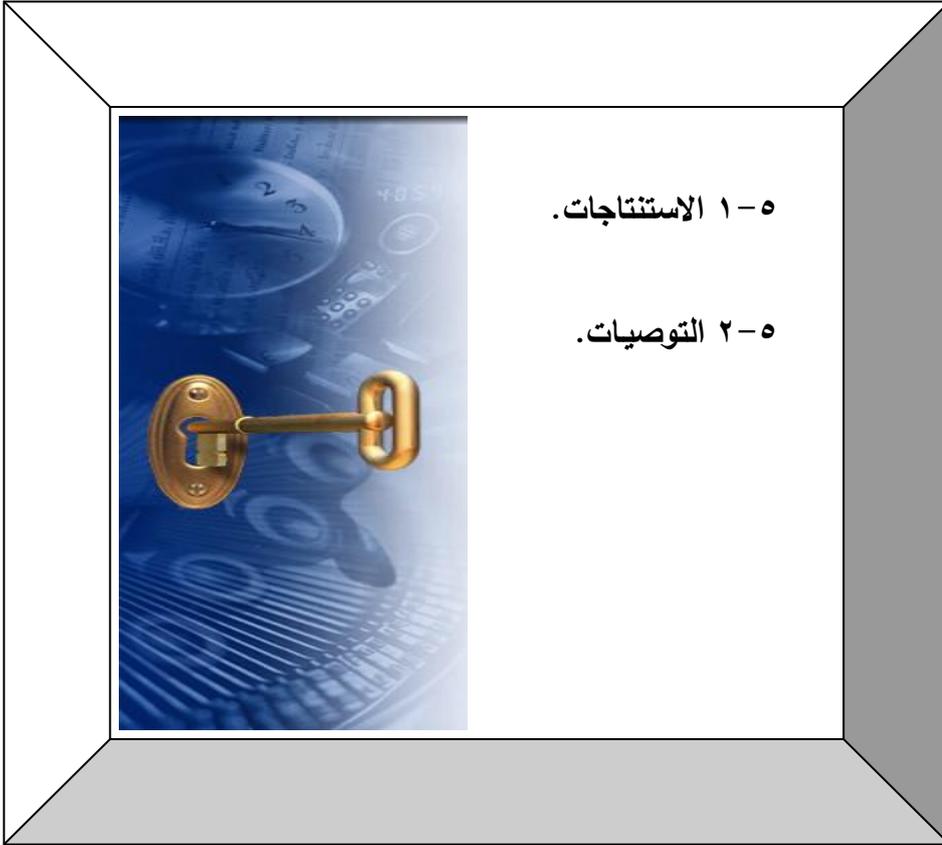


الشكل (٤-١١) قيم التكهين المحسوبة بالطريقتين الكلاسيكية والشبكات العصبية.

الفصل الخامس

الاستنتاجات والتوصيات

CONCLUSIONS and RECOMMENDATIONS



٥- ١ الاستنتاجات

إن من أهم الاستنتاجات التي تم التوصل إليها من خلال هذه الدراسة هي:

- ١- تفوق الشبكات العصبية على الطرائق الكلاسيكية، حيث تم الحصول على نتائج ذوات قيم أقل للمعايير الاحصائية المستخدمة لحساب أخطاء التكهّن. لذلك تعتبر الشبكات العصبية الاصطناعية هي الطريقة الأفضل والأكثر دقة للتكهّن بالقيم المستقبلية للسلسلة الزمنية قيد الدراسة، مما يشجع استخدام هذا الأسلوب للتكهّن بالسلاسل الزمنية المختلفة.
- ٢- تُعدّ الشبكات العصبية طريقة بديلة عن الطرائق الكلاسيكية المستخدمة في التكهّن التي تفترض شروط صارمة وصعبة ومنها المرحلية وتحتاج إلى صياغة رياضية معقدة، في حين ان الشبكات العصبية لا تفترض أي شروط ولا تحتاج إلى صياغة العلاقة الرياضية لامتلاكها خاصية التعلم والتدريب والتكيف ذاتيا.

٥- ٢ التوصيات

إن أهم التوصيات التي يوصى بها في مجال التكهّن هي:

- ١- إجراء دراسات تطبيقية للتكهّن بالقيم المستقبلية للسلاسل الزمنية متعددة المتغيرات Multivariate Time Series باستخدام الشبكات العصبية.
- ٢- إجراء دراسات باستخدام شبكات عصبية اخرى غير شبكة الانتشار العكسي للخطأ مثل شبكة المدرك Perceptron او الشبكة الدورية Recurrent Neural Network ومقارنة النتائج .

المصادر

REFERENCES



١. الجابري، عبدالرحمن محمد مرشد. (٢٠٠٠). "دراسة لبعض اساليب ترشيح السلاسل الزمنية مع تطبيقات". رسالة دكتوراه غير منشورة، كلية علوم الحاسبات والرياضيات، جامعة الموصل.
٢. حامد، جمال. (٢٠٠٣). "اساليب التنبؤ"، المعهد العربي للتخطيط، العدد الرابع عشر، شباط، السنة الثانية، الصفاة، الكويت.
٣. الشخيلي، ايفان علاء ناظم. (٢٠٠٣). "تصميم نظام رياضي ديناميكي لاخطي باستخدام الشبكات العصبية (NARMAX) لاغراض تحليلية وتنبؤية لنشاط المبيعات في شركة كهرباء بغداد"، رسالة ماجستير غير منشورة، كلية الادارة والاقتصاد، جامعة بغداد.
٤. عبد، صلاح حمزة وحسن، اياد جواد (٢٠٠٣). "استخدام المحاكاة للتحري عن حصانة معيار اكيكي لتقدير درجة عملية الانحدار الذاتي"، المجلة العراقية للعلوم الاحصائية، العدد (٥) المجلد (١)، ص ص ٢١٦-٢٣٩.
٥. الطائي، فارس غانم احمد. (٢٠٠٣). "دراسة مقارنة بين طرائق بوكس و جينكنز وطريقة التنقية المعدلة في التكهّن"، اطروحة دكتوراه غير منشورة، كلية علوم الحاسبات والرياضيات، جامعة الموصل.
٦. العبيدي، عبدالغفور جاسم سالم. (١٩٨٩). "تحليل ونمذجة السلسلة الزمنية لدرجات الحرارة في مدينة الموصل"، رسالة ماجستير غير منشورة، كلية العلوم، جامعة الموصل.
٧. المعهد العربي للتخطيط، (٢٠٠٠). "التدريب عن بعد عبر شبكة الانترنت"، الكويت، <http://www.api.org.kw>
٨. الموسوعة العربية للكمبيوتر والانترنت. (٢٠٠٣ و ٢٠٠٤). "الشبكات العصبية" <http://www.c4arab.com.mejhar.php>
٩. الناصر، عبدالمجيد حمزة والعبيدي، مروان عبدالحميد. (٢٠٠٣). "استخدام الشبكات العصبية للتنبؤ المستقبلي بقيم السلاسل الزمنية غير المنتظمة في طول الموسمية"، المجلة العراقية للعلوم الاحصائية، المجلد ٣، العدد ٦، كلية علوم الحاسبات والرياضيات، جامعة الموصل.

10. Ampazis, N. (1998). “**Introduction to Neural Networks**”, www.iit-nrcps.ariadne-t.gr/neural/index.
11. 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 .
12. Betker, A. L.; Szurm, T.; Moussavi, Z. (2003). “**Application of Feedforward Backpropagation Neural Network to Center of Mass Estimation for use in a Clinical Environment**”, Department of Electrical Engineering, University of Manitoba, Canada.
13. Bone, R. and Assaad, M. (2003). “**Boosting Recurrent Neural Networks for Time Series Prediction**”, RFAI Publication, International Conference in Roanne, France, April, pp. 18-22.
14. Box,G.P. and Jenkins,G.M.(1976)."**Time Series Analysis Forecasting and Control**" , Revised Edition Holden-Day Inc. San Francisco.
15. Chatfield, C.(1980).“**The Analysis of Time Series: An Introduction**” Bath University, 2nd ed., UK.
16. Ennett , C. M. and Frize M. (2002). “**Weight-elimination Neural Networks Applied to Coronary Surgery Mortality Prediction**”, IEEE Trans Info Technol Biomed, Oct.
17. Gershenson , Carlos. (1998). “**Artificial Neural Networks for Beginners**”, Sussex Academy, UK.
18. Gilchrist, W. (1976). “**Statistical Forecasting**”, Department of Mathematics and Statistics Sheffield City Polytechnic, John Wiley&Sons, UK.
19. Hamilton, J. D. (1994). “**Time Series Analysis**”, Princeton University Press, New Jersey.

20. Kneale , p.; See, L. and Smith, A. (2000). “**Towards Defining Evaluation Measures for Neural Network Forecasting Models**”, School of Geography, University of Leeds , UK.
21. Lewis, P. A. W.; McKenzie, E. and Hugus, D. K. (1989). “**Gamma Processes**”, Commune Statistic, Stochastic Model, 5(1), 1-30.
22. 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.
23. 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.
24. Makridakis, Spyros; Wheelwright, Steven C.; and Hyndman, Rob J. (1998). “**FORECASTING Method and Applications**”, 3rd ed., John Wiley & Sons. Inc., USA.
25. Mois , R. and Pires , F. (2002). “ **Prediction Model, Based on Neural Networks, for Time Series with Origin in Chaotic Systems**”, Institute Politécnico de Beja, Portugal.
26. Pin, N. (2003). “**Business Statistics**”, A First Course, 3rd ed., Chapter 12, Prentice-Hall.
27. Portugal , M. S. (1995). “**Neural Networks Versus Time Series Methods: A Forecasting Exercise**”, University Federal do Rio Grande do Sul, Brazil.
28. Priestley, M. B. (1981). “**SPECTRAL ANALYSIS AND TIME SERIES**”. Vol. 1, Department of Mathematics, University of Manchester, Academic Press Inc., London, UK.
29. Rao, V. B. and Rao, H. V. (1993). “**C++ Neural Networks and Fuzzy Logic**” .MIS Press.

30. Sandy D. B.; Ernst and Young, LLP. (2003). “**Statistical Aspects of Neural Networks**,” Quantitative Economics & Statistics, 1225 Connecticut Avenue, NW, Washington. USA.
31. 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.
32. Sinha, H. (2002). “**Designing a Neural Network for forecasting Financial and Economic Time Series**”, June 4th, IND E 593.
33. [Smith, Leslie. \(2003\).](#) “**An Introduction to Neural Networks**”, Department of Computing and Mathematics ,University of Stirling. UK.
34. Stergiou, Ch. and Sigonos, D. (2001). “**Neural Networks**”. <http://www.emsl.pnl.gov:2080/docs/cie/techbrief/NN.techbrief.html>
35. Tkacz Greg. (2001). “**Neural network forecasting of Canadian GDP growth**”, International Journal of Forecasting 17 (2001) 57–69, Ottawa , Ontario , Canadak .
36. Tomasz J. Cholewo Jacek M. Zurada. (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.
37. Tong, Howell. (1990). “**Non-linear Time Series, A Dynamical System Approach**”, Institue of Mathematics and Statistics, University of Kent at Conterbury, Clarendon Press Oxford.
38. Trafalis, Th. B. (2003). “**Artificial Neural Networks Applied to Financial Forecasting**”, School of Industrial Engineering, University of Oklahoma.

39. Vinod, H. D. (1999). “**Time Series Analysis**”. Economic Fordham University, Bronx, New York, USA.
40. Whittle, P. (1963). “**Prediction and Regulation**”. English University Press, London, UK.
41. YAO , J. T. (2002). “ **Towards a Better Forecasting Model for Economic Indices**”, Department of Computer Science, University of Regina, Regina, Saskatchewan, Canada.
42. Zhou, Zhi-Hua; Wu, Jianxin and Tang, Wei . (2003). “**Ensembling Neural Networks: Many Could Be Better Than All**”, Artificial Intelligence, 137(1-2): 239-263, National Laboratory for Novel Software Technology, Nanjing University, Nanjing 210093, P.R.China.



الملاحق



(١) الملحق

المشاهدات الحقيقية لاستهلاك الطاقة الكهربائية (ميكاواط/ساعة) في مدينة الموصل

للفترة ٢٠٠٣/٦/١٥ ولغاية ٢٠٠٣/٩/٢٥.

التسلسل	التاريخ	الاستهلاك	التسلسل	التاريخ	الاستهلاك
١	٢٠٠٣/٦/١٥	7077	26	٢٠٠٣/٧/١٠	7701
2	٢٠٠٣/٦/١٦	7574	27	٢٠٠٣/٧/١١	6736
3	٢٠٠٣/٦/١٧	7319	28	٢٠٠٣/٧/١٢	6820
4	٢٠٠٣/٦/١٨	7440	29	٢٠٠٣/٧/١٣	6657
5	٢٠٠٣/٦/١٩	7394	30	٢٠٠٣/٧/١٤	6616
6	٢٠٠٣/٦/٢٠	6741	31	٢٠٠٣/٧/١٥	6723
7	٢٠٠٣/٦/٢١	7489	32	٢٠٠٣/٧/١٦	6630
8	٢٠٠٣/٦/٢٢	7909	33	٢٠٠٣/٧/١٧	7054
9	٢٠٠٣/٦/٢٣	7822	34	٢٠٠٣/٧/١٨	6870
10	٢٠٠٣/٦/٢٤	7280	35	٢٠٠٣/٧/١٩	6258
11	٢٠٠٣/٦/٢٥	9455	36	٢٠٠٣/٧/٢٠	6610
12	٢٠٠٣/٦/٢٦	8823	37	٢٠٠٣/٧/٢١	5855
13	٢٠٠٣/٦/٢٧	8377	38	٢٠٠٣/٧/٢٢	6496
14	٢٠٠٣/٦/٢٨	7660	39	٢٠٠٣/٧/٢٣	6503
15	٢٠٠٣/٦/٢٩	6925	40	٢٠٠٣/٧/٢٤	6723
16	٢٠٠٣/٦/٣٠	7975	41	٢٠٠٣/٧/٢٥	6610
١٧	٢٠٠٣/٧/١	8541	42	٢٠٠٣/٧/٢٦	5932
18	٢٠٠٣/٧/٢	6895	43	٢٠٠٣/٧/٢٧	5400
19	٢٠٠٣/٧/٣	7364	44	٢٠٠٣/٧/٢٨	6411
20	٢٠٠٣/٧/٤	7457	45	٢٠٠٣/٧/٢٩	6317
21	٢٠٠٣/٧/٥	7092	46	٢٠٠٣/٧/٣٠	6231
22	٢٠٠٣/٧/٦	7028	47	٢٠٠٣/٧/٣١	6046
23	٢٠٠٣/٧/٧	7132	48	٢٠٠٣/٨/١	6280
24	٢٠٠٣/٧/٨	6921	49	٢٠٠٣/٨/٢	6093
25	٢٠٠٣/٧/٩	7279	50	٢٠٠٣/٨/٣	5115

التسلسل	التاريخ	الاستهلاك	التسلسل	التاريخ	الاستهلاك
51	٢٠٠٣/٨/٤	5632	78	٢٠٠٣/٨/٣١	7165
52	٢٠٠٣/٨/٥	6382	٧٩	٢٠٠٣/٩/١	6114
53	٢٠٠٣/٨/٦	6452	80	٢٠٠٣/٩/٢	7436
54	٢٠٠٣/٨/٧	6327	81	٢٠٠٣/٩/٣	6803
55	٢٠٠٣/٨/٨	6844	٨٢	٢٠٠٣/٩/٤	6589
56	٢٠٠٣/٨/٩	6439	٨٣	٢٠٠٣/٩/٥	7857
57	٢٠٠٣/٨/١٠	6648	٨٤	٢٠٠٣/٩/٦	7494
58	٢٠٠٣/٨/١١	6985	٨٥	٢٠٠٣/٩/٧	6893
59	٢٠٠٣/٨/١٢	6437	٨٦	٢٠٠٣/٩/٨	6966
60	٢٠٠٣/٨/١٣	7014	٨٧	٢٠٠٣/٩/9	6777
61	٢٠٠٣/٨/١٤	7171	٨٨	٢٠٠٣/٩/١٠	7414
62	٢٠٠٣/٨/١٥	6240	٨٩	٢٠٠٣/٩/١١	6670
63	٢٠٠٣/٨/١٦	6761	٩٠	٢٠٠٣/٩/١٢	6833
64	٢٠٠٣/٨/١٧	6569	٩١	٢٠٠٣/٩/١٣	7351
65	٢٠٠٣/٨/١٨	6600	٩٢	٢٠٠٣/٩/١٤	7665
66	٢٠٠٣/٨/١٩	5993	٩٣	٢٠٠٣/٩/١٥	7965
67	٢٠٠٣/٨/٢٠	6338	٩٤	٢٠٠٣/٩/١٦	7728
68	٢٠٠٣/٨/٢١	6490	٩٥	٢٠٠٣/٩/١٧	7676
69	٢٠٠٣/٨/٢٢	7133	٩٦	٢٠٠٣/٩/١٨	7736
70	٢٠٠٣/٨/٢٣	7807	٩٧	٢٠٠٣/٩/١٩	7069
71	٢٠٠٣/٨/٢٤	7780	٩٨	٢٠٠٣/٩/٢٠	8781
72	٢٠٠٣/٨/٢٥	8119	٩٩	٢٠٠٣/٩/٢١	9581
73	٢٠٠٣/٨/٢٦	7223	١٠٠	٢٠٠٣/٩/٢٢	9300
74	٢٠٠٣/٨/٢٧	7773	١٠١	٢٠٠٣/٩/٢٣	8580
75	٢٠٠٣/٨/٢٨	7167	١٠٢	٢٠٠٣/٩/٢٤	8553
٧٦	٢٠٠٣/٨/٢٩	6447	١٠٣	٢٠٠٣/٩/٢٥	8381
77	٢٠٠٣/٨/٣٠	6912			

الملحق (٢)

قيم التكهن بالقيم المستقبلية وبالطريقتين الكلاسيكية والشبكات العصبية.

التسلسل	الشبكات العصبية	طريقة بوكس-جينكنز	التسلسل	الشبكات العصبية	طريقة بوكس-جينكنز
١	7305	6862.836	٢٦	6759	8804.671
٢	7266	7767.65	٢٧	6718	6653.297
٣	7290	7139.488	٢٨	6648	6987.218
٤	6966	7533.781	٢٩	6677	6698.425
٥	7069	8112.754	٣٠	6675	6510.996
٦	7526	6054.902	٣١	6824	6817.565
٧	7617	7096.904	٣٢	6897	6231.72
٨	7375	8000.469	٣٣	6576	7243.195
٩	7928	8401.332	٣٤	6526	7542.113
١٠	8077	5605.745	٣٥	6379	5925.01
١١	7948	10133.85	٣٦	6390	7462.664
١٢	7686	9292.578	٣٧	6556	5277.447
١٣	7154	9161.374	٣٨	6641	6489.221
١٤	7364	8473.615	٣٩	6667	6290.449
١٥	7846	6013.386	٤٠	6401	6838.186
١٦	7454	7446.813	٤١	6175	7365.761
١٧	7069	10580.33	٤٢	6282	6516.728
١٨	7291	6456.084	٤٣	6469	4548.568
١٩	7156	7272.434	٤٤	6419	6506.635
٢٠	6985	7841.13	٤٥	6350	6404.446
٢١	7010	7156.799	٤٦	6373	6421.89
٢٢	6950	6925.791	٤٧	6372	5820.886
٢٣	7039	7349.721	٤٨	6152	6473.018
٢٤	7369	6580.907	٤٩	6123	7258.349
٢٥	7081	6880.37	٥٠	6316	4645.609

التسلسل	الشبكات العصبية	طريقة بوكس-جينكنز	التسلسل	الشبكات العصبية	طريقة بوكس-جينكنز
٥١	6506	4970.311	٧٦	6981	6013.533
٥٢	6483	6313.009	٧٧	6612	6668.15
٥٣	6632	6579.787	٧٨	6808	8396.899
٥٤	6637	5849.244	٧٩	7011	5027.247
٥٥	6592	7274.772	٨٠	6684	8128.224
٥٦	6800	6236.832	٨١	7185	7024.208
٥٧	6683	6327.482	٨٢	7477	5525.88
٥٨	6738	7579.918	٨٣	7076	8237.875
٥٩	7023	5907.734	٨٤	6881	8147.755
٦٠	6664	6860.652	٨٥	6822	6820.975
٦١	6574	8241.171	٨٦	7047	7160.59
٦٢	6662	5759.395	٨٧	6940	6194.937
٦٣	6614	6958.907	٨٨	6742	8241.336
٦٤	6416	6538.465	٨٩	7039	6511.191
٦٥	6377	7268.663	٩٠	7379	6351.763
٦٦	6507	5667.014	٩١	7599	7050.104
٦٧	6809	6189.798	٩٢	7599	7376.597
٦٨	7364	5905.195	٩٣	7509	8209.503
٦٩	7573	6517.445	٩٤	7516	7780.748
٧٠	7683	7834.464	٩٥	7250	7616.694
٧١	7451	7455.428	٩٦	7715	8466.29
٧٢	7381	9126.41	٩٧	8104	5690.923
٧٣	7308	6712.238	٩٨	8129	8048.151
٧٤	6749	8430.553	٩٩	8034	9870.914
٧٥	6699	7967.673	١٠٠	7947	10080.8
			١٠١	٧٨٦٠	8607.401

الملحق (٣)

البرنامج الحاسوبي المصمم بلغة ++C لحساب قيم التكهن باستخدام الشبكات العصبية.

```
/* this program read X[N] from void R_inputs()*/
#include<iostream.h>
#include<fstream.h>
#include<math.h>
#include<conio.h>
#include<stdio.h>
#include<stdlib.h>
#include<graphics.h>

unsigned int I , N ;

float E , n ;

long double Vx[40] , Wx[40] , Wy[40] , Wy1[40] , Out[200] ;
long double Ww[40][40] , Ww1[40][40] , D[2][40] , D1[2][40];
long double A , C , d , Norm , Vo ;
void putpixel ( int x , int y , int c){
int i , j ;
for( i =-1;i<=1;++i)
for( j =-1;j<=1;++j)
putpixel ( x+i,y+j,c);
}
long double Sgm(long double Net ){
long double a1,a2,sgm ;

a1 = -Net ;
a2 = exp(a1) ;
sgm = (2./(1+a2))-1 ;
return sgm ;
}
long double SgmD(long double Net ){
long double Dsgm ;

Dsgm = .5*(1+Net)*(1-Net) ;
return Dsgm ;
}
long double Norm_W(long double *W,long double *W1){
long double NW , NW1 = 0 , NormW ;

for(int i = 0; i < N; i++){
NW = W[i] - W1[i] ;
NW1 += (NW * NW);
}
}
```

```

NormW = sqrt(NW1);
return NormW ;
}

void R_Weight(){
int i , j ;
for( i = 0; i < N; i++){
    Wx[i] = ( random(1001) - 500 ) / 500. ;
    Vx[i] = ( random(1001) - 500 ) / 500. ;
    Wy[i] = ( random(1001) - 500 ) / 500. ;
}
Vo = ( random(1001) - 500 ) / 500. ;
for(i = 0 ; i < N ; ++i )
    for(j = 0 ; j < N ; ++j)
        Ww[i][j] = ( random(1001) - 500 ) / 500. ;
}
void main(){
long double X , net , out , Zet , Norm ,
            NormT , MaxE ;
float    NewOut[400] ;
unsigned int i , j , k , MaxOut , MinOut , Ok ,MaxP,Pb[200],Cb[200];
unsigned long Iter ;
FILE *fp ;
int gdriver = DETECT, gmode;

clrscr();
if( ( fp = fopen("out.txt","r") ) == NULL ){
    printf(" Error can not open file OUT.TXT ");
    return ;
}
MaxOut = 0 ;
MinOut = 60000u ;
fscanf(fp,"%d %d %f %f",&I,&N,&E,&n);
if( I >= 1000 )I = 1000 ;
if( N >= 40 )N = 40 ;
for( i = 0 ; i < I ; ++i ){
    fscanf(fp,"%d %d",&j,&j);
    Out[i] = j ;
    if( j > MaxOut ) MaxOut = j ;
    if( j < MinOut ) MinOut = j ;
}
fclose(fp);
MaxOut -= MinOut ;
for( i = 0 ; i < I ; ++i ){
    Out[i] = (Out[i]-MinOut)/MaxOut ;
    Pb[i] = 0 ;Cb[i] = 0 ;
}
initgraph(&gdriver, &gmode, "");
bar(0,0,640,480);
for( i = 0 ; i < I ; i++)PutPixel(i*4,400-Out[i]*400,12);

```

```

R_Weight();
Ok=0;
for( Iter = 1 ;!Ok ;++Iter ){
    if( kbhit())break;
    Ok = 1 ;
    NormT = 0 ;
    MaxE = -1 ;
    for( k = 0 ; k < I ; ++k ){
        X = (float)(k) / I ;
        for( i = 0 ; i < N ; i++)D[0][i] = Sgm( Vx[i] + X * Wx[i] ) ;
        for(i = 0 ; i < N ; ++i ){
            net = 0 ;
            for( j = 0 ; j < N ; ++j)net += D[0][j] * Ww[i][j] ;
            D[1][i] = Sgm( net ) ;
        }
        net = 0 ;
        for( i = 0 ; i < N ; i++)net += D[1][i] * Wy[i] ;
        out = Sgm( net + Vo ) ;
        PutPixel(k*4,Pb[k],Cb[k]);
        Pb[k] = 400-out*400 ;
        Cb[k] = getpixel( k*4,Pb[k]);
        PutPixel(k*4,Pb[k],9);
        Zet = ( Out[k] - out ) * SgmD( out ) ;
        for( i = 0 ; i < N ; i++)
            Wy1[i] = Wy[i] + n * Zet * D[1][i] ;
        Vo = Vo + n * Zet ;
        for( i = 0 ; i < N ; i++)
            D1[1][i] = Zet * Wy[i] * SgmD( D[1][i] ) ;
        for(i = 0 ; i < N ; ++i )
            for( j = 0 ; j < N ; ++j)
                Ww1[i][j] = Ww[i][j] + n * D1[1][i] * D[0][j] ;
        for(i = 0 ; i < N ; ++i ){
            D1[0][i] = 0 ;
            for( j = 0 ; j < N ; ++j)
                D1[0][i] += D1[1][j] * Ww[j][i] * SgmD( D[0][i] ) ;
        }
        for( i = 0 ; i < N ; i++){
            Wx[i] = Wx[i] + n * D1[0][i] * X ;
            Vx[i] = Vx[i] + n * D1[0][i] ;
        }
        Norm = fabs( Out[k] - out );
        if( Norm >= E ) Ok = 0 ;
        if( Norm > MaxE ){
            MaxE = Norm ;
            MaxP = k ;
        }
    }
    for(i = 0 ; i < N ; ++i )
        for( j = 0 ; j < N ; ++j)
            Ww[i][j] = Ww1[i][j] ;
    for( i = 0 ; i < N ; i++){

```

```

        Wy[i] = Wy1[i] ;
    }
    NormT += Norm ;
//    printf(" %d %f \n", k , float(Norm) ) ;

}
NormT /= I ;
if( NormT < .075 )break;
if( !(Iter%100)){
    gotoxy(1,1);printf("
");
    gotoxy(1,1);
    printf(" %ld %f %f %d \n", Iter ,float(NormT) ,(float)(MaxE),MaxP+1) ;
}
}
for( k = 0 ; k < 2*I ; ++k ){
    X = (float)(k) / I ;
    for( i = 0 ; i < N ; i++)D[0][i] = Sgm( Vx[i]+X * Wx[i] ) ;
    for(i = 0 ; i < N ; ++i ){
        net = 0 ;
        for( j = 0 ; j < N ; ++j)net += D[0][j] * Ww[i][j] ;
        D[1][i] = Sgm( net ) ;
    }
    net = 0 ;
    for( i = 0 ; i < N ; i++)net += D[1][i] * Wy[i] ;
    NewOut[k] = Sgm( Vo + net )*MaxOut+MinOut ;
}
fp = fopen("my_out.txt","w");
for( k = 0 ; k < 2*I ; ++k ){
    fprintf(fp,"%d %7.2f\n",k+1 ,NewOut[k]);
}
fclose(fp);
fp = fopen("W_out.txt","w");
for( k = 0 ; k < N ; ++k ){
    fprintf(fp,"%7.5f %7.5f %7.5f \n",(float)Wx[k],(float)Vx[k],(float)Wy[k]);
}
fprintf(fp,"%7.5f \n",(float)Vo);
for(i = 0 ; i < N ; ++i ){
    for( j = 0 ; j < N ; ++j)
        fprintf(fp,"%7.5f ",(float)Ww[i][j]) ;
    fprintf(fp,"\n");
}
for(i = 0 ; i < I ; ++i )
    Out[i] = Out[i]*MaxOut+MinOut ;
double M1 , M2 , m1 , m2 ;
M1 = M2 = 0 ;
for(i = 0 ; i < I ; ++i ){
    M1 += Out[i] ;
    M2 += NewOut[i] ;
}
M1 /= I ; M2 /= I ;

```

```

fprintf(fp,"Mean = %7.5f  %7.5f \n",(float)(M1),(float)(M2)) ;
m1 = m2 = 0 ;
for(i = 0 ; i < I ; ++i ){
    m1 += fabs( Out[i] -M1  ) ;
    m2 += fabs( NewOut[i] -M2);
}
m1 /= I ; m2 /= I ;
fprintf(fp,"MAD = %7.5f  %7.5f \n",(float)(m1),(float)(m2)) ;
m1 = m2 = 0 ;
for(i = 0 ; i < I ; ++i ){
    m1 += ( Out[i] -M1  )*( Out[i] -M1  ) ;
    m2 += ( NewOut[i] -M2)*( NewOut[i] -M2);
}
m1 /= I ; m2 /= I ;
fprintf(fp,"S^2 = %7.5f  %7.5f \n",(float)(m1),(float)(m2)) ;
m1 = sqrt( m1 ) ; m2 = sqrt( m2 ) ;
fprintf(fp,"S.D = %7.5f  %7.5f \n",(float)(m1),(float)(m2)) ;
m1 = 0 ;
for(i = 0 ; i < I ; ++i ){
    m1 += ( Out[i] - NewOut[i] )*( Out[i] - NewOut[i] ) ;
}
m1 /= I ;
m1 = sqrt( m1 ) ;
fprintf(fp,"MSE = %7.5f \n",(float)(m1)) ;

fclose(fp);
}
-

```

ABSTRACT

Forecasting of future behavior of time series is one of the important subjects in statistical science, because of its need in the different areas life, like forecasting of weather state and air temperature, market state and prices, water flow, consumption electrical power. In the recent years there are increase interesting in forecasting, and some new techniques in the field of computer science, like Artificial Neural Networks (ANN), are appeared. These techniques are able for learning and self-adaptation with any model, and don't need assumptions on the natural of time series. On the other side the classical forecasting methods, like Box-Jenkins method, need hard conditions.

Hence, there is a need a comparison between classical methods in forecasting of time series with ANN technique to find which approach main goal for this study.

A raw data about consumption electrical power in Mosul city is used to perform this comparison through the application of the two programms Minitab and Matlab on the statistical analysis, and a program is written in C++ for the ANN. From the practical application it found that ANN give better and more efficient results than classical methods.

**The Use of Neural Networks in
Forecasting of Time Series with
Application on Consumption
of Electrical Power in
Ninavah Governarate**

**A Thesis Submitted to
The Council of the College of
Computer Sciences and Mathematics
University of Mosul
As a partial Fulfillment of the Requirement
for a Degree of Master in
Statistics**

**By
Azza H. Z. Ameen-Bak
(Bs.C. Statistics, 1985)**

**Supervised by
Prof. Dr. Basil Y. Thanoon Al-Khayat**

1426 A.H

200• A.C.