

استخدام نماذج الشبكات العصبية الاصطناعية للتنبؤ والمقارنة

Using Artificial Neural Network Models For Forecasting & Comparison

م. م إيفان علاء ناظم
وزارة التعليم العالي والبحث العلمي
دائرة البحث والتطوير

الخلاصة

تعد منهجية الشبكات العصبية الاصطناعية (ANN) من المواضيع المهمة والجديدة في بناء النماذج والتحليل وتقييم البيانات والتنبؤ والسيطرة عليها بدون الرجوع إلى نموذج أو طريقة إحصائية شائعة تشخيص مسبقاً لسلوك الظاهرة، حيث تتم المعالجة بمحاكاة البيانات للوصول إلى أمثل أنموذج رصين وحصين يمثل الظاهرة تمثيل قريب من الواقع يمكن استخدامه في أغلب الأوقات والحالات، وتم استخدام منهجية بوكس-جنكنز (ARMAX) لغرض المقارنة، واستند البحث على الطاقة المستلمة لبناء نموج حصين للتنبؤ والتحليل والسيطرة بالطاقة المباعة واعتبرت الطاقة المستلمة المولدة من شركة محطات التوليد المصدر الأساسي للمنهجيتين وهي متغيرات خارجية (Exogenous variables)، ويقسم عمل نشاط المبيعات في الشركة العامة لتوزيع كهرباء بغداد إلى ثلاث مراحل:

- ١- حساب الطاقة المباعة (بالكيكا واط).
- ٢- حساب أقيام الطاقة المباعة (بالدينار).
- ٣- النقد المستلم (بالدينار).

Abstract

The Artificial Neural Network methodology is a very important & new subjects that build's the models for Analyzing, Data Evaluation, Forecasting & Controlling without depending on an old model or classic statistic method that describe the behavior of statistic phenomenon, the methodology works by simulating the data to reach a robust optimum model that represent the statistic phenomenon & we can use the model in any time & states, we used the Box-Jenkins (ARMAX) approach for comparing, in this paper depends on the received power to build a robust model for forecasting, analyzing & controlling in the sod power, the received power come from the generation state company & to be considered as Exogenous variables to two methodologies, the sales activity in the General Company of Baghdad Electricity Distribution divides it's work to three stages:

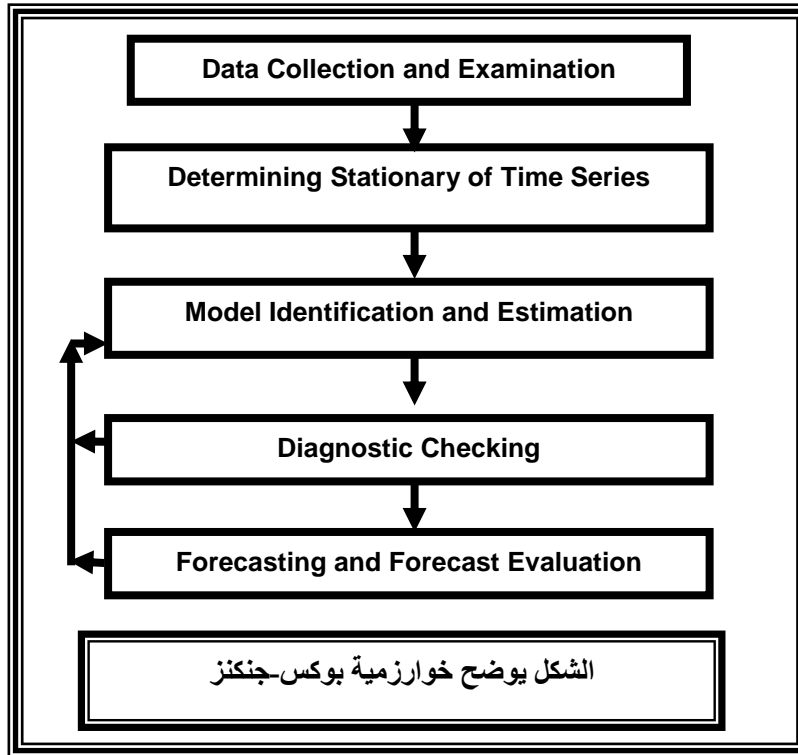
- 1- Account the Sold Power.
- 2- Account the Value of the Sold Power.
- 3- Account the Cash Received.

الجزء النظري / مقدمة

إن علم بحوث العمليات هو تطبيق للطرائق العلمية لحل المشكلات التي تنجم عن العمليات المتضمنة الأنظمة المتكاملة للأفراد والمعدات والمواد الأولية بحيث تحقق المنفعة القصوى لتلك الأنظمة، تم استخدام نماذج الشبكات العصبية الاصطناعية (ANNM) والتي هي جزء من نظرية الشبكات (Network Theory)، حيث إنها تعالج النماذج الخطية واللاخطية بدون الرجوع إلى نماذج مقترحة من قبل، وأصبحت من الشائعة الاستخدام في كثير من مجالات البحث العلمي كالفلك والرياضيات والإحصاء والهندسة والطب وغيرها، واستخدم الباحث منهجية بوكس- جنكنز (ARMA) للمقارنة لأنها تعالج البيانات عن طريق قواعد ثابتة، يعتمد هذا البحث في المقارنة بالمعايير الإحصائية الشائعة والمعتمدة، إن الهدف من البحث هو الحصول على نموذج حصين (Robust) وبالإمكان تحديثه ويكون قادراً على التنبؤ والسيطرة بالطاقة المباعرة التقديرية ليخدم قسم المبيعات للتخطيط بالكمية المطلوبة من الطاقة الكهربائية من محطات التوليد مستقبلاً.

Box-Jenkins (ARMA) Approach

٢- منهجية بوكس- جنكنز (ARMA):



تتكون منهجية بوكس- جنكنز خمس خطوات أساسية^(١)، حيث المخطط جانباً يوضح الخطوات.

١-٢ جمع البيانات واختبارها

ومن الأفضل توفر على الأقل (50) مشاهدة واختبارها من خلال التوزيعات الإحصائية لمعرفة هل إنها تتبع إلى توزيع معين أو إنها ظاهرة لها سلوك خاص يتمثل بالنماذج المستخدمة بواسطة الطرق الإحصائية الشائعة.

٢-٢ فحص إستقرارية السلسلة

تعتبر السلسلة الزمنية مستقرة بالمتوسط إذا كانت متذبذبة حول وسط حسابي ثابت لا يعتمد على الزمن $\{E(X_t)=\mu\}$ ، ومستقرة بالتباين إذا كان تباين السلسلة الزمنية كمية ثابتة خلال الزمن $\{Var(X_t)=\sigma_x^2\}$ ، أما إذا كانت السلسلة الزمنية غير مستقرة أي عدم تحقق أي من الشرطين أنفي الذكر، فمن ملاحظة دالة الارتباط الذاتي لعدد من الإزاحات، نستنتج أن السلسلة الزمنية غير مستقرة بالوسط الحسابي، و لجعل السلسلة الزمنية مستقرة حول وسط حسابي ثابت فيمكن إجراء تعديل الفروق، حيث الفرق من الدرجة (d) يمثل بالمعادلة الآتية:

$$\nabla^d X_t = (1 - B)^d X_t \dots \dots \dots (1)$$

والمعادلة التالية تمثل للجزء الموسمي للسلسلة الزمنية الموسمية:

$$\nabla_s^D X_t = (1 - B^s)^D X_t \dots \dots \dots (2)$$

أما إذا كانت السلسلة الزمنية غير مستقرة بالتباين فيمكن أخذ اللوغاريتم أو أخذ الجذر التربيعي للسلسلة الزمنية أو أي تحويلات لا خطية تعالج عدم الإستقرارية في التباين تلائم السلسلة الزمنية وتجعلها مستقرة.

٣-٢ تشخيص وتقدير الأنموذج: Model Identification and Estimation

إن عملية التشخيص تعتمد على الدلتى الارتباط الذاتي و الارتباط الذاتي الجزئي لتحديد أنموذج (ARIMA) ومن ملاحظة الجدول أدناه يمكن أن نتعرف على آلية التشخيص:

| الأنموذج | دالة الارتباط الذاتي | دالة الارتباط الذاتي الجزئي |
|------------|------------------------|-----------------------------|
| AR (p) | أسي | يقطع بعد p من الإزاحات |
| MA (q) | يقطع بعد q من الإزاحات | أسي |
| ARMA (p,q) | أسي | أسي |

أما تقدير معالم الأنموذج فتوجد عدة طرق تعتمد على معرفة التوزيعات الاحتمالية للسلسلة الزمنية ومن هذه الطرق طريقة الإمكان الأعظم التامة^(١) (Exact Maximum Likelihood) وطريقة الإمكان الأعظم التقريبية (Approximate Maximum Likelihood)، وهناك طرق لا تعتمد على معرفة التوزيعات الاحتمالية للسلسلة الزمنية وهي طريقة المربعات الصغرى (Least Squares).

٤-٢ اختبار الأنموذج المشخص: يبقى النموذج تحت الاختبار حتى يجتاز الاختبارات التالية:

٤-٢-١ اختبار إحصاءة Q: إذا توزعت الأخطاء (Residuals) توزيع (X^2) و بدرجة حرية $(N-p-q)$ ، وكانت القيمة المحسوبة أقل من القيمة الجدولية فهذا مؤشر يعني أن معاملات الارتباط الذاتي غير معنوية أي إن الأخطاء لها سلوك عشوائي وغير منتظم، ومن ذلك نعتبر أن الأنموذج المشخص ملائم، والصيغة العامة المستخدمة هي كالآتي:

$$Q = (N - d) \sum_{k=1}^K \hat{\rho}_k^2 (e) \dots \dots \dots (3)$$

٢-٤-٢ القيم الشاذة

إذا تحولت الأخطاء إلى أخطاء قياسية (Standardized Residuals)، فإن تباين الأخطاء يساوي واحد ($\sigma_e^2=1$)، واعتبار حدي الأعلى والأدنى للأخطاء هو بين (3) و(-3)، وهذا مؤشر يوضح عدد الأخطاء الخارجة عن الحدود، وكذلك مخططي دالة الارتباط الذاتي والذاتي الجزئي.

٢-٥-٢ تنبؤ و تقييم التنبؤ

١-٥-٢ التنبؤ

إذا اجتاز النموذج المشخص الاختبارات السابقة^(١٥)، يصبح بالإمكان استخدام النموذج للتنبؤ بعد تقدير معالمته، وللتنبؤ بالقيم المستقبلية ($t + \tau$) حيث (τ) تمثل الفترات المستقبلية، والصيغة التالية هي الصيغة العامة للتنبؤ:

$$E(X_{t+\tau}) = \hat{X}_\tau = \Phi_1 E(X_{t+\tau-1}) + \Phi_2 E(X_{t+\tau-2}) + \dots + \Phi_{p+d} E(X_{t+\tau-p-d}) - \theta_1 E(e_{t+\tau-1}) - \theta_2 E(e_{t+\tau-2}) - \dots - \theta_q E(e_{t+\tau-q}) + E(e_{t+\tau}) \dots \dots \dots (4)$$

٢-٥-٢ تقييم التنبؤ: في هذه المرحلة يتم تقييم النموذج أو إعادة التشخيص للسلسلة إذا تطلب الأمر وخطأ التنبؤ هو الفرق بين مشاهدات السلسلة الحقيقية والقيم التقديرية ومعادلة الأخطاء هي:

$$e_t = X_t - X_t^F \dots \dots (5)$$

حيث: X_t = المشاهدات الحقيقية، X_t^F = القيمة التقديرية للمشاهدات الحقيقية، e_t = الفرق بين المشاهدات الحقيقية والتقديرية (الأخطاء).

٣- نماذج بوكس- جنكنز: Box-Jenkins (ARMA) Models:

إن نماذج بوكس-جنكنز^(٥) هي امتداد لعدة تجارب لظواهر رياضية وإحصائية، حيث أصبحت من النماذج الشائعة والمستخدمة في بداية السبعينات (1970)، وتستخدم في التحليل والسيطرة والتنبؤ للسلاسل الزمنية.

٢-٣ عمليات الانحدار الذاتي: Autoregressive Processes {AR (p)}

إن عمليات الانحدار الذاتي^(١) هي عبارة عن ارتباط المشاهدات الحالية للسلسلة الزمنية مع مشاهدات سابقة لنفس السلسلة ويرمز إلى نموذج الانحدار الذاتي {AR (P)} حيث (P) يمثل عدد المعالم في النموذج حيث أن نموذج الانحدار الذاتي هو كالاتي:

$$X_t = \zeta + \Phi_1 X_{t-1} + \Phi_2 X_{t-2} + \dots + \Phi_p X_{t-p} + e_t \dots \dots \dots (6)$$

حيث X = مشاهدات السلسلة، ζ = الحد الثابت، Φ = معالم النموذج، p = رتبة عمليات الانحدار الذاتي.

٣-٣ عمليات الأوساط المتحركة: Moving Average Processes {MA (q)}

إن عمليات الأوساط المتحركة^(٦) هي عبارة عن ارتباط مشاهدات السلسلة الزمنية الحالية مع الخطأ السلسلة نفسها لفترات سابقة ويرمز لأنموذج عمليات الأوساط المتحركة {MA(q)} حيث (q) يمثل عدد معالم النموذج حيث أن نموذج الأوساط المتحركة هو كالاتي:

$$X_t = \zeta - e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \dots \dots \dots (7)$$

حيث X = مشاهدات السلسلة، ζ = الحد الثابت، θ = معالم النموذج، q = رتبة الأوساط المتحركة.

٣-٤ عمليات الانحدار الذاتي والأوساط المتحركة:

Autoregressive Moving Average Processes {ARMA (p,q)}

إن عمليات الانحدار الذاتي و الأوساط المتحركة^(٣) هي عبارة عن ارتباط قيم السلسلة الزمنية الحالية مع قيم سابقة للسلسلة نفسها وارتباط قيم السلسلة الزمنية مع خطأ السلسلة نفسها لفترات سابقة، ويرمز للأنموذج {ARMA (p,q)} حيث إن (p,q) هما عدد معالم الأنموذج، وأنموذج الآتي يوضح ذلك:

$$X_t - \Phi_1 X_{t-1} - \Phi_2 X_{t-2} - \dots - \Phi_p X_{t-p} = \dots\dots\dots(8)$$

$$e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q}$$

ويمثل الأنموذج أعلاه الجزء غير الموسمي أو ما يسمى بالجزء المنتظم للسلسلة الزمنية (Non-Seasonal Portion) أو (Regular Portion)، أما أنموذج السلسلة الزمنية الموسمية (Seasonal Portion) فيرمز لها {ARIMA (p,d,q)(P,D,Q)_s} والصيغة العامة للأنموذج هي:

$$\Phi_p (B)\Phi_p^s (B^s) \nabla^d \nabla_s^D X_t = \theta_q (B)\theta_q^s e_t \dots\dots(9)$$

حيث X = مشاهدات السلسلة، θ = معالم الأنموذج، q = رتبة الأوساط المتحركة، p = رتبة عمليات الانحدار الذاتي، s = طول الموسم، D = درجة الفرق للجزء الموسمي، d = درجة الفرق للجزء الغير الموسمي.

٤- أنموذج الانحدار الذاتي والأوساط المتحركة مع متغيرات خارجية

Autoregressive Moving Average with Exogenous Variables (ARMAX):

إن عمليات (ARMA)^(٨) هي متسلسلات عشوائية متكون من المخرجات (Y(t)) والخطأ (e(t))، وقبل بناء أي أنموذج يجب تحديد المتغيرات الخارجية التي تؤثر على السلسلة الزمنية لتوضيح سلوك العملية، وصيغة أنموذج السلاسل الزمنية عندما يتضمن المتغيرات الخارجية (ARMAX)^(٨) هي:

$$AY(t) = Bx(t - k) + Ce(t) \dots\dots\dots(10)$$

حيث:

إن (A) يمثل مركبة السلسلة الزمنية لفترات سابقة التي تتأثر بها، أو بمعنى آخر هو الانحدار الذاتي للسلسلة نفسها.

أما (B) فيمثل الفترات السابقة للمتغيرات الخارجية التي تؤثر على السلسلة الزمنية.

أما (C) فهو عبارة عن الأوساط المتحركة لمركبة الخطأ العشوائي التي تؤخذ بعين الاعتبار أنها تؤثر على السلسلة الزمنية.

والصيغة العامة في حالة أخذ الفرق لعدة فترات لمركبة الخطأ العشوائي التي يرمز لها (ARIMAX) هي^(٢٤):

$$Y(t) = \frac{B}{A} x(t - k) + \frac{Ce(t)}{A\Delta^n} \dots\dots\dots(11)$$

حيث:

(n) تمثل عدد الفترات السابقة التي تؤثر على السلسلة الزمنية (B,C) الفرق الذي يؤخذ للسلسلة لتلك الفترات.

وبالإمكان إضافة متغيرات خارجية أخرى إذا كانت تؤثر على السلسلة الزمنية، ويمكن استخدام السلاسل الزمنية لبناء نماذج لاختية مع متغيرات خارجية، (NARIMAX)^(٨)، وتعرف المتغيرات الخارجية (Exogenous Variables)^(١٤) بأنها متغيرات مستقلة عن ظاهرة السلسلة الزمنية وتعتمد السلسلة الزمنية على القيم الحالية أو القيم السابقة للمتغيرات الخارجية.

٥- الشبكات العصبية الاصطناعية: Artificial Neural networks

إن منهجية الشبكات العصبية الاصطناعية من الطرق الحديثة التي تعالج البيانات والتي أصبح لها رواج ودور كبير في العالم لأنها تحاكي^(١) البيانات بشكل مستمر بالدوال اللاخطية للوصول إلى أنموذج غرضه التحليل، التصنيف، التنبؤ أو أي معالجة أخرى دون اللجوء إلى أنموذج مقترح مسبقاً لهذه البيانات حيث تعتبر الشبكات العصبية الاصطناعية هي حالة ذكية^(٢) من نظرية الشبكات في عملية التعلم والتدريب على البيانات وخرن وبث المعلومات في الشبكة العصبية الاصطناعية.

١-٥ هيكل الشبكة العصبية الاصطناعية Artificial Neural Network Structure

تتكون الشبكة العصبية الاصطناعية (ANN)^(١) من ثلاث مستويات وهي:

- أ- مستوى المدخلات (Input Level): ويحتوي على عدد من العقد التي تمثل عدد المتغيرات المستقلة.
- ب- مستوى المخفي (Hidden Level): قد يكون في الشبكة أكثر من مستوى مخفي واحد و يرتبط مع مستوى المدخلات والمخرجات، والشبكة التي تحتوي على مستوى مخفي واحد تسمى (Single-Layer Network) أما الشبكة التي تحتوي على أكثر من مستوى مخفي واحد فتسمى (Multi-Layer Network).
- ت- مستوى المخرجات (Output Level): هو عبارة عن مخرجات الشبكة العصبية الاصطناعية. ويتضمن كل مستوى من المستويات الثلاثة أنفة الذكر على:
 ١. العقد (Nodes) : هي نقاط الارتباط العصبي بين مستويات الشبكة العصبية.
 ٢. المستوى (Level) : هي مجموعة من العقد التي تستلم المدخلات ولها مخرجات.
 ٣. الأوزان (Weights): توضح الأوزان مدى قوة الارتباط العصبي بين مستويات الشبكة العصبية حيث إن كل عقدة لها وزن يربطها مع المستوى السابق ووزن يربطها مع المستوى اللاحق، وتحتوي الشبكة العصبية على ثلاثة طبقات من الأوزان هي:

- أ- طبقة أوزان مستوى المدخلات والمستوى المخفي Input to Hidden Weight
- ب- طبقة أوزان بين المستويات المخفية.
- ت- طبقة أوزان المستوى المخفي ومستوى المخرجات Hidden to Output Weight

٥-٢ منهجية الانتشار العكسي للخطأ: Error Back-Propagation Approach

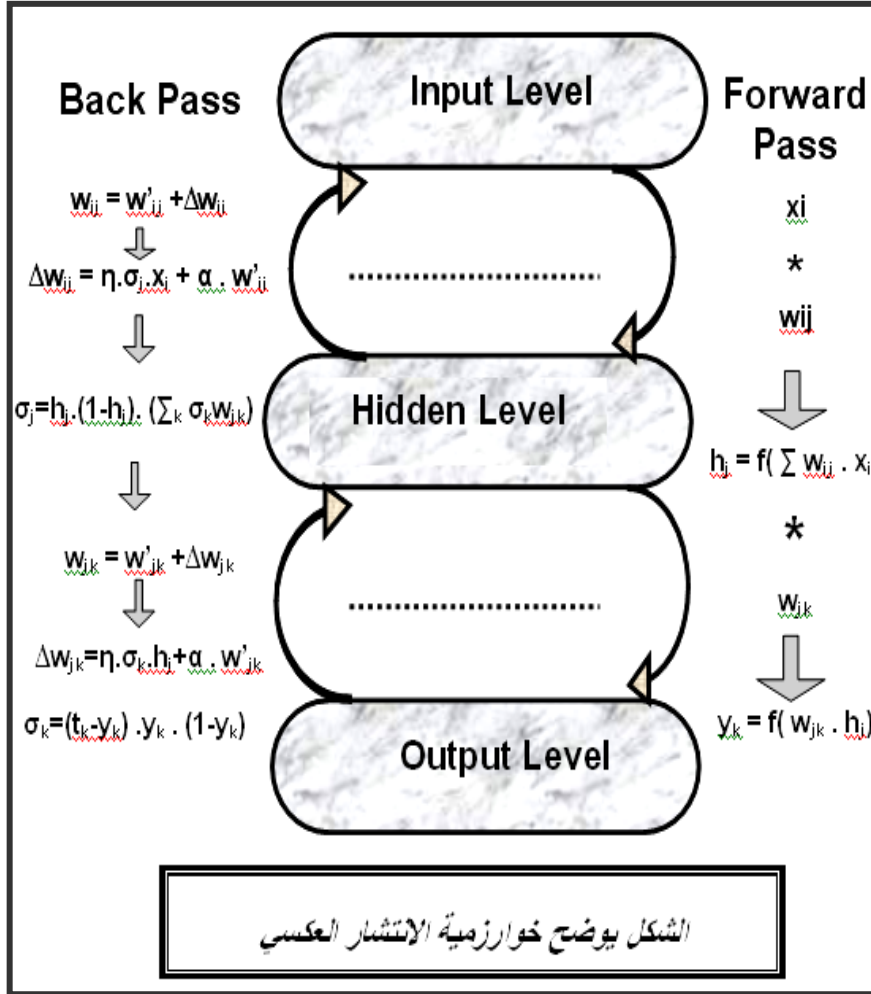
إن مفهوم عمل منهجية الانتشار العكسي للخطأ هو بث البيانات في الشبكة العصبية المقترحة من ناحية (عدد المدخلات وعدد الطبقات المخفية وعقدتها) إلى أن نحصل على المخرجات ومن ثم تعود عكسياً للحصول على مشتقة الخطأ التي تغير الأوزان وبالتالي يقل الخطأ في الشبكة العصبية وتستمر هذه العملية إلى نصل إلى المعايير المطلوبة والتي تناسب الظاهرة وأوزان الشبكة النهائية هي أمثل أوزان، تستخدم هذه الأوزان المثلى لحساب التنبؤات لبيانات جديدة لم يسبق للشبكة العصبية أن تدربت عليها.

٥-٣ خوارزمية الانتشار العكسي للخطأ: Error Back-Propagation Algorithm

- إن خوارزمية الانتشار العكسي للخطأ تمثل بالخطوات التالية^(١):
- أ- توليد قيم ابتدائية (أولية) لأوزان الطبقات من إحدى التوزيعات الإحصائية.
 - ب- تستمر الخطوات الآتية بالتنفيذ إلى أن نصل إلى المعايير المطلوبة والتي تناسب الظاهرة:
 - عملية المرور الأمامي (Forward Pass): هي حساب قيم مخرجات العقد المخفية لاستخدامها في حساب مخرجات الشبكة العصبية.
 - عملية المرور الخلفي (Back Pass): هي لحساب مشتقات الخطأ من عقد لمخرجات والعقد المخفية ولإستخدامها في تحديث أوزان الطبقات.
 - تحديث أوزان طبقات الشبكة العصبية (Updating Weights): إن تحديث أوزان الطبقات يعتمد على وجود المشتقة للخطأ ومعدل التعلم والزخم و مقدار التغيير في الوزن السابق.

واختبار الشبكة: هو إدخال بيانات جديدة لم يسبق أن تدربت عليها الشبكة ومقارنة النتائج مع نتائج البيانات التي تدربت عليها الشبكة.

ت- استخدام الشبكة العصبية لأغراض التنبؤ أو التصنيف أو تقريب الدوال.



والشكل أدناه يوضح عملية حساب تغير الوزن في الشبكة العصبية حسب منهجية الانتشار العكسي للخطأ^(١):
حيث إن :

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
 $\Delta W'_{jk}$: التغير السابق في وزن المستوى المخفي إلى المخرجات
 t_k : قيمة المخرجات للوزن السابق

٥-٤ العوامل المؤثرة على كفاءة الشبكة العصبية الاصطناعية

إن جودة التنبؤات المستقبلية لظاهرة معينة التي يمكن الحصول عليها من الشبكة العصبية تعتمد على مدى كفاءة تدريب الشبكة العصبية على بيانات تاريخية لتلك الظاهرة ومن تلك العوامل:

١. عامل معدل التعلم: يعتبر معدل التعلم من العوامل المؤثرة على عملية تحديث الأوزان في الشبكة العصبية حيث معدل التعلم يحدد حجم الخطوة في عملية تعلم الشبكة العصبية ومقدار تغير الوزن^(٩).
٢. عامل الزخم: هو من العوامل المهمة الذي يجعل عملية التعلم متزنة ويجعل مقدار التغير في الوزن متزن ومستقر نسبياً^(٩).
٣. عامل عدد المتجهات في الشبكة العصبية: إن عدد المتجهات (Exemplars) يؤثر على أداء الشبكة بشكل مباشر، وذلك لأنه يمثل المتغيرات المستقلة، فإذا كان عدد المتجهات مناسباً فإن الشبكة العصبية بإمكانها استخلاص أنموذج يمثل البيانات، أما إذا كانت مدخلات الشبكة على درجة من التعقيد فيجب زيادة عدد المتجهات لكي تتعلم الشبكة على سلوك البيانات^(١).

٤. عامل عدد العقد المخفية: إن عدد العقد المخفية للشبكة العصبية يُحدد من قبل المستخدم وللبدء بتدريب الشبكة العصبية لا بد من إعطاء تقدير أولي لعدد العقد المخفية^(٣)، وإن أفضل طريقة في تحديد عدد العقد المخفية في الشبكة العصبية هو اختيار عدد قليل من العقد المخفية عند البدء بتدريب الشبكة العصبية ثم

ملاحظة النتائج وبعدها نبدأ بزيادة العقد المخفية إلى أن نصل إلى أقل خطأ ممكن وأفضل نتائج في معايير المقارنة، وهذا يعتبر العدد الأمثل للعقد المخفية.


٥. عامل عدد المستويات المخفية: هو من العوامل المهمة في كفاءة تدريب الشبكة العصبية، حيث يبدأ تدريب الشبكة العصبية بمستوى مخفي واحد وتستمر عملية التدريب أو التعلم على صفات بيانات الشبكة العصبية، إلى أن نصل إلى أقل خطأ ممكن^(٣)، وفي حالة عدم تعلم الشبكة العصبية على أغلب صفات البيانات تتم زيادة مستوى مخفي آخر إلى الشبكة العصبية.

الجزء العملي / مقدمة

| النسبة | الصنف |
|--------|----------------|
| %64 | المنزلي |
| %8 | تجاري |
| %1 | الصناعي |
| %15 | الحكومي |
| %12 | الزراعي |
| %100 | الطاقة المباعة |

يتمثل عمل الشركة العامة لتوزيع كهرباء بغداد في استلام الطاقة الكهربائية المولدة من شركة محطات التوليد كاملة ١٠٠% وغير مجزئة، ينقسم نشاط المبيعات إلى خمسة أصناف من المشتركين وهم: (المنزلي والتجاري والصناعي والحكومي والزراعي) ولكل صنف من هذه الأصناف نسبة تقديرية تتوزع على أساسها الطاقة المستلمة والفائدة من تقسيم هذه الأصناف هي لمعرفة كمية استهلاك كل من صنف من هذه الأصناف على حدة، وإن نسبة كل صنف من الأصناف هي موضحة في الجدول جانباً. تبدأ عملية جمع البيانات بدراسة سجلات قراءة المقاييس لمعرفة الطاقة المباعة لكل صنف، حيث كان المتوفر من المشاهدات من سنة (١٩٩٥-٢٠٠٢) حيث تم الاعتماد على هذه الفترة لنمذجة الطاقة المباعة استخدمت السنوات الخمس من (٢٠٠٣-٢٠٠٧) لاختبار النموذج والتي تم تزويد الباحث بها بنسخة إلكترونية، والبيانات حصراً يصعب الحصول عليها من قسم الإحصاء وبحوث العمليات/ الشركة العامة لتوزيع كهرباء بغداد لأهميتها لديهم لأنها بيانات حقيقية واقعية ولا يمكن سحبها ونشرها إلا بشكل رسمي.

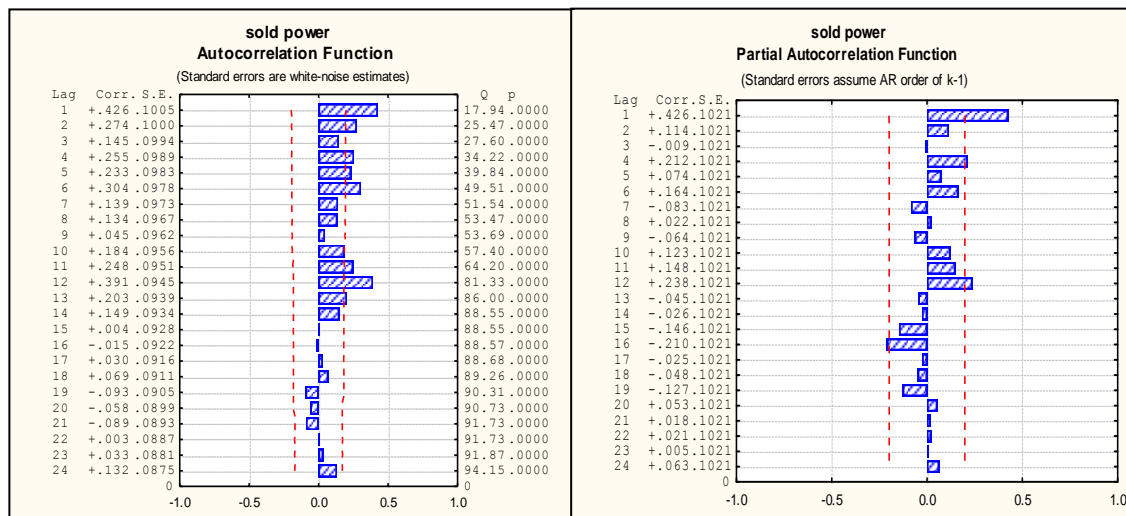
والمخطط أدناه يوضح سلوك ظاهرة الطاقة المباعة للشركة العامة لتوزيع كهرباء بغداد.



٥- نمذجة الطاقة المباعة باستخدام منهجية بوكس-جنكنز (ARMA):

| النموذج الطاقة المباعة | المعالم |
|------------------------|---|
| ARMA(1,0,0)(1,0,0) | Cont.= 693712.5 $\phi = 0.37743$ $\phi_s = 0.44604$ |

إن منهجية بوكس-جنكنز (ARIMA) من المنهجيات الشائعة الاستخدام ذات الكفاءة العالية في النمذجة والتي تعكس سلوك السلسلة الزمنية إن كانت موسمية أو غير موسمية ذات السلوك المنتظم أو شبه المنتظم، حيث تبدأ عملية النمذجة بالتشخيص عن طريق ملاحظة الدلتى الارتباط الذاتي والارتباط الذاتي الجزئي ومن ثم تقدير المعالم لكي نحصل على النموذج المقترح واختباره بالتنبؤ لفترة لم تخضع إلى نمذجة وبذلك نحصل على النموذج والمعالم ومخطط الدلتى الارتباط الذاتي والدلتى الجزئي.



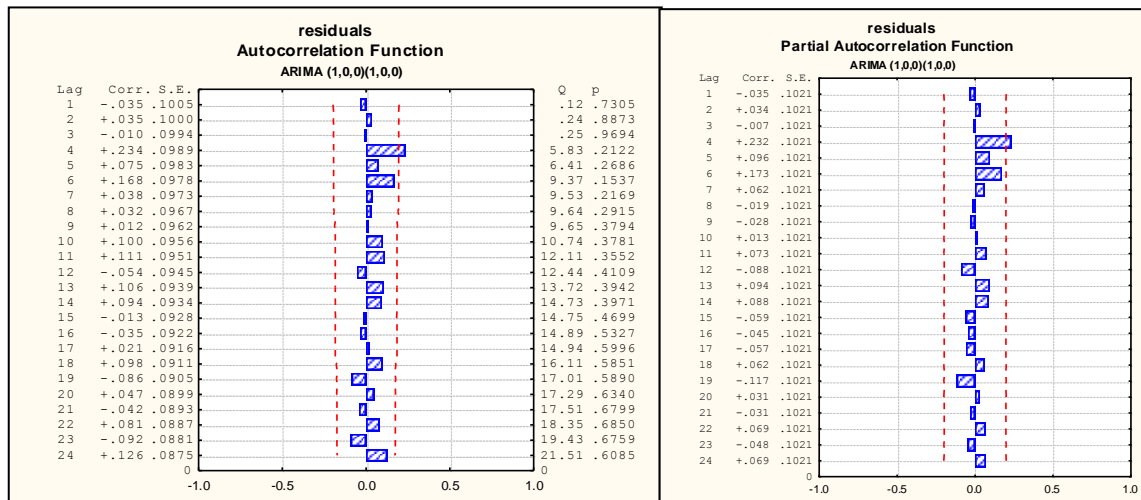
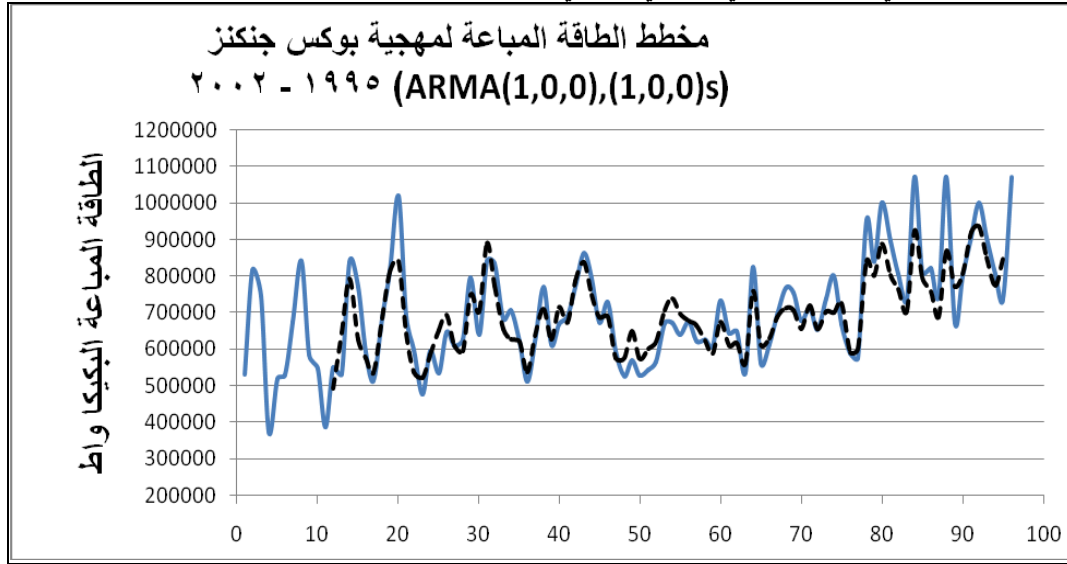
والمعايير المستخدمة لنموذج الطاقة المباعة فهي موضحة في الجدول وكالاتي:

| الطاقة المباعة | ME | MAE | MSE | MAPE % | *GMAPE% |
|--|----------|----------|-----------|----------|----------|
| ARMA(1,0,0) (1,0,0) | 18631.24 | 84862.88 | 135361323 | 12.41816 | 10.61956 |
| الجدول يوضح المعايير لمنهجية بوكس-جنكنز (ARMA) | | | | | |

إن المعايير الإحصائية المستخدمة هي من المعايير الشائعة الاستخدام إلا إن معيار (GMAPE)^(*) هو عبارة عن حاصل قسمة متوسط الخطأ على متوسط البيانات مضروباً في (١٠٠) لنحصل على مؤشر يكون ذو اتزان وعدم تذبذب مع البيانات أو الخطأ، وصيغة متوسط مطلق الخطأ المنوية العام (GMAPE) هي:


$$GMAPE = \left(\frac{MAE}{MData} \right) * 100 \dots \dots (12)$$

إن بداية السلسلة منتظمة نوعاً ما ولكن وبعد السنة ٢٠٠٠ تقريباً بدأت سلسلة الطاقة المستقلة بالارتفاع وهذا يعني زيادة استهلاك الطاقة ومن ملاحظة الطاقة المباعة التقديرية وكأنها هي متماشية مع خط الوسط الحسابي وبهذا أصبح النموذج المستخدم غير ملائماً تماماً للسلسلة، ورسم المقارنة مع الطاقة المباعة التقديرية ومخطط دالتي الارتباط الذاتي والذاتي الجزئي موضحة أدناه.





المخطط الاختباري للطاقة المباعة لمنهجية ARMA ٢٠٠٣-٢٠٠٧



٦- أنموذج الشبكة العصبية الاصطناعية للطاقة المباعة

بعد اختبار الطاقة المباعة في البرنامج الإحصائي (STATISTICA) لمعرفة مدى ارتباط الأشهر فيما بينها لتحديد عدد المدخلات للشبكة أتضح أن المشاهدات مرتبطة بالشهرين السابقين وعلى هذا الأساس تم اختيار المتغيرات الخارجية (X_t, X_{t-1}, X_{t-2}) لكل الأصناف وبعد محاكاة البيانات بشكل مستمر إلى أن نصل إلى المعايير المطلوبة عبر الشبكة العصبية الاصطناعية، وأنموذج الشبكة العصبية للطاقة المباعة لأصناف المبيعات هو موضح على شكل مصفوفات في المعادلات وكالاتي:

$$Y_1 = [w_1 * X'] + b_1$$

$$H = \frac{2}{\left[1 + \exp^{-2 * Y_1} \right] - 1} \dots (13)$$

$$Y_2 = [w_2 * H'] + b_2$$

إن معادلة (Y_1) : تمثل مخرجات المستوى الأول
والمعادلة (H) : مخرجات المستوى المخفي
والمعادلة (Y_2) : مخرجات مستوى المخرجات وهي تعتبر القيم التقديرية لأنموذج الشبكة العصبية الاصطناعية.

حيث إن: W_i : الأوزان بين مستويات الشبكة العصبية.
 b_i : التحيز الذي يضاف إلى المخرجات.

والجدول أدناه يوضح أمثل نماذج لأصناف نشاط المبيعات:

| الصف | No. Inputs X | Fun. Of NET training | hidden nodes | Input-hidden Weight Dim. matrix W_1 | Fun. Of NET training | Hidden-output Weight Dim. matrix W_2 |
|---------|--------------|----------------------|--------------|---------------------------------------|----------------------|--|
| المنزلي | 3 | TANSIG | 7 | 7X3 | PURELIN | 7X1 |
| التجاري | 3 | TANSIG | 7 | 7X3 | PURELIN | 7X1 |
| الزراعي | 3 | TANSIG | 7 | 7X3 | PURELIN | 7X1 |
| الصناعي | 3 | TANSIG | 8 | 8X3 | PURELIN | 8X1 |
| الحكومي | 3 | TANSIG | 8 | 8X3 | PURELIN | 8X1 |

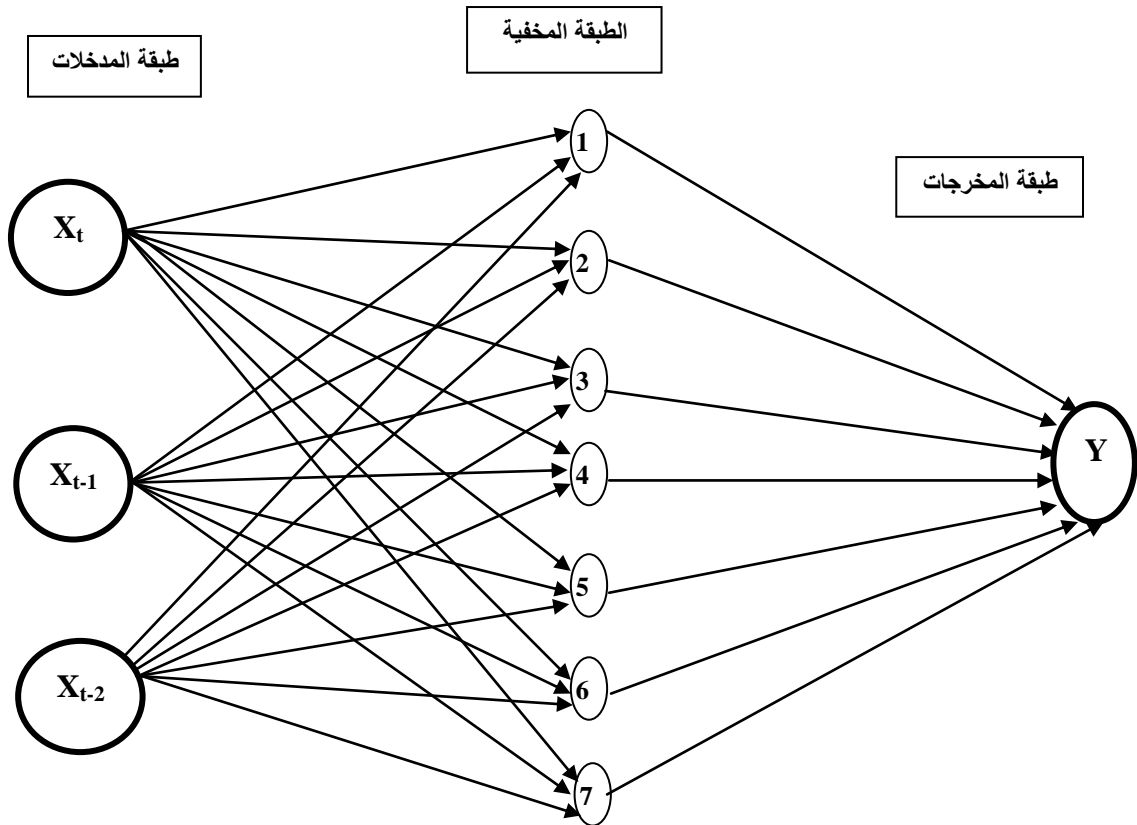
الجدول يوضح نماذج الشبكات العصبية

وكمثال نفهم من الصف المنزلي في الجدول أعلاه أن عدد المدخلات هي (3) وعدد العقد المخفية هي (7) عقد وأبعاد مصفوفة أوزان (Input-hidden) هو (7X3) ودالة التحويل المستخدمة في الشبكة (TANSIG) وأبعاد مصفوفة أوزان (Hidden-output) هو (7X1) ودالة التحويل المستخدمة في الشبكة (PURELIN)، والمخطط أدناه يوضح نموذج الشبكة العصبية لأحد أصناف المبيعات، والمخطط أدناه يوضح نموذج الشبكة العصبية لأحد أصناف نشاط المبيعات.

حيث إن:

١- TANSIG: تمثل دالة التحويل ظل السكمويد الإطنابية.

٢- PURELIN: تمثل دالة التحويل الخطية.




والمعايير المستخدمة لاعتماد نماذج الشبكات العصبية الاصطناعية للطاقة المباعة لأصناف المبيعات هي موضحة في الجدول وكالاتي:

| الصنف | ME | MAE | MSE | MAPE % | GMAPE % |
|---------|--------|--------|---------|---------|---------|
| المنزلي | 1.9 | 312.6 | 1289.2 | 6.159 | 5.4 |
| التجاري | -10.56 | 11.445 | 214.6 | 14.8657 | 14.325 |
| الزراعي | 2.3 | 3.6 | 709.846 | 12.6333 | 15.3 |
| الصناعي | -8.36 | 12.58 | 261.78 | 11.3 | 7.6 |
| الحكومي | 19.269 | 17.265 | 298.46 | 16.738 | 9.4658 |

الجدول يوضح المعايير لنماذج الشبكات العصبية

والمخطط أدناه يوضح رسم سلسلة الطاقة المباعة مع أنموذج الشبكة العصبية الاصطناعية.



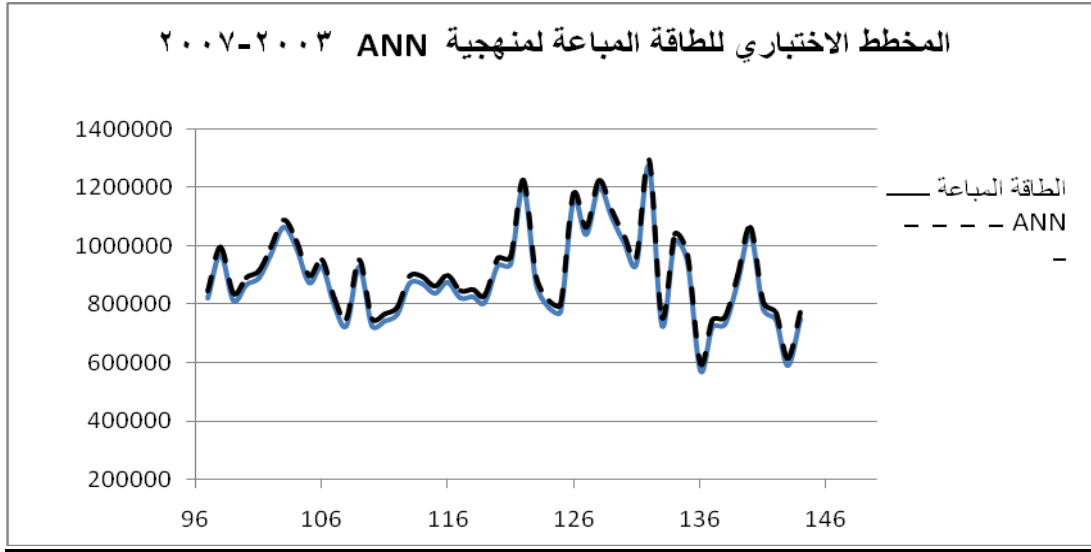
وبعد دمج أصناف نشاط المبيعات من نماذج الشبكات العصبية الاصطناعية (ANNM) نحصل على الطاقة المباعة التقديرية للفترة من ١٩٩٥ إلى ٢٠٠٢ واستخدمت الفترة من ٢٠٠٣-٢٠٠٧ لأغراض الاختبار النموذج، والمخطط أدناه يوضح ما مدى تلائم النموذج مع السلسلة، والجدول أدناه يوضح المقارنة بين نتائج نماذج منهجية بوكس-جنكنز (ARIMA) ونماذج الشبكة العصبية الاصطناعية (ANNM) للطاقة المباعة التقديرية، ويركز الجدول على معيار متوسط مربع الخطأ (MSE) ومعيار متوسط مطلق الخطأ المنوي (MAPE) حيث الفروق بين المنهجيتين كبيرة، علماً إن نشاط المبيعات (الطاقة المباعة) بالإمكان بناء نموذج له بطريقة بوكس-جنكنز يمثلها لكن يكمن عجز الطريقة في أن لو تبدلت مجموعة البيانات أصبح التنبؤ صعب جداً ولفترات قليلة ولكن منهجية الشبكات العصبية الاصطناعية لها القدرة على أن تعامل مع كافة أنواع البيانات (المستقرة وغير المستقرة، الخطية واللاخطية، الرقمية والوصفية للتصنيف).

| Measures | ARIMA Approach | ANN Approach |
|----------|----------------|--------------|
| ME | 18631.24 | 50191.79 |
| MAE | 84862.88 | 51762.77 |
| MSE | 135365 | 3607060103 |
| MAPE | 12.4182 | 7.673735 |
| GMAPE | 10.6196 | 7.178165 |

الجدول يوضح مقارنة بين المنهجية ARIMA وأنموذج الشبكة العصبية الاصطناعية ANNM للطاقة المباعة التقديرية

من نتائج الجدول أعلاه تبين ان منهجية الشبكات العصبية الاصطناعية أعطت معايير أفضل من منهجية بوكس-جنكنز (ARIMA) ومن مقارنة مقياس الرسم البياني أيضاً نلاحظ ان منهجية الشبكات العصبية هي أفضل ويمثل نموذج حصين، والآن بالإمكان استخدام نموذج الشبكة العصبية الاصطناعية (ANNM) للتنبؤ والسيطرة وملاحظة أداء نشاط المبيعات في مرحلة الطاقة المباعة. والمخطط أدناه يوضح فترة التنبؤ من (٢٠٠٣-٢٠٠٧) وهي الفترة التي تم إعطائها من قسم بحوث الإحصاء وبحوث العمليات في كهرباء بغداد،

المخطط يوضح مدى قدرة النموذج لتعقب المشاهدات التي لم يتدرب عليها في منهجية الشبكات العصبية ولم تدخل في نمذجة منهجية بوكس-جنكز.





الاستنتاجات والتوصيات

- ١- إن منهجية الشبكات العصبية الاصطناعية يمكن أن تحل مشاكل اللاخطية مع وجود المتغيرات الخارجية دون اللجوء إلى إدخال البيانات دوال تحويل لغرض جعلها مستقرة.
- ٢- عند المقارنة بين المنهجيتين نلاحظ المعايير الإحصائية متفاوتة نستدل من ذلك أن الشبكات العصبية الاصطناعية هي تأخذ بنظر الاعتبار كافة التغيرات والحالات للظاهرة الإحصائية.
- ٣- نماذج الشبكات العصبية الاصطناعية في الأغلب هي نماذج حصرية لأنها تتدرب على البيانات.
- ٤- نمذجة منظومة تأخذ بنظر الاعتبار مراحل نشاط المبيعات الثلاثة (الطاقة المباعة، قيمة الطاقة المباعة، النقد المستلم) مرتبطة مع بعض، وذلك لاستخدامها لأعراض السيطرة والتنبؤ والتخطيط المستقبلي.
- ٥- نوصي بدراسة مقارنة بين نماذج الشبكات العصبية الاصطناعية والخوارزمية الجينية والبرمجة الضبابية.
- ٦- نوصي في البحوث المستقبلية استخدام منهجية الشبكات العصبية الاصطناعية في عدة مجالات لبناء النماذج أو حلول مشاكل النقل وغيرها.

المصادر

- ١- ناظم، م. م. أيفان علاء، (٢٠٠٣)، "تصميم نظام رياضي ديناميكي لا خطي باستخدام الشبكات العصبية (NARMAX) لأغراض تحليلية وتنبؤية لنشاط المبيعات في شركة كهرباء بغداد"، رسالة ماجستير مقدمة إلى قسم الإحصاء/ كلية الإدارة والاقتصاد/ جامعة بغداد.
- ٢- العبيدي، مروان عبد الحميد، (٢٠٠١)، "استخدام الأساليب الكمية في تصميم مراقبة أداء نشاط المبيعات في الشركة العامة لتوزيع كهرباء بغداد"، رسالة ماجستير مقدمة إلى قسم الإحصاء/ كلية الإدارة والاقتصاد/ جامعة بغداد.
- ٣- قسم المعلوماتية وبحوث العمليات، (٢٠٠٢)، "استخدام الشبكات العصبية الاصطناعية في التنبؤ و تحليل البيانات، الجزء الأول: التصنيف، التوفيق، التوقعات، Classification, Fitting, Prediction"، بحث مقدم إلى الشركة العامة لتوزيع كهرباء بغداد.
- 4- Giles, C. L.⁽¹⁾, Lawrence, S.⁽¹⁾, Tsoi, A. C.⁽²⁾, (August (2001)), "Noisy time Series Prediction Using Recurrent Neural Network and Grammatical Inference", (1) NEC Research Institute, (2) Faculty Informatics, University Of Wellongong, Australia.
- 5- Allende, H.⁽¹⁾, Salas, R.⁽¹⁾, Moraga, C.⁽²⁾, (2001), "Neural Model Identification Using Local Robustness Analysis", (1) Universidad Técnica Federica Santa Mario; Departamento de Infomática; valparaiso-Chile, (2) University Of Dortmund; Dep. Of Computer Science, Germany, Springer-Verlag Berlin Heidelberg 2001.
- 6- Makridakis, S., Wheelwright, S. C. and Hyndman, R. J., (1998), "Forecasting Methods and Application" 3rd. ed., John Wiley-Sons.
- 7- Meyler, A., Kenny, G. and Quinn, T., (December (1998)), " Forecasting Irish Inflation Using (ARIMA) Models", Economic Analysis, Research and Publication Dep. Center Bank of Ireland.
- 8- Tham, M. T., (1996-1999), "Dynamic Models For Control Design", Dep. Of Chemical and Process Engineering, University of Newcastle Upon Tyne, Newcastle Upon Tyne, U.K.
- 9- Rzempoluck, E. J., (1998), "Neural Network Data Analysis Using SimulnetTM ", Springer.
- 10- Luger, G. F., Stubblefield, W. A., (1998), " Artificial Intelligence Structure and Strategies for complex Problem Solving", 3rd. ed., John Wiley-Sons.