

بناء نظام للتنبؤ بطلب الحمل الكهربائي في بغداد

أ.م.د. نشات جاسم محمد

مدير قسم شؤون الحاسبات/الجامعة التقنية الوسطى/بغداد/العراق

Nashaat1974@googlemail.com

هادي طلال جعفر

الكلية التقنية الادارية-بغداد/الجامعة التقنية الوسطى/بغداد/العراق

Haditalal2000@gmail.com

009647705749888

الخلاصة

يقدم هذا البحث كيفية بناء نظام ديناميكي للتنبؤ بطلب الحمل الكهربائي في مدينة بغداد من خلال المقارنة بين الطرق الاحصائية المتمثلة في تحليل السلاسل الزمنية مثل نماذج الانحدار الذاتي المتكامل والمتوسط المتحرك الموسمية (SARIMA) "Seasonal Auto Regressive Integrated Moving Average" , نماذج دالة التحويل (TFM-SISO) "Transfer Function Models" و تقنيات تنقيب البيانات في التنبؤ مثل نموذج الشبكات العصبية الاصطناعية المتعددة الطبقات مع النوافذة المتنقلة MLP-NN-with "sliding windows" , نموذج شبكة الانحدار الذاتي الغير خطي مع مدخل خارجي (Network "Non-Linear Auto Regressive with Exogenous Input Network Model"(NARX). حيث تم دراسة العلاقة الديناميكية بين استهلاك الكهرباء ومتغيراتها الخارجية ذات الصلة (exogenous) مثل درجة الحرارة وتم الاعتماد على بيانات اسبوعية للمدة من 2007/1/1 لغاية 2014/12/31 في مدينة بغداد. ومن خلال تصميم نظام مؤتمت باستخدام لغة (Visual C#, Matlab) اظهرت نتائج المقارنة تفوق نموذج شبكة الانحدار الذاتي الغير خطي مع مدخل خارجي (NARX network) على باقي النماذج المستخدمة بالاعتماد على بعض معايير الخطأ .

الكلمات المفتاحية : SARIMA,TFM-SISO, " MLP-NN-with sliding windows,NARX

Build a system for forecasting the electrical load demand in Baghdad

Assist. Prof. Dr. Nashaat Jasim Mohammed

Director of Computer Affairs Department / Middle Technical University/Baghdad/Iraq

Nashaat1974@googlemail.com

Hadi Talal Jaffar

Technical College Of Management-Baghdad/ Middle Technical University/Baghdad/Iraq

Haditalal2000@gmail.com

009647705749888

Abstract

This research studies how to build a dynamic system for forecasting the electrical demand in Baghdad city by comparing between statistical methods in time series analysis such as Seasonal Auto Regressive Integrated Moving Average model (SARIMA), Transfer Function Model with single input-single (TFM-SISO) output to analyze the data for their dynamic structure and Data Mining techniques in prediction in Artificial Neural Networks (ANN) such as MLP-NN With Sliding Windows Model and the Non-Linear Auto regressive with exogenous input network (NARX Network) , which studies the dynamic relationship between electricity consumption and its relevant variables exogenous variable such as temperature, the Weekly data from January 2007 to December 2014 for all-electric residences in Baghdad are used for this study. Depending on the automated system that built by using (Visual C#, Matlab) The results showed superiority of the non-linear Auto regressive with exogenous input network(NARX Network)) by using some error criterion .

Keywords : SARIMA,TFM-SISO, " MLP-NN-with sliding windows, NARX

المقدمة

التنبؤ في الحمل هو واحد من المهام الرئيسية في عمليات إدارة أنظمة الطاقة. الدافع وراء الحصول على تنبؤات دقيقة يكمن في طبيعة الكهرباء كمادة بسبب ان الكهرباء لا يمكن تخزينها , وهو ما يعني ان تقدير الطلب المستقبلي حاجة ضرورية في إدارة الإنتاج بطريقة معقولة اقتصادياً.

ما زالت شركات الكهرباء الوطنية تعتمد على خبرة مراقبي الشبكة في موضوع التنبؤ . بعض المراقبين يعرفون نظام الطاقة لدرجة تمكنهم من معرفة سلوكه في المستقبل القريب . وفي حالة بناء نظام ديناميكي فإنه يساعد على التنبؤ بشكل مستمر ومؤتمت دون الحاجة او اللجوء إلى دراسة للتنبؤ او استخدام الخوارزميات التقليدية من قبل مراقبي ادارة الطاقة في وزارة الكهرباء .

إن أساليب تحليل السلاسل الزمنية وبناء النماذج الإحصائية يعتبر من المواضيع المهمة في مجال التنبؤ بالاحمال ويتم ذلك من خلال دراسة سلوك الظواهر وتفسيرها عبر فترات زمنية محددة , ومن ثم بناء نماذج تنبؤية للسلاسل الزمنية بالاعتماد على الأساليب الإحصائية وبرزها نماذج (ARIMA) التي تم صياغة منهجيتها من قبل العالمان Box & Jenkins عام 1970 . ان نماذج دالة التحويل العشوائي تلعب دوراً مهماً في تحليل السلاسل الزمنية متعددة المتغيرات بهدف زيادة كفاءة التنبؤ وقد تزايد الاهتمام بموضوع التنبؤ خلال الآونة الأخيرة حيث ظهرت تقنيات حديثة في موضوع تنقيب البيانات Data Mining ومن أهمها نماذج الشبكات العصبية الاصطناعية والتي تتمثل بأنموذج الشبكات العصبية مع النوافذة المتنقلة MLP-NN-with sliding windows " وانموذج شبكة الانحدار الذاتي اللاخطي بمدخل خارجي NARX network . ان هدف البحث يتمثل في تطوير نماذج تنبؤ بالاحمال الكهربائية من خلال دراسة مقارنة بين بعض الطرائق الإحصائية في تحليل السلاسل الزمنية وبين تقنيات تنقيب البيانات اعتماداً على أحدث التقنيات المستخدمة في هذا المجال عالمياً لتساعد الإدارة في عمليات اتخاذ القرار من خلال تصميم نظام حاسوبي كفوء للتنبؤ بطلب الحمل الكهربائي [13,15].

1- الجانب النظري

1-1 التنبؤ في السلاسل الزمنية

الهدف من تحليل السلاسل الزمنية هو التنبؤ بالقيم المستقبلية بالاستناد على بيانات سابقة. واحدة من هذه الطرائق هي الطريقة البسيطة للتنبؤ وهي تلك التي تفترض ان افضل تقدير لقيمة المتغير في الفترة الزمنية القادمة هي قيمته في الوقت الحاضرة, بشكلها المبسط يمكن التعبير عنها بالشكل: $y'_{t+1} = y_t$ حيث y'_{t+1} هي التقدير لقيمة الفترة الزمنية في الفترة القادمة, y_t هي القيمة الحقيقية في الفترة الزمنية الحالية. وبالطبع فان اكثر السلاسل الزمنية هي اكثر تعقيداً وكافة السلاسل الزمنية على الاقل تحتوي على احد المركبات التالية (الاتجاه العام Secular Trend, التغيرات الموسمية The Seasonal, التغيرات الدورية Cyclical Variation, التغيرات العشوائية Irregular Fluctuations).

و تصنف السلاسل الزمنية الى سلاسل زمنية مستقرة Stationary وسلاسل زمنية غير مستقرة Non Stationary ويمكن القول بان السلسلة مستقرة اذا كانت خصائص السلسلة (الوسط الحسابي , التباين , التباين الذاتي المشترك , ... الخ) كلها ثابتة ولا تتغير مع الوقت $f(x; t) = f(x; t + T)$, يمكن تحويل السلاسل الزمنية الى سلسل مستقرة بعدد من الطرق وأهمها (تعديل الفروق Differencing the series) ان الغرض من تعديل الفروق

الأول والثاني هو لتحقيق الاستقرارية للسلسلة الزمنية وبشكل عام اذا اخذنا dth-order للاختلاف وباستخدام عملية الارتداد الزمني Operator B للمعادلة (1) نكتب الانموذج بهذه الحالة :

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

حيث ان d تمثل مقدار الفرق الذي يحسب للبيانات ليجعلها مستقرة واغلب الاحيان تتراوح قيمته بين d=1,2 , اما بالنسبة للفروق الموسمية من الدرجة (D) فان الصيغة العامة :-

$$\nabla_S^D X_t = (1 - B^S)^D X_t \dots \dots \dots (2)$$

ولاختبار استقرارية السلسلة الزمنية يتم اعتماد اختبار جذر الوحدة لديكي وفولر Augmented Dickey-Fuller

[6,8] Unit Root Tests

2-1 نماذج السلاسل الزمنية Time series models

1-2-1 نماذج السلاسل الزمنية اللاموسمية non-seasonal الشائعة

1-1-2-1 انموذج الانحدار الذاتي والايوساط المتحركة

Auto Regressive Moving Average ARMA(p,q)

هو عبارة عن ارتباط قيم السلسلة الزمنية الحالية مع القيم السابقة للسلسلة نفسها وارتباط قيم السلسلة مع خطأ السلسلة نفسها لمدة سابقة والصيغة العامة لنموذج كالاتي:

$$X_t = \varphi_1 X_{t-1} - \varphi_2 X_{t-2} - \dots - \varphi_p X_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_p \varepsilon_{t-q} \dots \dots \dots (3)$$

2-1-2-1 انموذج الانحدار الذاتي المتكامل والايوساط المتحركة

Auto Regressive Integrated Moving Average ARIMA (p,d,q)

يشابه هذا الانموذج الانحدار الذاتي والايوساط المتحركة الذي تم ذكره لكن يختلف بانه يتعامل مع السلاسل الزمنية غير المستقرة باخذ الفرق d وبعد اخذ هذا الفرق تتم اضافة Integrated الى اسم الانموذج ويرمز له ARIMA(p,d,q) والصيغة العامة للانموذج :-

$$\nabla_d X_t = \varphi_1 \nabla_d X_{t-1} - \varphi_2 \nabla_d X_{t-2} - \dots - \varphi_p \nabla_d X_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \dots \dots \dots (4)$$

حيث d هي عدد مرات الفروق التي يتم اخذها للسلسلة حتى تحقق الاستقرارية [3,4,6,8]

2-2-1 نماذج السلاسل الزمنية الموسمية

1-2-2-1 انموذج الانحدار الذاتي المتكامل والايوساط المتحركة الموسمية

Seasonal Auto Regressive Integrated Moving Average

تفسر هذه النماذج الى العوامل الغير الموسمية والموسمية معا في انموذج مضاعف (multiplicative model)

ويرمز الى الانموذج $ARIMA(p, d, q) \times (P, D, Q)^S$, حيث :

p تمثل رتبة الانحدار الذاتي الغير الموسمية

d تمثل رتبة الفروق الغير الموسمية

q تمثل رتبة الاوساط المتحركة غير الموسمية

P تمثل رتبة الانحدار الذاتي الموسمية

D تمثل رتبة الفروق الموسمية

Q تمثل رتبة الاوساط المتحركة الموسمية

S تمثل عدد المدة لكل موسم .

لتسهيل معادلة الانموذج وباستخدام عامل الارتداد الخلفي Backshift operator تكون معادلة الانموذج بدون اخذ الفروق [3,4,6,8].-

$$\Phi(B^S)\varphi(B)(xt) = \theta(B^S)\theta(B)\varepsilon_t \dots \dots \dots (5)$$

1-1-2-2-1 مراحل بناء الانموذج حسب منهجية بوكس جينكس

المرحلة الاولى : التحقق من استقرارية السلسلة الزمنية Stationary Check :- فحص استقرارية السلسلة الزمنية , الاتجاه العام , التغيرات الموسمية برسم مخطط زمني للسلسلة الزمنية ومخطط لكلا من دالة الارتباط الذاتي (Auto-Correlation Function) ودالة الارتباط الذاتي الجزئي (Partial Correlation Function) او عن طريق الاختبار الاحصائي جذر الوحدة لديكي وفولر Augmented Dickey-Fuller Unit Root Tests واذا كانت السلسلة غير مستقرة يطبق تعديل الفروق للحصول على الاستقرارية [4,9].

المرحلة الثانية : تشخيص الانموذج الذي يلائم البيانات Identification :- تحديد درجة الانموذج من خلال فحص عناصر الانحدار الذاتي والمتوسط المتحرك وكذلك للموسمية في الانموذج من خلال رسم مخطط لدالتي الارتباط الذاتي والارتباط الذاتي الجزئي والجدول ادناه يوضح سلوك الدالتين :-

جدول (1) : يوضح سلوك دالتي الارتباط الذاتي والارتباط الذاتي الجزئي

الانموذج	دالة الارتباط الذاتي	دالة الارتباط الذاتي الجزئي
AR(p)	تناقص اسي	يقطع بعد p من الازاحات
SAR(P)	تناقص اسي	يقطع بعد P من الازاحات
MA(q)	يقطع بعد q من الازاحات	تناقص اسي
SMA(Q)	يقطع بعد Q من الازاحات	تناقص اسي
ARMA(p,q)	تناقص اسي	تناقص اسي
SARMA(P,Q)	تناقص اسي	تناقص اسي

او عن طريق استخدام بعض المعايير الاحصائية (AIC,BIC,MSE,MAPE, RMSE) [4,9,8].

المرحلة الثالثة : تقدير معاملات الانموذج المشخص Estimation :- بعد تشخيص الانموذج الذي يلائم البيانات يتم تقدير معلمته بحساب قيم المعاملات باستخدام طريقة الامكان الاعظم التقريبية Maximum Likelihood method(EML) Approximate [4,9].

المرحلة الرابعة : اختبار ملائمة الانموذج Diagnostic Checking :- اختبار الانموذج المقدر , عن طريقة اعتماد اختبار سلسلة البواقي (Residuals) حيث يتم حساب دالة الارتباط الذاتي لسلسلة البواقي , فاذا كانت معاملات دالة الارتباط الذاتي للبواقي واقعة ضمن مستوى ثقة معين فهذا يعني بان سلسلة البواقي عشوائية وبالتالي الانموذج المشخص يمكن القول بانه ملائمة وايضا يمكن استخدام اختبار (Ljung-Box) لمعرفة ملائمة الانموذج .

في حالة اذا كانت الانموذج غير ملائمة وسلسلة البواقي مترابطة فيجب الرجوع الى مرحلة تشخيص الانموذج الذي يلائم البيانات وبناء انموذج اخر [4,9].

المرحلة الخامسة : التنبؤ **Forecasting** :- بعد الحصول على الانموذج المشخص والملائم لتمثيل بيانات السلسلة الزمنية فان هذا الانموذج يستخدم للتنبؤ بالقيم المستقبلية للسلسلة الزمنية [4,9].

3-1 نماذج دالة التحويل Transfer Function Model

ان نماذج دالة التحويل تشتمل على مواصفات نماذج ARIMA بمتغير واحد , ومن الجدير بالذكر ان نماذج (TFM) ما زالت تعاني من صعوبات كثيرة وبالاخص مرحلة التشخيص اضافة الى مرحلتي التقدير والاختبار بسبب زيادة عدد معلمات الانموذج [2,8].

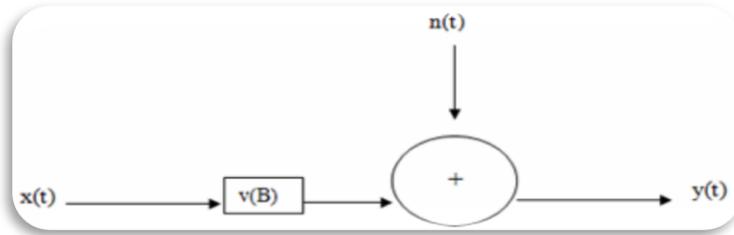
1-3-1 دالة التحويل بمدخلات احادية ومخرجات احادية

Single Input - Single Output Transfer Function (SISO)

افتراض ان $x(t)$ و $y(t)$ تمثلان سلسلتين مستقرتين (Stationary) في منظومة (SISO) فان هاتين السلسلتين ترتبطان من خلال مرشح خطي هو:-

$$y(t) = v(B)x(t) + n(t) \dots \dots \dots (6)$$

حيث ان $v(B) = \sum_{j=-\infty}^{\infty} v_j B^j$ تمثل دالة التحويل وان $n(t)$ تمثل سلسلة الاخطاء العشوائية وهي مستقلة عن السلسلة $x(t)$ وان المعاملات في الانموذج تدعى باوزان استجابة الدفع Impulse response weights وان $x(t)$ تمثل سلسلة المدخلات و $y(t)$ تمثل سلسلة المخرجات والشكل (1) يوضح منظومة دالة التحويل احادية المدخلات - احادية المخرجات [2,6,8].



شكل (1) يوضح منظومة دالة التحويل احادية المدخلات - احادية المخرجات

2-3-1 نماذج دالة التحويل العشوائي Transfer Function - Noise Models

1-2-3-1 انموذج دالة التحويل احادية المدخلات احادية المخرجات SISO TFM

حالة الانموذج بمخرجات احادية فان هذا يتطلب معادلة واحدة لوصفها وعند ذلك يدعى الانموذج بانموذج دالة التحويل بمعادلة احادية. ان انموذج التحويل لمعادلة احادية من الممكن ان يحتوي على اكثر من متغير مدخلات فعلى فرض ان المدخلات والمخرجات تمثلان سلاسل زمنية مستقرة فان الشكل العام لانموذج (SISO) :-

$$y(t) = \frac{\omega_s(B)}{\delta_r(B)} B^b x(t) + \frac{\theta B}{\phi B} \alpha_t \dots \dots \dots (7)$$

اذ ان :

$$\begin{aligned} \delta_r(B) &= \delta - \delta_1 B - \delta_2 B^2 \dots \dots \dots - \delta_r B^r \\ \omega_s(B) &= \omega_0 - \omega_1 B - \omega_2 B^2 \dots \dots \dots - \omega_s B^s \\ B^b x(t) &= x(t - b) \end{aligned}$$

$$\varphi(B) = 1 - \varphi_1 B - \dots - \varphi_p B^p$$

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

حيث ان :- $\delta_r(B)$ هو متعدد الحدود لمقام الدالة و $\omega_s(B)$ هو متعدد الحدود لبسط الدالة و $\phi(B)$ هو معامل الانحدار الخطي AR و $\theta(B)$ هو معامل المتوسط المتحرك MA [6,8,9].

1-1-2-3-1 مراحل بناء انموذج SISO TFM

المرحلة الاولى : تشخيص الانموذج Model Identification

ان هذه المرحلة تتضمن تشخيص دالة التحويل للانموذج , وفيما يخص الدالة المتمثلة بسلسلة المدخلات $x(t)$ وسلسلة المخرجات $y(t)$ فان المرحلة تشمل النقاط التالية [2,6,8] :-

1- تهيئة سلسلتي المدخلات والمخرجات Preparation of Input and Output Series :- يتم فحص استقرارية لسلسلة المدخلات , الاتجاه العام , الموسمية فعندما تكون السلسلة غير مستقرة بالتباين فينبغي اخذ تعديل الفروق من الرتبة (d) فضلا عن ازالة الاثر الموسمي عندما تحتوي السلسلة الزمنية على المركبة الموسمية , فعليه يبغي اخذ الفرق نفسه لسلسلة المخرجات وذلك لان دالة التحويل تنقل سلسلة المدخلات الى المخرجات . وبذلك حيث :-

$$x(t) = (1 - B)^d X(t) \dots \dots \dots (8)$$

$$y(t) = (1 - B)^d Y(t) \dots \dots \dots (9)$$

2- تنقية سلسلة المدخلات Prewhitening Input Series :- لاجل ان تكون دالة التحويل ذات طبيعة واضحة بحيث يمكن دراسة كافة خصائصها , فانه من الضروري ان يكون نظام المدخلات ابسط ما يمكن لكي تتم السيطرة على المدخلات وكذلك المخرجات المقابلة لها , وعليه يبغي تنقية سلسلة المدخلات لتحويلها الى سلسلة بواقي (سلسلة عشوائية تماما) .

3- تنقية سلسلة المخرجات Prewhitening Input Series :- كما ذكر في فقرة تهيئة سلسلتي المدخلات والمخرجات بان دالة التحويل تقوم بنقل المدخلات $x(t)$ الى المخرجات $y(t)$ فعليه ان الاسلوب المطبق في تنقية سلسلة المدخلات $x(t)$ يتم تطبيقه ايضا لسلسلة المخرجات $y(t)$.

4- احتساب الارتباط المتقاطع لسلسلتي المدخلات والمخرجات النقية

Computing Cross Correlation For Prewhitening Input and Output Series

يعد الارتباط المتقاطع الاداة المهمة في تشخيص انموذج دالة التحويل والصيغة العامة له :-

$$\hat{\rho}_{\alpha\beta}(k) = \frac{\hat{\gamma}_{\alpha\beta}(k)}{S_{\alpha}S_{\beta}}, k = 0, \pm 1, \pm 2, \dots \dots \dots (10)$$

اذ ان $S_{\alpha}S_{\beta}$ تمثل الانحرافات المعيارية لـ $\alpha(t)$ و $\beta(t)$ على التوالي.

و $\hat{\gamma}_{\alpha\beta}(k)$ تمثل دالة التباين المتقاطع بين السلسلتين $\alpha(t)$ و $\beta(t)$.

5- تقدير اوزان دالة استجابة الدافع Estimation of Impulse Response Function Weights :- يمكن

الحصول على التقديرات المباشرة لاوزان استجابة الدافع لانموذج دالة التحويل (SISO) باستخدام المعادلة التالية :-

$$v_k = \frac{\hat{\rho}_{\alpha\beta}(k)S_{\beta}}{S_{\alpha}} \dots \dots \dots (11)$$

6- تحديد قيم (r,s,b) لدالة التحويل Specifying (r,s,b) values for TF :- تعتبر هذه المرحلة من المهام الرئيسية في بناء نموذج دالة التحويل حيث ان هذه المهمة غير واضحة تطبيقيا رغم ان المؤشرات اللازمة للتشخيص تشير الى ان قيمة (r) تمثل درجة الدالة $\delta_r(B)$ وان (s) تمثل درجة الدالة $\omega_s(B)$ وكذلك (b) تمثل فترة التأخير بمعتبر المدخلات والتي تكون هي الايسر في تحديد قيمة الرتبة في عملية التشخيص لكونها تمثل ايضا قيمة الازاحة عند اول ارتباط متقاطع معنوي يختلف عن الصفر بين سلسلة المدخلات $\alpha(t)$ والمخرجات $\beta(t)$ وان قيمة (r) تحدد بواسطة النمط الذي تاخذه اوزان استجابة الدافع وان قيمة (s) تحدد بواسطة النمط الذي عنده تاخذه اوزان استجابة الدافع بالتناقص وبشكل عام فقد ذكر (Box and Jenkins 1976) بان قيمة كل من (r) و (s) لا تتجاوز عن (2).

7- ايجاد سلسلة الاخطاء $n(t)$ للانموذج الاولي Find Noise Series For The Preliminary Model :- تحسب التقديرات لسلسلة الاخطاء في الانموذج (SISO) وذلك باستخدام تقديرات الازان (vj) لدالة التحويل $V(b)$. حيث تحسب حسب الصيغة الاتية :-

$$n(t) = y(t) - \frac{\omega_s(B)}{\delta_r(B)} x(t-b) \dots\dots\dots (12)$$

حيث يمكن ايجاد التقديرات الاولية لمعاملات انموذج (SISO) وذلك باستخدام المعادلة :-

$$\begin{aligned} v_j &= 0, & j < b \\ v_j &= \delta_1 v_{j-1} + \dots + \delta_r v_{j-r} + \omega_0 \dots\dots, & j = b \\ v_j &= \delta_1 v_{j-1} + \dots + \delta_r v_{j-r} + \omega_{j-b} \dots\dots, & j = b+1, \dots, b+s, \dots \\ v_j &= \delta_1 v_{j-1} + \dots + \delta_r v_{j-r} \dots\dots, & j > b+s \dots\dots\dots (13) \end{aligned}$$

والتي تضم اوزان استجابة الدافع مع الدوال $\delta(B)$ و $\omega(B)$ ولتوضيح ذلك نفرض ان دالة التحويل (SISO) تم تشخيصها بالرتبة $(r,s,b) = (1,1,2)$ فان اوزان استجابة الدافع تكون :

$$\begin{aligned} v_{01} &= 0 \\ v_{11} &= 0 \\ v_{21} &= \delta_{11} v_{21} - \omega_{01} \\ v_{31} &= \delta_{11} v_{21} - \omega_{11} \\ v_{41} &= \delta_{11} v_{31} \end{aligned}$$

وبعد احتساب تقديرات اوزان استجابة الدافع في ايجاد التقدير الاولي لمعاملات دالة التحويل يتم التعويض كما مبين ادناه :-

$$\begin{aligned} \omega_{01} &= v_{21} \\ \delta_{11} &= v_{41} / v_{31} \\ \omega_{11} &= (v_{21} v_{41} - v_{31}^2) / v_{31} \end{aligned}$$

وبالتالي يتم التوصل الى المقدرات الاولية لدالة التحويل .

8- تشخيص سلسلة الاخطاء $n(t)$ بالانموذج $ARIMA(p_n, 0, q_n)$:- ان قيم سلسلة الاخطاء التي تم حسابها بالمعادلة 13 يتم تحليلها ووصفها بالانموذج ARIMA او SARIMA اذا كان المركب موسمي حيث يتم تحديد رتبة الانموذج من خلال رسم مخطط لدالتي الارتباط الذاتي والارتباط الذاتي الجزئي والجدول (1) يوضح سلوك الدالتين او عن طريق استخدام بعض المعايير الاحصائية (AIC,BIC,MSE,MAPE, RMSE).

المرحلة الثانية : تقدير الانموذج النهائي Final Estimation of the model :- بعد تشخيص انموذج سلسلة الاخطاء الذي يلائم البيانات يتم تقدير معلمته بحساب قيم المعاملات باستخدام طريقة الامكان الاعظم التقريبية [2,8]

.Maximum Likelihood method(EML) Approximate

المرحلة الثالثة : اختبار ملائمة الانموذج **Diagnostic Check** :- اختبار الانموذج المقدر , عن طريقة اعتماد اختبار سلسلة البواقي (Residuals) النهائية حيث يتم حساب دالة الارتباط الذاتي لها , حيث يجب ان تكون السلسلة عشوائية وغير مترابطة حتى يمكن القول بانه ملائما [2,6,8].

المرحلة الرابعة : التنبؤ **Forecasting** :- في هذه المرحلة يتم استخدام الانموذج للتنبؤ من خلال تقديرات قيم سلسلة المخرجات وتقديرات قيم سلسلة المدخلات [6,8].

4-1 نماذج الشبكات العصبية الاصطناعية Artificial Neural Networks Models

1-4-1 مفاهيم اساسية للشبكات العصبية الاصطناعية Basic Concepts of ANN

الشبكات العصبية الاصطناعية تستخدم بشكل واسع في منهجية تحديد الانماط (pattern-recognition) لتعلم الالة . الشبكات العصبية الاصطناعية هي محاكاة الشبكة العصبية البيولوجية (للانسان) التي تتألف من العديد من الخلايا المترابطة ومع ذلك فهي تستفيد من مجموعة محددة جدا من المفاهيم من نظيره البيولوجي . ويمكن ان تكون طبقة واحدة او اكثر من الخلايا العصبية . يمكن للخلايا ان تكون مرتبطة ارتباطا كاملا او جزئيا . كل اتصال بين خليتين (عقدتين) لها وزنها , سيتم التعديل على هذه الاوزان اعتمادا على الفروقات بين المخرجات الحقيقية والمتوقعة . بسبب النمط الغير خطي للشبكات العصبية الاصطناعية يمكن استخدامها في الكثير من تطبيقات الاعمال . وعملية التعلم للشبكات العصبية الاصطناعية (ANN) تكمن في ثلاث خطوات مستمرة :-

1- حساب مخرجات مؤقتة .

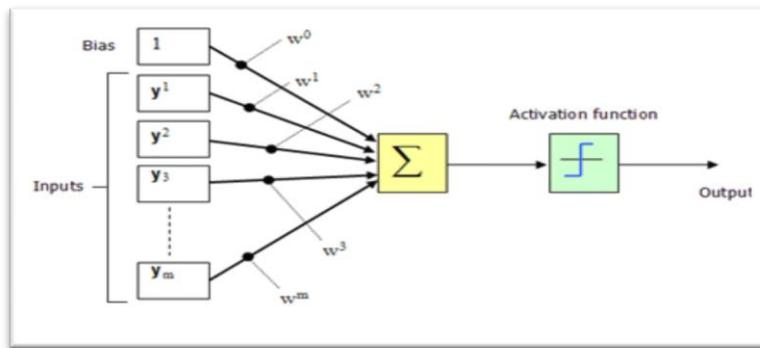
2- مقارنة المخرجات مع الاهداف المطلوبة .

3- ضبط الاوزان وتكرار العملية .

تستقبل الخلية العصبية الصناعية عناصر الادخال (المعلومات) ويتم ضرب كل عنصر بالوزن المرافق له W_i وبعد ضرب جميع عناصر الادخال بالاوزان المرافقة لها يتم جمعها في خلية الجمع كما موضح :-

$$Net = Y_1W_1 + Y_2W_2 + \dots + Y_nW_n \dots \dots \dots (14)$$

ثم يتم ادخال ومعالجة الـ Net في تابع التنشيط (Activation) حيث ان R تمثل $Activation Function$ والتي تكون خطية او غير خطية كما في الشكل [7,10] (2) :-



شكل رقم (2) يوضح مكونات الخلية العصبية الاصطناعية

2-4-1 دالة التنشيط (التحويل) Activation Function

تعرف ايضا بدالة التحويل *Transfer function* لانها تقوم بتحويل المدخلات عبر تفاعلها مع الاوزان وقد تكون الدالة خطية او غير خطية حسب الاستخدام ومنها الدالة اللوجستية (*log-sigmoid function*) والدالة الخطية (*The linear function*) وغيرها [7,10,12].

3-4-1 الشبكات العصبية المتعددة الطبقات Multi-layer networks

تحتوي هذه الشبكة على اكثر من طبقة مخفية (*Hidden Layer*) بحيث كل طبقة مخفية تحتوي على عدد من العقد المخفية (*Hidden Nodes*) وتتألف من ثلاث مستويات [1,7] :-

المستوى الاول : مستوى المدخلات Input Level :- ويحتوي على عدد المدخلات المطلوب معالجتها وعندما تكون وحدات الادخال تمثل ازاحات المتغير المعتمد (*Lags*) حسب مفهوم السلاسل الزمنية فان نموذج الشبكة العصبية سيكون مشابه الى نموذج الاحدار الذاتي الغير خطي *Non-linear Autoregressive Model*.

المستوى الثاني : المستوى المخفي Hidden level :- وهو ثاني مستوى وقد يكون من طبقة مخفية واحدة او اكثر والتي تحتوي على عدد من العقد المخفية كل عقد لها وزن يربطها مع المستوى السابق (المدخلات) ووزن يربطها مع المستوى اللاحق (المخرجات) .

المستوى الثالث : مستوى المخرجات Output Level :- وهو اخر مستوى من الشبكة العصبية ويمثل مخرجات الشبكة حيث تقارن مع القيمة الحقيقية في عملية التدريب *Training*.

4-4-1 خوارزمية التعلم The Learning Algorithm

1-4-4-1 خوارزمية الانتشار العكسي Back Propagation Algorithm

ان تعليم *BPN* خلال تكرار التعليم (*Training Epoch*) . ربما سنذهب بعدد من التكرارات *Epochs* قبل ان تتعلم الشبكة بشكل كامل حتى تستطيع التعامل مع جميع البيانات التي جهزت لها وفي النهاية النتيجة ستكون مرضية , وتكرار التدريب (*Training Epoch*) موضحة ادناه : لكل مدخل يدخل في تدريب البيانات [1,7,5] :-

- تغذية مدخلات ادخال البيانات (*feed forward*)
- تهيئة الاوزان (*Initialized weights*)
- تحقق من المخرجات مقابل القيمة المطلوبة (الحقيقية) وحسب الخطأ (*Back-Propagate*) وحيث عملية الانتشار العكسية تحتوي على :-

1- حساب تدرجات الاخطاء *Error Gradients* 2- تحديث الاوزان .

5-4-1 نماذج الشبكات العصبية

1- نماذج الشبكات العصبية الثابتة **Static neural networks models** :- مثل الشبكات العصبية المتعددة الطبقات امامية التغذية ولكن بدون تغذية عكسية حيث المخرجات تحسب مباشرة اعتمادة على ارتباطاتها مع مدخلات التغذية الامامية وتكون استجابة هذه الشبكة في اي مرحلة زمنية تعتمد فقط على قيمة تسلسل المدخلات في المرحلة الزمنية نفسها اي تتدفق باتجاه واحد من المدخلات الى المخرجات.

2- نماذج الشبكات العصبية الديناميكية **Dynamic Neural Networks Models** :- مخرجات هذه الشبكة تعتمد على القيم الحالية والسابقة للمدخلات و المخرجات او على هيكل الشبكة حيث تكون استجابة هذه الشبكة في اي زمن

معطى تعتمد ليس على فقط القيمة الحالية لكن على القيم السابقة لسلسلة المدخلات. و يمكن ان تصنف الشبكات العصبية الديناميكية الى العديد من الشبكات اهمها

أ- الشبكات العصبية - تاخير الزمني (TDNN) **Time Delay Neural Networks**

ب- الشبكات العصبية مع النوافذة المتحركة (MLP With Sliding Windows)

ج- الشبكات العصبية الارجاعية **Recurrent Neural Networks** :- هي شبكات عصبية بارتيباط واحد او اكثر من التغذية العكسية التي يمكن ان تكون بطبيعة عامة او خاصة. التغذية العكسية تسمح للشبكات الارجاعية بان تكتسب تمثيل الحالة بشكل دقيق, مما يجعلها ملائمة لمختلف التطبيقات الديناميكية مثل (التنبؤ او نظم النمذجة الغير خطية وغيرها).

1-5-4-1 تطبيق الشبكات العصبية متعددة الطبقات مع النوافذة المتحركة باستخدام خوارزمية الانتشار العكسي في تنبؤ البيانات :-

1- تقسيم السلسلة الزمنية **Dividing Time Series**

- مجموعة للتدريب
- مجموعة للتحقق
- مجموعة للاختبار

2- تقدير السلسلة الزمنية **Time Series Prediction** :- السلسلة الزمنية هي سلسلة من المتجهات او القيم العددية التي تعتمد على الوقت , بتطبيق خوارزمية الانتشار العكسي على مجموعة البيانات المدربة في شكل نوافذة متنقلة لتنفيذ التعليم العام (online Learning) , تقدير السلسلة الزمنية يوضح بالنقاط الاتية :-

أ- تعديل البيانات **Data Normalization** :- وتعني تهيئة البيانات قبل معالجتها بالنسبة لانموذج للشبكات العصبية الاصطناعية وانموذج شبكة الانحدار الذاتي الغير خطي مع متغير خارجي لاستخدامها في عملية التدريب الشبكة العصبية لذلك فان مجال هذه البيانات لابد ان يقع ضمن حدود دالة التنشيط [1,7].

ب- تحديد هيكل الشبكة **Determining network's topology** :- الخطوات ادناه تحدد الربط بين الخلية العصبية , عدد الطبقات المخفية , عدد الخلايا العصبية في كل طبقة [5,7,13].

1- تحديد عقد المدخلات و كيف الخلايا العصبية في الشبكة مرتبطة مع بعضها , ان المتغيرات في انموذج السلسلة الزمنية تكون بدلالة المتغيرات المزاحة اي ان :-

$$Y_t = f(Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}) \dots \dots \dots (15)$$

اذ ان (p) تمثل درجة الانحدار الذاتي اي انحدار Y_t على القيم السابقة له. يصعب تحديد عقد المدخلات فانها تمثل مشكلة كبيرة اتجاه مصمم الشبكة العصبية ولهذا اقترحت عدة طرق اهمها :-

- الاعتماد على معاملات الارتباط الذاتي المعنوية للسلسلة الزمنية المستقرة كما ذكر في انموذج الانحدار الذاتي والمتوسط المتحرك.
- الاعتماد على طريقة تجميع البيانات في حالة وجود المركب الموسمي على سبيل المثال : اذا كانت البيانات تحتوي على موسمية سنوية فان (عدد عقد الادخال للبيانات الاسبوعية P=52 وللشهرية P=12 وللفصلية P=4).

- 2- لا توجد طريقة مثالية لتحديد عدد الخلايا العصبية المستخدمة في الطبقة المخفية فبعض الباحثين يختارها بعدد يساوي المتغيرات المزاحة زمنيا او اكثر والبعض الاخر يستخدم معايير احصائية ولكن يحتاج مدة زمنية طويلة جداً .
- 3- لتحديد عقد الاخراج *Output Nodes* اتفق اكثر الباحثون في مجال استخدام الشبكات العصبية في التوقع *Prediction* على ان عقدة اخراج واحدة تكفية للتوقع بخطوة واحد نحو الامام (*one step ahead prediction*).

ج- تدريب الشبكة *Train The Network*

د- تحديد معايير الخطأ

3- التنبؤ *Forecasting*

ان الهدف الاساسي من هذه المرحلة هو لحساب القيم المستقبلية للسلسلة الزمنية التي تم تدريبها ففي حالة التنبؤ خطوة واحدة نحو الامام (*one step ahead forecasting*) يكون باستخدام المعادلة باستخدام المشاهدة الفعلية لكل المتغيرات المزاحة كمدخل للشبكة كما موضح:-

$$Y_{t+1} = f(Y_t, Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}) \dots \dots \dots (16)$$

حيث (p) تمثل درجة الانحدار الذاتي اي انحدار Y_{t+1} على القيم السابقة له (عدد المتغيرات المزاحة) [1,5,13].

1-4-5-2 نموذج شبكة الانحدار الذاتي الغير خطي مع مدخل خارجي (شبكة ناركس)

non-linear auto regressive network with exogenous input (NARX Network)

في جميع مفاهيم الشبكات العصبية الاصطناعية التي نوقشت لحد الان ركزت على الديناميكية فقط في طبقة المدخلات او شبكات الـ (Feedforward) , اما في نموذج شبكة الانحدار الذاتي الغير خطي مع مدخل خارجي (NARX network) هي شبكة ديناميكية ارجاعية (Recurrent neural network) مع وصلات التغذية العكسية (feedback connections) والتي تحتوي على العديد من الطبقات في الشبكة وهذه الوصلات (connections) تشكل سلسلة حُددت خارجا والتي تولد سلسلة من التقديرات (Series of predictions), في نمذجة السلاسل الزمنية فان شبكة ناركس هي نموذج انحدار ذاتي غير خطي مع مدخل خارجي وهذا يعني بان الانموذج يربط القيمة الحالية للسلسلة الهدف مع:-

- القيم المدربة Trained او المقدره Predicted السابقة للسلسلة الهدف.
- القيم السابقة للسلسلة الدافعة والمؤثرة (Exogenous series) وهذا المطلوب من سلسلة خارجية تحدد وتؤثر على السلسلة المهمة.

على وجه التحديد , المعادلة التعريفية لعمل انموذج NARX هي :-

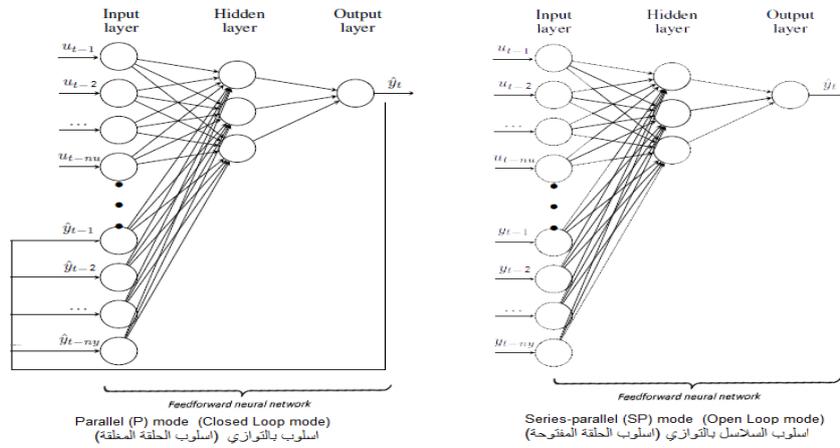
$$y_t = f(y_{t-1}, y_{t-2}, y_{t-3}, \dots, y_{t-p}, u_{t-1}, u_{t-2}, u_{t-3}, \dots, u_{t-q}) \dots \dots (17)$$

حيث u_t هي متغيرات سلسلة المدخلات input (السلسلة الخارجية exogenous series) و y_t متغيرات سلسلة المخرجات output (السلسلة الهدف target series) بينما t تمثل الزمن عند القيمة المزاحة ودالة f هي شبكة ممكن ان تكون (neural networks, wavelet networks, ...etc) في هذا البحث تنفذ المعادلة اعلاه باستخدام الشبكات العصبية امامية التغذية لتقريب الدالة حيث تكون القيم السابقة للسلسلة المدخلات (السلسلة الخارجية exogenous series) بجانب القيم السابقة لسلسلة المخرجات معا للحصول على القيم التالية لـ $y(t)$, الشكل (3-20) يوضح شبكة NARX في انماط مختلفة . الانموذج يمكن ان يعبر عنه للصيغة العامة [11,14] :-

$$y_{t+1} = f(y(t); u(t)) \dots \dots (17-1)$$

• اسلوب السلاسل بالتوازي Series-parallel (SP) mode :-

ويدعى ايضاً باسلوب الحلقة المفتوحة (Open Loop Mode) حيث يطبق فقط على القيم الفعلية لسلسلة المخرجات او ما تسمى سلسلة الهدف (Target series) وعلى قيم سلسلة المدخلات (السلسلة الخارجية Exogenous series) بهدف تقدير Predict القيمة التالية للسلسلة للهدف, يستخدم اسلوب السلاسل بالتوازي (SP mode) لتدريب الشبكة Network Train بين متغيرات



شكل (20-3) انماط (Parallel(P) mode-Series-parallel(SP)) في انماط NARX

الهدف وبين العناصر الرئيسية المؤثرة على هذه المتغيرات (سلسلة المدخلات) ,ينفذ هذا الاسلوب تقدير خطوة واحدة للامام One-step-ahead prediction والذي بدوره يعطي نتائج ادق ومن المهم ان تدرّب الشبكة في اسلوب السلاسل بالتوازي حيث يكون الخطا قليل جدا , الشكل (20-3) يوضح عمل هذا الاسلوب.

• اسلوب بالتوازي Parallel (P) mode :-

ويدعى ايضا باسلوب الحلقة المغلقة (Closed Loop Mode) , يستخدم هذا الاسلوب بعد ان تدرّب الشبكة في اسلوب بالتوازي (اسلوب الحلقة المفتوحة) حيث يمتاز هذا الاسلوب لتقدير القيم باستخدام التقدير متعدد الخطوات Multi-step-ahead Prediction, وهي تعني تطبيق الانموذج المدرب او المقدر (في اسلوب الحلقة المفتوحة Open Loop Mode) خطوة بخطوة واستخدام القيمة المقدرة الحالية لتحديد او تقدر قيمتها في الخطوة التالية , اي بمعنى اخر تقدير القيمة التالية لسلسلة المخرجات (السلسلة الهدف) باستخدام التغذية العكسية للقيم المقدرة لسلسلة الهدف كمدخل للشبكة بالاضافة الى قيم سلسلة المدخلات والشكل (20-3) يوضح عمل اسلوب بالتوازي (P) Mode [13,14]

1-2-5-4-1 تطبيق انموذج شبكة NARX باستخدام خوارزمية الانتشار العكسي في تنبؤ البيانات

1- تجزئة السلسلة الزمنية Dividing Time Series

2- اعداد الحلقة المفتوحة Open Loop Setup :-

- تجهيز البيانات- تعديل البيانات
- تحديد هيكلية الشبكة
- تدريب الشبكة
- تحديد معايير الخطأ

3- الانتقال الى اسلوب الحلقة المغلقة **Switching To Closed Loop Mode**- استخدام تصميم الحلقة المغلقة

مع الشبكة المدربة للتنبؤ بالقيم المستقبلية

2- الجانب التطبيقي

يتضمن هذا الجانب عرض الطرائق التي يتم من خلال التنبؤ بالسلاسل الزمنية :-

1- الانحدار الذاتي المتكامل والمتوسط المتحرك الموسمي SARIMA

2- دالة التحويل TFM

3- الشبكات العصبية متعدد الطبقات مع النوافذة المتنقلة

4- شبكة الانحدار الذاتي الغير خطي مع مدخل خارجي (NARX network)

2-1 تجهيز البيانات **Date Preprocessing**

في هذا المبحث تم استخدام معطيات الحمل المتحقق الساعي للطاقة الكهربائية المستهلكة ودرجة الحرارة في بغداد من تاريخ 2007/01/01 الى 2014/12/31 التي حصلنا عليها من دائرة التشغيل والتحكم لوزارة الكهرباء وكانت من مصادر مختلفة حيث كان لكل يوم ملف اكسل وكل ملف اكسل يحتوي على بيانات الحمل لجميع المحافظات وبيانات محافظة بغداد بشكل صف والمطلوب ان تكون بشكل اعمدة لسهولة العمل عليها وبهذا تجميع البيانات يتطلب وقت وجهد كبير جدا. لهذا تم اللجوء الى استخدام قواعد بيانات SQL Server وربطها مع واجهات باستخدام Visual C# .net. وانشاء واجهة مرنة لادخال البيانات لتقليل الوقت والجهد لادخال البيانات .

2-2 تنقية البيانات **Data Cleaning**

وتتضمن هذه المرحلة حذف الضوضاء ومعالجة البيانات المفقودة ' حيث كانت هناك بيانات مفقودة بالنسبة لمعطيات الحمل المتحقق ودرجة الحرارة وتمت معالجتها بطريقة الاستكمال الخطي Linear Interpolation .

2-3 تقليص وتحويل البيانات **Data Transformation And Reduction**

تم تحويل البيانات حسب الطريقتين ادناه :-

2-3-1 تعديل البيانات **Normalization** : البيانات حولت باستخدام طريقة min-max بمدى يتراوح بين 0-1

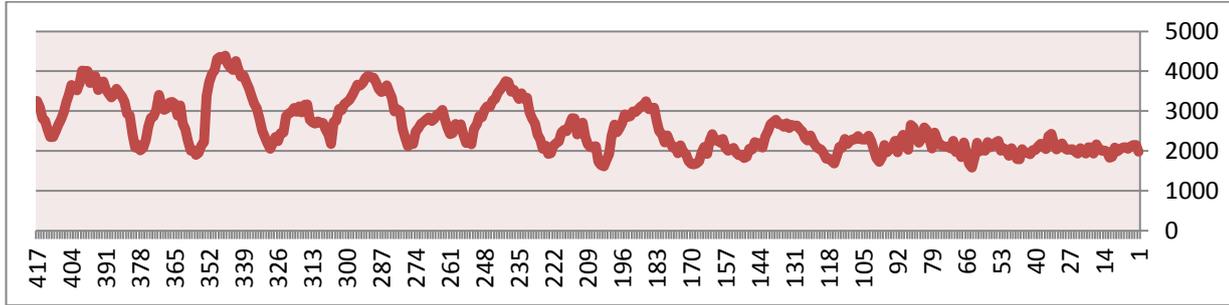
وذلك لاجل سلوك دوال التنشيط في الشبكة العصبية.

2-3-2 تعديل الفروق **difference** : استخدم تعديل الفروق في نماذج الانحدار الذاتي المتكامل والمتوسط المتحرك

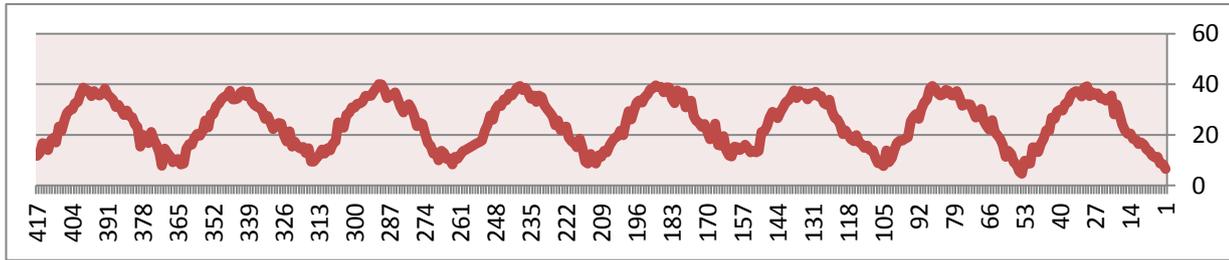
الموسمي SARIMA وفي نماذج دالة التحويل TFM.

بعد التأكد من ان جميع البيانات سليمة يتم البدء بتطبيق نماذج التنبؤ ونظرا لما تحمله البيانات من موسمية سنوية بسبب الفصول وموسمية اسبوعية بسبب ايام العطل في الاسبوع فهي تحتوي على موسمية متعددة (Multiple seasonal) والتي تحتاج الى بناء انظمة تنبؤ معقدة جدا ولا تعطي نتائج دقيقة ومرضية ولذلك تم اخذ المعدل لـ 24 ويليه المعدل لـ 7 ايام لتصبح البيانات بشكل اسبوعي بحدود 417 اسبوع وتم تجزئة البيانات الى جزئين جزء التدريب

(Training) بنسبة 70% والذي يتم تطبيق طرائق التنبؤ عليه وجزء التجربة (Testing) بنسبة 30% لاختبار النتائج. وتم رسم مشاهدات السلسلة الزمنية المذكورة وكان الاتجاه العام لها متصاعد Upper trend كما في شكل رقم (4) :-



الشكل (4) يوضح مشاهدات الحمل المتحقق



الشكل (5) يوضح مشاهدات درجة الحرارة

4-2 التنبؤ بنماذج الانحدار الذاتي المتكامل والمتوسط المتحرك الموسمي SARIMA

لقد تم برمجة هذا النموذج كجزء من النظام في لغة ماتلاب Matlab 2013ra وبعد اجراء جميع مراحل تطبيق النموذج تبين ان النموذج الاكثر ملائمة بعد اجراء 256 احتمال مع التغيير بعدد المدخلات هو SARIMA(1,1,1)*(1,1,2)52 الذي حقق اقل معايير كما في جدول رقم(2) :

جدول (2) نتائج انموذج SARIMA

MAPE	RMSE	MSE	BIC	AIC
0.191833607	736.5701	542535.5	3839.63	3813.893

ومعادلة الانموذج هي :-

$$(1 - \Phi_1 B^{52})(1 - \phi_1 B)(y_t) = (1 + \theta_1 B^{52} + \theta_1 B^{104})(1 + \theta_1 B)\epsilon_t$$

حيث :-

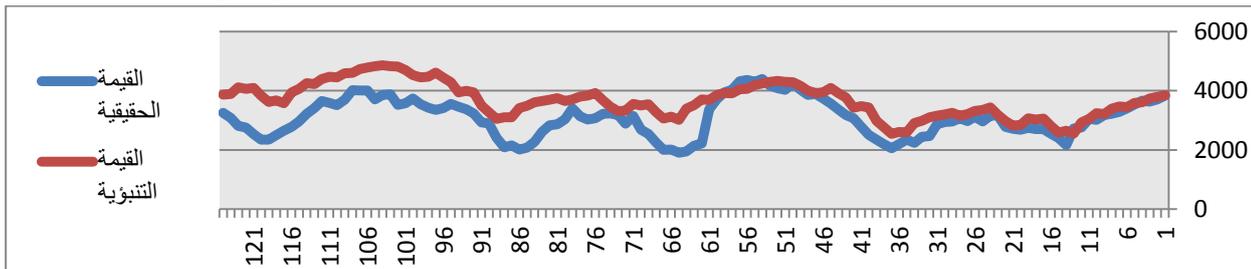
$$y_t = (1 - B)(1 - B^{52})(Y_t)$$

قيم معامل الانحدار الذاتي : $\phi = 0.757100402139758$

قيم معامل المتوسط المتحرك : $\theta = -0.178926364999704$

قيم معامل الانحدار الذاتي الموسمي : $\Phi = -0.990747559514488$

قيم معامل المتوسط المتحرك الموسمي : $(\theta_2 = -1.0000, \theta_1 = 0.001)$ والشكل رقم 6 يوضح نتائج التنبؤ :-



شكل (6) يوضح التنبؤ بانموذج SARIMA

5-2 التنبؤ بنماذج دالة التحويل SISO TFM

لقد تم برمجة هذا النموذج كجزء من النظام في لغة ماتلاب Matlab 2013ra وبعد تطبيق جميع مراحل النموذج وتشخيص سلسلة الاخطاء تبين ان الصيغة التقديرية لانموذج دالة التحويل تكون كالآتي :-

$$v(B) = \frac{(\omega_0 - \omega_1 B)}{(1 - \delta_1 B)} x(t)$$

وان الانموذج الاكثر ملائمة لسلسلة الاخطاء هو SARIMA(1,0,1)*(1,0,2)52 :-

$$(1 - \Phi_1 B^{52} - \Phi_1 B^{104})(1 - \phi_1 B)(nt) = (1 + \Theta_1 B^{52})(1 + \theta_1 B) \alpha_t$$

والذي حقق اقل معايير للخطأ كما موضح في جدول رقم(3):

جدول (3) نتائج انموذج TFM

MAPE	RMSE	MSE	BIC	AIC
0.0888	341.2279	116436.5	3080.039	3061.655

وبالتالي فان الانموذج الذي تم تشخيصه بعد تطبيق جميع مراحل بناء نماذج دالة التحويل هو :-

$$y(t) = \frac{(\omega_0 - \omega_1 B)}{(1 - \delta_1 B)} x(t) + \frac{(1 + \Theta_1 B^{52})(1 + \theta_1 B)}{(1 - \Phi_1 B^{52} - \Phi_1 B^{104})(1 - \phi_1 B)} \alpha_t$$

حيث :

$$yt = (1 - B)(1 - B^{52})(Yt)$$

$$xt = (1 - B)(1 - B^{52})(Xt)$$

ولتقليل المعلمات وتسهيل مرحلة التقدير Estimation تم اللجوء الى التقدير بدالة ARIMAX ليصبح الانموذج بالشكل

الآتي :-

$$y(t) = \beta x(t) + \frac{(1 + \Theta_1 B^{52})(1 + \theta_1 B)}{(1 - \Phi_1 B^{52} - \Phi_1 B^{104})(1 - \phi_1 B)} \alpha_t$$

قيم معامل الانحدار الذاتي : $\phi = -0.596040696122376$

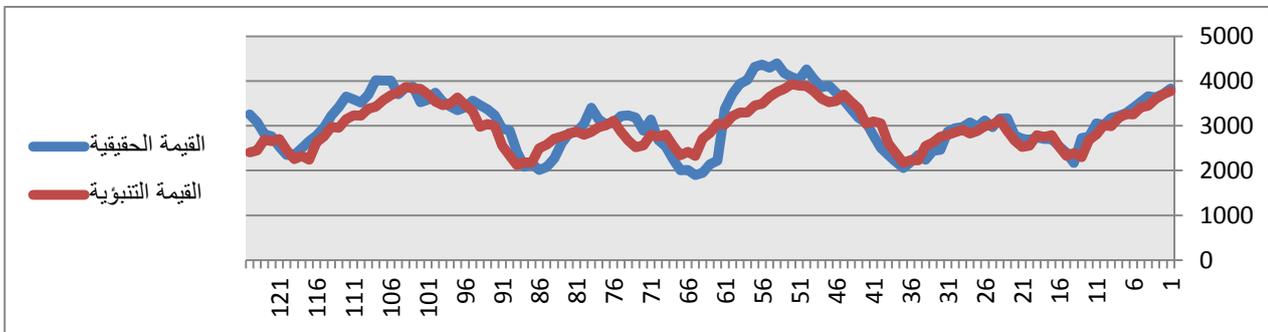
قيم معامل المتوسط المتحرك : $\theta = 0.230401744378446$

قيم معامل الانحدار الذاتي الموسمي : $(\Phi_1 = 0.001, \Phi_2 = -0.1787)$

قيم معامل المتوسط المتحرك الموسمي : $\Theta = 0.230401742254619$

قيم معامل المدخل الخارجي Beta (سلسلة المدخلات) : $\beta = 0.259790780292811$ والشكل رقم (7) يوضح

نتائج التنبؤ :-



شكل (7) يوضح التنبؤ بانموذج SISO TFM

6-2 التنبؤ بانموذج الشبكة العصبية متعدد الطقات مع النوافذة المتحركة

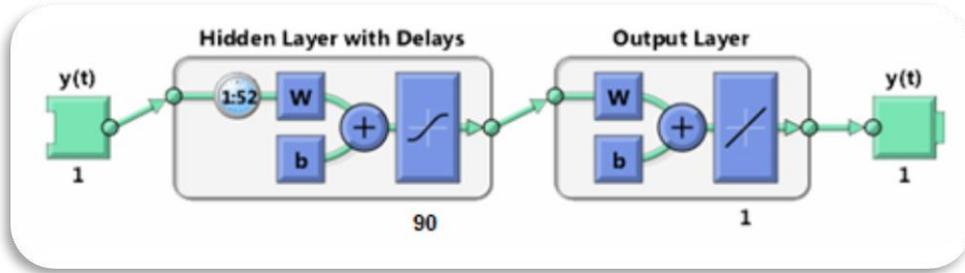
لقد تم برمجة هذا النموذج كجزء من النظام بلغة . Visual C# وبعد العديد من التجارب والتغيير في عدد المدخلات والعقد المخفية تم تحديد هيكلية الشبكة:

عدد وحدات الإدخال : عدد المتغيرات المزاحة 52 اسبوع (حسب طبيعة الموسمية السنوية للبيانات).
عدد الوحدات المخفية :طبقة مخفية واحدة وعدد عقد 90 عقدة .وبعد تحديد هيكلية الشبكة بدأت عملية التعليم *learning process* ب 5000 تكرار *Epoch* وان افضل شبكة (*Best Network*) والتي اظهرت افضل النتائج عند التكرار (Epochs) 1775 وبنسبة تعلم *Learning rate* 0.5 وبقوة دفع *Momentum* 0.2 والتي حققت اقل معايير خطأ كما موضح في جدول رقم (4):-

جدول (4) نتائج انموذج MLP-With Sliding Windows

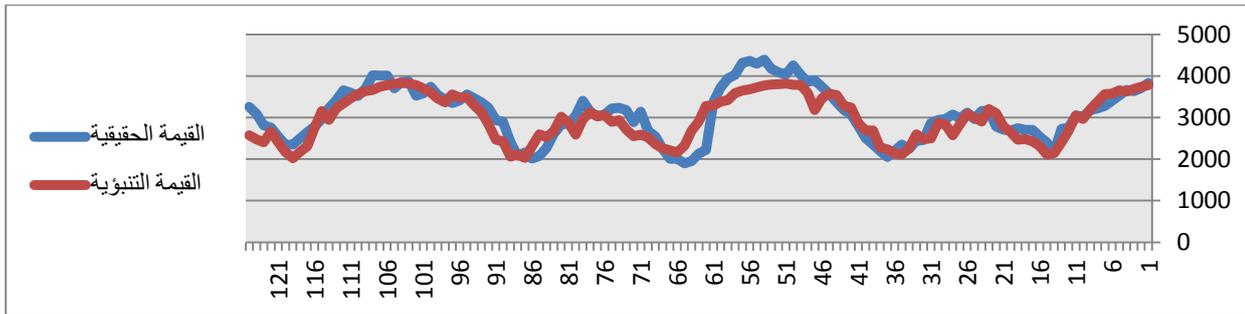
MAPE	RMSE	MSE
0.083096	294.7553	86880.66

حيث يصبح انموذج الشبكة في الشكل رقم (8)



شكل (8) يوضح هيكلية الشبكة Network topology

والشكل 9 يوضح نتائج التنبؤ :-



شكل (9) يوضح التنبؤ بانموذج LP-With Sliding Windows

7-2 التنبؤ بانموذج شبكة الانحدار الذاتي الغير خطي مع مدخل خارجي (NARX Networks)

لقد تم برمجة هذا النموذج كجزء من النظام بلغة . Visual C# ومثل ما ذكر في الجانب النظري يجب تحديد درجة الانحدار الذاتي لسلسلة المدخلات ايضا (عدد القيم المزاحة لسلسلة المدخلات) لتدريب الشبكة في اسلو الحلقة المفتوحة (Open Loop Mode) , وبعد العديد من التجارب والتغيير في عدد المدخلات والطبقات والعقد المخفية تم تحديد هيكلية الشبكة:

عدد وحدات الإدخال : عدد المتغيرات المزاحة لسلسلة المخرجات 52 اسبوع (حسب طبيعة الموسمية السنوية للبيانات) يقابلها عدد المتغيرات المزاحة لسلسلة المدخلات 52 اسبوع حيث كل حمل اسبوعي يقابله معدل الاسبوعي

درجة الحرارة وذلك لان (مثل ماذكر في دالة التحويل تنقل سلسلة المدخلات الى سلسلة المخرجات) حيث كل قيمة من سلسلة المدخلات يجب ان تقابلها قيمة من سلسلة المخرجات .

عدد الوحدات المخفية : من طبقتين مخفيتين *Hidden Layer* حيث :-

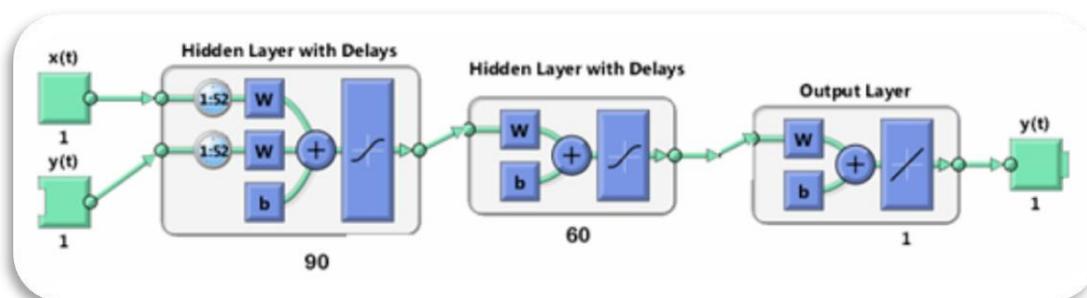
الطبقة الاولى : عدد العقد 90 .

الطبقة الثانية : عدد العقد 60 . وبعد تحديد هيكلية الشبكة بدأت عملية التعليم *learning process* باجراء 2000 تكرار *Epoch* وان افضل شبكة (*Best Network*) اظهرت افضل نتائج تقدير في اسلوب الحلقة المفتوحة عند التكرار (*Epochs*) 1467 وبنسبة تعلم *Learning rate* 0.5 وبقوة دفع *Momentum* 0.2 ثم تحول الى اسلوب الحلقة المغلقة للتقدير متعدد الخطوات *Multi-Step Ahead Prediction* وكانت نتائج التنبؤ في اسلوب الحلقة المغلقة والتي حققت اقل معايير خطأ كما جدول 5:-

جدول (5) نتائج نموذج NARX Network

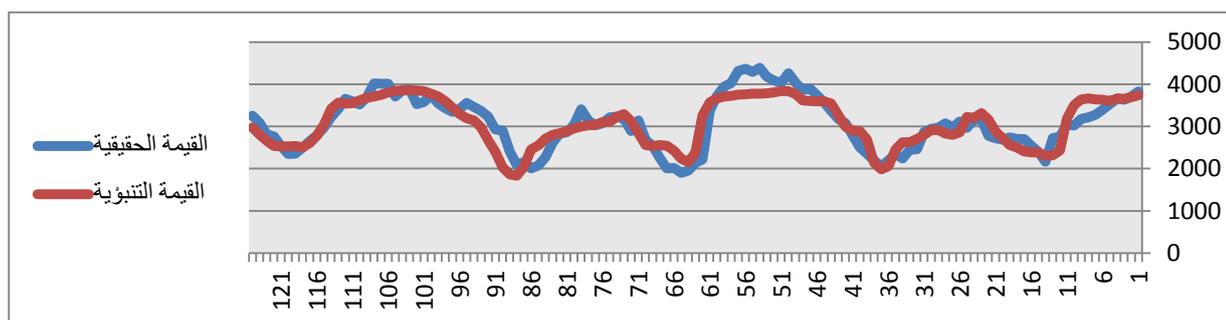
MAPE	RMSE	MSE
0.076337	288.4776	83219.33

حيث يصبح نموذج الشبكة في الشكل رقم (10) ادناه :-



شكل (10) يوضح هيكلية شبكة NARX Network topology

والشكل ادناه يوضح نتائج التنبؤ :-



شكل (11) يوضح التنبؤ بانموذج NARX Network

وكما هو واضح فان نموذج شبكة الانحدار الذاتي الغير خطي مع مدخل خارجي (*NARX Network*) تفوقت على جميع النماذج المذكورة وفق المعايير الاحصائية الثلاثة , وبذلك فان هذه الطريقة تعتبر الافضل والاكثر دقة للتنبؤ بقيم السلاسل الزمنية المتعلقة بالاحمال الكهربائية والجدول (6) يوضح المقارنة بين نتائج الطرق المستخدمة .

جدول (6) يوضح معايير الخطأ للاساليب المستخدمة

MAPE	RMSE	MSE	معايير الخطأ الطريقة المستخدمة
------	------	-----	-----------------------------------

0.191833607	736.5701	542535.5	SARIMA
0.0888	341.2279	116436.5	TFM
0.083096	294.7553	86880.66	MLP-With Sliding Windows
0.076337	288.4776	83219.33	NARX Network

3- الاستنتاجات

1. السلسلة الزمنية للاحمال الكهربائية لديها سلوك (غير خطي، موسمي ، اتجاه عام متصاعد ، عدم استقرارية).
2. اظهرت النتائج اتجاه متناسق للقيم التنبؤية مع القيم الحقيقية للنماذج المستخدمة.
3. بيانات استهلاك الكهرباء والحرارة تحتوي على بيانات مفقودة وتمت معالجتها باستخدام الاستكمال الخطي $(linear interpolation)$.
4. بيانات استهلاك الكهرباء لديها سلوك موسمية المتعددة.
5. بيانات استهلاك الكهرباء ودرجة الحرارة اظهرت موسمية سنوية حيث لكل سنة 52 اسبوع.
6. لتحديد هيكلية المعلمات المتناهية $finite-parameter$ لهيكل دالة التحويل $V(B)$, افضل تقدير نهائي للمعلمات هو باستخدام دالة $ARIMAX(p,d,q)$.
7. في نموذج دالة التحويل $(SISO)$, عند تأثير العامل الخارجي الذي ظهر في بيانات الحمل , العديد من الشروط يمكن ان تحسب للنمط الذي وجد في البيانات :-
أ- لقد وجد بان العامل الخارجي شرح افضل نظرية بناء على قيمة درجة الحرارة .
ب- لقد وجدنا بن كل السلسلة من 2007 الى 2014 تشير الى القبول الاحصائي بان العامل الخارجي يظهر بشكل قوي في موسم الشتاء .
8. بعد العديد المحاولات قبل ان نحصل على افضل هيكلية للشبكة , قمنا بمحاولة العديد من التركيبات (ل الطبقات , نسبة التعلم $Learning rate$, قوة الدفع $Momentum$, التكرار $Epochs$.. الخ) وحسب طبيعة تنبؤ السلاسل الزمنية :-
أ- افضل نموذج $MLP-with Sliding Windows$ كان عند نسبة تعلم 0.5 وقوة دفع 0.2 وبطبقة مخفية واحدة وبعدها عقد 90 , والمتغيرات المزاحة 52 عند التكرار $1775 epoch$.
ب- افضل نموذج $NARX network$ ($Closed Loop Design$) كان عند نسبة تعلم 0.5 وقوة دفع 0.2 واثنين من الطبقات المخفية (الاولى تحوي على 90 عقدة مخفية , الثانية بعدد عقد 60 عقدة مخفية) , والمتغيرات المزاحة 52 بالنسبة لكلتا سلسلتى المدخلات والمخرجات عند التكرار $1467 epoch$ (التكرار يمثل افضل تقدير عند تدريب الشبكة في اسلوب الحلقة المفتوحة) .
9. وجدنا بان ادق نتائج للتنبؤ بالاحمال الكهربائية هي في نموذج $(NARX network)$ باستخدام بعض معايير الخط $(MSE, RMSE, MAPE)$.

4- التوصيات

- على ضوء ما تم استنتاجه في هذا البحث نوصي بمايلي :-
1. بدراسة عوامل خارجية اكثر $(Exogenous variable)$ الدخل ، السعر وعوامل الطقس الاخرى) باستخدام نماذج دالة التحويل TFM او نماذج شبكة الانحدار الذاتي الغير الخطي مع مدخل خارجي $NARX Network$.

2. تقنيات هجينة تحتاج للتعامل مع تباين الطلب الكبير الذي يحدث.
3. هذا العمل هو استمرار لممارسة النماذج (ARIMA ,TFM, MLP-With Sliding Windows , NARX) على بيانات محافظات اخرى في بلدنا .
4. للعمل المستقبلي نوصي بانشاء خوارزمية تدريب للشبكة العصبية لجعل النموذج باقل عدد من التكرارات *Epochs*.
5. استخدام نموذج (*NARX networks predictor*) لتحسين نتائج النموذج لان النتائج كانت ماشابهة جدل مع بيانات الحمل الكهربائي عند التوقع (*Prediction*) في خوارزمية التدريب وكيف المتغير الخارجي (متغير سلسلة المدخلات) يؤثر على متغير السلسلة (سلسلة المخرجات).

المصادر

1. عبد العزيز, بثينة عبد الجادر و الوكيل, خولة حسين(2015), "التنبؤ بالمعدلات الشهرية لدرجات الحرارة العظمى والصغرى في مدينة بغداد باستخدام الشبكة العصبية المتعددة الطبقات", مجلة كلية الرافدين /العدد 63.
2. الموسوي ,جواد كاظم و لفته ,سولاف صبري(2012), "التنبؤ بمبيعات البنك المركزي من العملة الاجنبية باستخدام " (انموذج دالة التحويل العشوائي). *Iraqi Journal for Economic Sciences*.
3. الصفاوي , صفاء يونس و مصطفى, مئينة عبد الله (2007), "مقارنة بين التنقية المكيفة والشبكات العصبية ذات الانتشار العكسي في السلاسل الزمنية |, تنمية الرافدين العدد 88(29) ص (177-192).
4. Montgomery, Douglas C., Lynwood A. Johnson, and John S. Gardiner. Forecasting and time series analysis. McGraw-Hill Companies, 1990.
5. Akintola, K. G., B. K. Alese, and A. F. Thompson. (2011). Time Series Forecasting with Neural Network: A Case Study of Stock Prices of Intercontinental Bank Nigeria. IJRRAS.
6. Ababio, Kofi Agyarko. (2012). Comparative study of stock price forecasting using ARIMA and ARIMAX MODELS. Diss.
7. Jiawei, H., Pei, J. and Kamber, M. (2011). Data mining: concepts and techniques. Elsevier, 2011.
8. Wei, W.W.S. (2006). Time Series Analysis Univariate & Multivariate Methods, Second Edition, Addison-Wesley Publishing Company, Inc. , New York , USA .
9. Box, G.E.P. and Jenkins, G.M. (1976). Time Series Analysis: Forecasting and Control, 2nd ed., Holden-Day, San Francisco .
10. Jeff, H. (2008). Introduction to Neural Networks for C. Heaton Research, Inc.,.
11. Sayfeddine, D. (2014). Nonlinear autoregressive neural network with exogenous inputs based solution for local minimum problem of agent tracking using quadrotor. Don Engineering Gazette (Russian) 29.2 (2014).
12. Zhang, G. Peter, and Douglas M. Kline. (2007). Quarterly time-series forecasting with neural networks. IEEE transactions on neural networks 18.6: 1800-1814.
13. Dhari Y. Samaraee, Sammer J, Ismail. (2005). Forecasting the Daily Peak Load using Artificial Neural Networks , Eng , & Technology, 24, (10).
14. Christopher, B., Stewart, R.A., and Lu J. (2014). "Autoregressive with exogenous variables and neural network short-term load forecast models for residential low voltage distribution networks." Energies 7.5: 2938-2960.
15. Harris, John L., and Lon-Mu Liu. (1993). Dynamic structural analysis and forecasting of residential electricity consumption. Int. J. Forecasting 9.4: 437-455.