

نماذج التنبؤ بأسلوب الشبكات العصبية لوارط ومطلق المياه لسد الموصل

رؤى خلدون فائق**

أ. م. د. رعد فاضل حسن*

المستخلص:

يعد التنبؤ المستقبلي للسلاسل الزمنية من الموضوعات المهمة في العلوم الإحصائية لمساعدة الإدارات في التخطيط وإتخاذ القرارات الدقيقة لذا تتناول هذه الدراسة أساليب التنبؤ الحديثة وتتمثل بنماذج الشبكات العصبية الاصطناعية Artificial Neural Networks Models (ANN) وبالتحديد الشبكة المتعددة الطبقات إذ اعتمدت خوارزمية الانتشار الخلفي (BP) Back Propagation عدة مرات للتدريب واختيار أقل قيمة للخطأ للحصول على أفضل نموذج لوصف البيانات وكذلك تم التطرق إلى طرق التنبؤ الكلاسيكية كنماذج بوكس-جنكينز وتحليل الإحدار الخطي المتعدد وتوفيق عدة نماذج واختيار أفضلها لكل طريقة وقد تم تطبيق هذه الأساليب الثلاثة على بيانات واقعية عن المعدلات الشهرية لتصاريف المياه الواردة والمطلقة والمقاسة بوحدات (م³/ثا) لبعض السدود في العراق وتمت المقارنة بين النماذج المقطرة لهذه الأساليب لإيجاد الأسلوب الأكثر كفاءة للتنبؤ وفق المقاييس الإحصائية إذ وجد إن أسلوب الشبكات العصبية يعطي نتائج أفضل وأكثر كفاءة لإغلب السلاسل الزمنية لوارط ومطلق السدود .

Abstract

The prediction futurely of time series from the important topics in statistics sciences to assist administrations in the planning and make the accurate decisions, so this study dealing with prediction methods modern and it's models of artificial neural networks specifically multiple layers network where they adopted the algorithm to Back Propagation (BP) of the train several times and choose the lowest value of the error to get the best model to describe the data and were discussed also the prediction ways classical as models Box - Jenkins and analysis of multiple linear regression and reconcile several models and choose the best model for each method and may to be applied to these three methods on the factual data off monthly averages for the water incoming and absolute and measured in units of (m³/s) for some dams in Iraq and has comparison between the models estimated for these methods to find the most efficient method to the prediction according to measurements statistical where was found that neural networks give better results and more efficient for most of the time series for incoming and absolute dams

1- المقدمة Introduction

شهد العالم في المدة الأخيرة تطوراً واضحاً في جميع ميادين الحياة والتي طرق بابها الحاسوب وفي مقدمتها التحكم الصناعي والتطور الطبي غير إن كثرة الصعوبات التقنية وتعقيدها وعدم قدرة الحلول

* قسم الاحصاء / كلية الإدارة والاقتصاد / الجامعة المستنصرية
** قسم الاحصاء / كلية الإدارة والاقتصاد / الجامعة المستنصرية

البرمجية التقليدية على إستيعابها قاد الباحثين للتعق في فهم واحدة من نعم الله وأعظمها وهو التفكير والذكاء البشري، وبه ميّز الإنسان الحروف والأنماط وتعرّف على الصور والأشكال وإن قابلية الإنسان وكفاءته ترجع إلى هيكل دماغه المتكون من عدد هائل ومعقد من الخلايا العصبية تزيد على (10) بليون خلية والمرتبطة مع بعضها مكونة الشبكة العصبية [4][2]

لذلك تعد الشبكات العصبية الاصطناعية ذكاءاً من صنع أو ابتكار الإنسان يتم الحصول عليه من خلال إعطاء الحاسوب القدرة البرمجية على التعلم والتعامل مع أنماط لبيانات خاطئة في العديد من المجالات التطبيقية ومعالجة هذه البيانات لإغراض التحليل أو التصنيف أو التنبؤ وأخذ القرارات المبنية على الآف الاحتمالات والعلاقات [5]

ويمكن تعريف الشبكات العصبية الاصطناعية ANN على إنها هيكل لخرن ومعالجة المعلومات بشكل متوازي ومتماثل ودون الحاجة إلى نموذج مقترح لهذه البيانات للوصول إلى أقرب نقطة للكفاءة بالمقارنة مع كفاءة الإنسان . [6] [1]

ومن هنا تم إختيار الشبكات العصبية لإستعمالها في التنبؤ إذ يتناول هذا البحث التفاصيل الخاصة بالشبكات العصبية وتقنياتها وطرق تعلمها ومعمارياتها مع التطرق إلى خوارزمية الانتشار العكسي Back Propagation Algorithm مع تطبيقاتها وطرق تعديلها.

فضلاً عن دراسة نظرية وتطبيقية لطرق تحليل السلاسل الزمنية ومنها نماذج بوكس- جنكينز ونماذج الإنحدار الخطي المتعدد باعتبارها من أساليب التقدير والتنبؤ الكلاسيكية ومقارنة النماذج الناتجة عنها مع نماذج الشبكات العصبية الاصطناعية لمعرفة الكفاءة لكل من هذه الطرق وقد تم تطبيق هذه الأساليب على البيانات الخاصة بوارد ومطلق المياه لسد الموصل والذي يقع على نهر دجلة على بعد (40) كم شمال مدينة الموصل ويبلغ ارتفاع السد (113) م وسعة الخزن الكلية (14.53) مليارم³ ويؤمن السد الزراعة الدائمة الكثيفة من الأراضي القابلة للزراعة على جانبي نهر دجلة في محافظات الموصل، بغداد، الكوت، الناصرية، العمارة والبصرة وكذلك السيطرة على مياه نهر دجلة لدرء أخطار الفيضان وبخاصة في مدينة الموصل وأيضاً توليد الطاقة الكهربائية تم إنجاز وتشغيل السد عام 1986 .

2- هدف البحث Objective of Research

يهدف البحث إلى بناء نماذج للتنبؤ بمعدل تصريف المياه الواردة والمطلقة لسد الموصل الشهرية والمقاسة بوحدة (م³/ثا) بإستعمال أسلوب الشبكات العصبية الاصطناعية ومقارنتها بالطرق الإحصائية التقليدية والمتمثلة بنماذج بوكس- جنكينز ونماذج الإنحدار الخطي المتعدد للوصول إلى أفضل أسلوب وإنموذج للتنبؤ وفقاً لبعض المقاييس الإحصائية .

3- الجانب النظري Theoretical Side

3-1 : السلاسل الزمنية Time series

توجد عدة أساليب لتحليل السلاسل الزمنية ومنها أسلوب بوكس - جنكينز Box- Jenkins (ARIMA) model والذي يكون ذو كفاءة عالية في نمذجة السلاسل الزمنية فيما إذا كانت موسمية أو غير موسمية وتتضمن منهجية بوكس- جنكينز جمع وتحليل البيانات وإختبارها من خلال تشخيص الإنموذج وتقدير معالمه Estimation & Diagnostic Model وإختبارات التشخيص Diagnostic Tests للإنموذج المستخدم في التنبؤ [1] ولأجل التحليل لا بد أن تكون السلسلة الزمنية مستقرة في المتوسط (Stationary time series) أي أن مشاهداتها تتذبذب بصورة عشوائية حول متوسط ثابت لا يعتمد على الزمن (t) ومنه فإن :

$$E(y_t) = \mu$$

وكذلك الاستقرار في التباين أي ثبات التباين من خلال علاقته بالزمن :

$$\text{var}(y_t) = E[(y_t - \mu)] = \sigma_y^2$$

ويمكن تحويل السلسلة الزمنية غير المستقرة في المتوسط إلى سلسلة مستقرة وذلك بإستعمال أسلوب الفروقات (differencing) وبعد أخذ عدد من الفروق المناسبة من الدرجة (d) للسلسلة الأصلية والفروق الموسمية التي تكون من الدرجة (D) فإن الصيغة العامة للإنموذج المختلط الموسمي Seasonal Mixed Model (SARIMA) بدلالة عامل الفروق الخلفية (Back shift operator) توصف كالآتي : [8]

$$\phi_p(B) \Phi_p(B^S) \nabla^d \nabla_S^D y_t = \theta_q(B) \Theta_Q(B^S) a_t \dots\dots (1)$$

إذ $\phi_p(B)$: متعدد الحدود من الدرجة (p) لإنموذج الإنحدار الذاتي و $\Phi_p(B^S)$: متعدد الحدود من الدرجة (P) لإنموذج الإنحدار الذاتي الموسمي و $\theta_q(B)$: متعدد الحدود من الدرجة (q) لإنموذج الأوساط المتحركة و $\Theta_Q(B^S)$: متعدد الحدود من الدرجة (Q) لإنموذج الأوساط المتحركة الموسمي S : طول الموسم D : الفرق للجزء الموسمي و a_t : حد الخطأ العشوائي . ويرمز لإنموذج المختلط الموسمي للسلسلة الزمنية الموسمية المستقرة بالرمز :

SARIMA

والذي بالإمكان إستنتاج أغلب نماذج بوكس- جنكينز الموسمية وغير الموسمية منه بالإعتماد على خصائص درجات متعددة الحدود والموسم . وأيضاً ممكن تحديد الإنموذج والتأثيرات الموسمية من خلال دالتي (ACF) و (PACF) فإذا وجد إن تلك الارتباطات لها فروق معنوية عند مدة زمنية ثابتة إذ تمثل طول الموسم عندها تكون السلسلة الزمنية موسمية وكذلك يتم إستعمالها للتمييز ما بين نماذج AR و MA وسلوك الإنموذج ARMA . [12]

3-1-2 : تشخيص النموذج وتقدير المعالم Estimation and Diagnostic model [12]

يتم تشخيص الإنموذج من خلال عدة صيغ منها :

- معيار أكايكي (Akaike Criterion (AIC لتشخيص درجة الإنموذج ARIMA (p,q) وفق هذا المعيار يعتمد على العلاقة :

$$AIC = n \ln(S/n) + 2p$$

إذ أن (S) مجموع مربعات البواقي

وتحدد الدرجة الأفضل التي تقابل أقل قيمة لهذا المعيار .

أو بالإعتماد على معيار شوارز (Schwarz Criterion (SC ويعرف أيضاً بمعيار (BIC) Bayesian Information Criterion وصيغته :

$$BIC = n \ln(S/n) + p + p \ln(n)$$

أو من خلال العلاقة بين دالة الارتباط الذاتي والارتباط الذاتي الجزئي وبالإعتماد على الأشكال التي يتم تحديد درجة الإنموذج فيها .

ولتقدير المعالم Estimation of parameters هناك طرق رئيسية منها :

طريقة المربعات الصغرى (Least Squares (LS بالإعتماد على مجموع مربعات الأخطاء وتكون صيغة التقدير لنماذج AR(P) كالآتي :

$$\phi = (x^T x)^{-1} x^T y$$

$$\hat{x}_{p,1}^T = [y_{t-1} \ y_{t-2} \ \dots \ y_{t-p}]^T$$

وطريقة الإمكان الأعظم (Maximum Likelihood method (ML وفيها يتم حساب وإختيار

أقل مجموع مربعات الأخطاء للمعالم للحصول على مقدر الإمكان الأعظم

$$a_t = \theta_q^{-1}(B) \theta_Q^{-1}(B^S) \phi_p(B) \phi_P(B^S) \nabla^d \nabla_S^D y_t$$

$$\hat{\sigma}^2 = \frac{1}{N} \sum_{t=1}^N \hat{a}_t^2$$

3-1-3 : إختبارات التشخيص Diagnostic Tests

بعد إختيار الإنموذج وتقدير المعالم يتم التحقق من مدى إمكانية تحسينه وتطويره ويتم ذلك من خلال عدة إختبارات ومنها :

- إختبار Box- Pierce ويعتمد على الأخطاء الخاصة بالإنموذج وفق الصيغة :

$$Q = N \sum_{k=1}^m \hat{\rho}_{\hat{a}(k)}^2 \sim \chi_m^2$$

وتعديلة للقيمة الصغيرة يعرف بـ (Ljung- Box) وبالصيغة :

$$Q^* = N(N+2) \sum_{k=1}^m (N-k)^{-1} \hat{\rho}_{\hat{a}(k)}^2 \sim \chi_m^2$$

إذ أن $m = \sqrt{N}$ و $\hat{\rho}_{\hat{a}(k)}^2$: تقدير لمربع معامل الارتباط الذاتي للأخطاء وعند الإراحة (k).

3-1-4 : مقاييس الكفاءة على دقة النماذج [1]

من المؤشرات التي توضح مدى ملائمة النموذج ما يلي :

1- متوسط الخطأ Mean Error (ME)

2- متوسط مربع الخطأ Mean Square Error (MSE)

3- متوسط مطلق الخطأ Mean Absolute Error (MAE)

4- متوسط مطلق الخطأ النسبي Mean Absolute Percentage Error (MAPE)

3-1-5 : التنبؤ Forecasting

بعد اختبار النموذج المشخص يمكن استعماله للتنبؤ بالقيم المستقبلية للسلسلة الزمنية وبافتراض أن (h) تمثل المدة المستقبلية المراد التنبؤ بها عندها تكون الصيغة العامة للتنبؤ :

$$E(y_{t+h}) = \hat{y}_t = \phi_1 E(y_{t+h-1}) + \phi_2 E(y_{t+h-2}) + \dots + \phi_{p+d} E(y_{t+h-p-q}) - \theta_1 E(a_{t+h-1}) - \theta_2 E(a_{t+h-2}) - \dots - \theta_q E(a_{t+h-q}) + E(a_{t+h})$$

$$E(y_{t+h}) = \hat{y}_t = \theta_1 E(a_{t+h-1}) - \theta_2 E(a_{t+h-2}) - \dots - \theta_q E(a_{t+h-q}) + E(a_{t+h})$$

$$\theta_1 E(a_{t+h-1}) - \theta_2 E(a_{t+h-2}) - \dots - \theta_q E(a_{t+h-q}) + E(a_{t+h})$$

, h= 1,2,.....
: $\hat{y}_t$

القيمة التقديرية للملاحظات الحقيقية

وبالإمكان تقييم النموذج بعد التنبؤ من خلال حساب الفرق بين مشاهدات السلسلة الحقيقية والقيم التقديرية للسلسلة الزمنية والذي يعرف بخطأ التنبؤ :

$$e_t = y_t - \hat{y}_t$$

3-2 : الشبكات العصبية الاصطناعية Artificial Neural Network (ANN)

عبارة عن نظام مصمم لمحاكاة الطريقة التي يؤدي بها العقل البشري مهمة معينة [5] إذ يُعد أسلوب جديد في تحليل البيانات وتشخيصها وحساب التنبؤ لها وإن الخلية العصبية الاصطناعية تتكون من وحدة عناصر المعالجة التي تحتوي على جزئين هما :

1- دالة المجمع net function : وتحدد طريقة وصيغة إدخال المعلومات إلى الشبكة العصبية والتي تعرف بالمدخلات وغالباً ما تكون عبارة عن تركيبة خطية (Linear combination) بدلالة الأوزان وتوصف :

$$a = f(n)$$

$$n = b + \sum_{j=1}^R w_j P_j \dots\dots\dots(2)$$

a : المخرجات المقدرة للشبكة العصبية

b : الحد المطلق (الثابت) bias

w_j : الأوزان المرتبطة بالمدخلات وهي تقابل المعلومات في نموذج الانحدار

P_j : متغيرات الإدخال

$f(\bullet)$: دالة التنشيط المستعملة

2- دالة التنشيط (الفعالية) Activation function

وتعرف أيضاً بدالة التحويل (transfer function) لأنها تقوم بتحويل المدخلات عبر تفاعلها مع المتغيرات التوضيحية من صيغة رياضية إلى أخرى وهي على عدة أنواع منها الخطية وغير الخطية وتمتاز بتحديد نوع العلاقة ما بين المدخلات والمخرجات عند كل عقدة من عقد الشبكة. ومن دوال التنشيط ما يلي :

1- الدالة اللوجستية Log- sigmoid function : [15]

تعد هذه الدالة الأكثر استعمالاً في عقد الطبقة المخفية للشبكات العصبية ومدخلاتها عبارة عن قيم حقيقية بين $(-\infty, \infty)$ أما مخرجات الدالة لكل عقدة من عقد الشبكة تكون ما بين $(0,1)$ وتكون صيغة الدالة :

$$f(n) = (1 + e^{-nT})^{-1}$$

إذ أن (T) تمثل معلمة افتراضية (Temp parameter)

2- الدالة الخطية Linear function :

تستعمل هذه الدالة غالباً عند طبقة الإخراج وصيغتها :
إذا أن المدخلات قيم حقيقية وناتج الدالة لا يتغير

$$a = f(n) = n$$

3- دالة التحويل المحددة Hard limit transfer function :

صيغة هذه الدالة توصف كالآتي :
 $a = \begin{cases} 1 & , n \geq 0 \\ 0 & , n < 0 \end{cases}$

4- دالة العتبة Threshold (Heaviside) function :

توصف الدالة كما يلي :
 $a = \begin{cases} 1 & , n \geq 0 \\ -1 & , n < 0 \end{cases}$

وتعرف هذه الدالة أيضاً بـ (symmetrical hard limit function)

5- الدالة اللوجستية ثنائية القطب Hyperbolic tangent function : [15]

تكون صيغة الدالة كما يلي :
 $f(n) = \tanh(n/T) = 1 - 2(1 + e^{2n/T})^{-1}$

3-3 : تعديل البيانات Data normalization [7]

وهي عملية تهيئة البيانات قبل معالجتها (pre- processing) لإستعمالها في عملية تدريب الشبكة العصبية لذلك لا بد من أن تكون هذه البيانات ضمن نطاق عمل دالة التنشيط المستعملة إذ تحقق متطلبات مدخلات الشبكة. وهناك عدة طرق للتهيئة منها :

1- الصيغة المبسطة Simple formula

2- الصيغة المعيارية Standarized formula

3- الصيغة الطبيعية normalized formula

4- الصيغة الطبيعية المعدلة Adjusted normalized formula

3-4 : قاعدة هب The Hebb Rule

تعد قاعدة هب أول قاعدة لتعليم الشبكات العصبية الاصطناعية وقد وضعت من قبل العالم Donald Hebb عام 1949 كآلية لوصف مناطق الاتصال (Synapse) في الدماغ [13] أو نقاط الاشتباك العصبي إذ تمتاز بقدرتها على نقل مختلف الكميات من الإشارات وهي بذلك تشابه في عملها عمل الصمام في الجهاز الذي يسمح بمرور كميات مختلفة من الوقود أو السائل خلاله ومن الممكن تحسين نقاط الاشتباك العصبي وتقويتها للإستلام والإرسال إذ يتم إعطائها أوزان معينة للدلالة على قوة تلك النقاط ثم تقوم الخلية العصبية بجمع تلك الإشارات الموزونة ويُمَرَّر هذا المجموع خلال دالة غير خطية وعند وصولها إلى عتبة معينة فإن الخلية تطلق إشارة تمثل مخرجات الشبكة [3] ويحدد متجه المخرجات (a) من قبل متجه متغيرات الإدخال (P) وبالصيغة :

$$a = W P$$

أو

$$a_i = \sum_{j=1}^R w_{ij} P_j \dots\dots\dots(3)$$

للعناصر :

ومن المعادلة (3) يمكن ملاحظة إن الربط ما بين المدخلات والمخرجات هو عبارة عن الوزن (w_{ij}) فإذا كانت قيمة كل من (P_j) و (a_i) موجبة عند ذلك فإن (w_{ij}) سوف تزداد والعكس صحيح وهذا يقود إلى الوصف الرياضي لقاعدة هب العامة وحسب الصيغة :

$$w_{ij}^{new} = w_{ij}^{old} + \alpha f_i(a_{iq}) f_j(P_{jq}) \dots\dots\dots(4)$$

P_{jq} : عبارة عن العنصر j^{th} وللمشاهدة q^{th} من المدخلات

a_{iq} : عبارة عن العنصر i^{th} من مخرجات الشبكة و α : معدل التعلم

وإن قيمة معدل التعلم $0 < \alpha < \frac{1}{\lambda_{\max}}$ ، إذ أن أكبر جذر أصم (مميز) في مصفوفة الأوزان . ويعد معدل التعلم من العوامل المؤثرة على عملية تحديث الأوزان في الشبكة من خلال تحديد حجم الخطوة للتعلم وبالتالي تقليل الأخطاء وتغيير الوزن [2] فإذا كانت قيمة معدل التعلم كبيرة فإن تغيير الوزن سيكون بشكل كبير مع انخفاض التكرارات لعملية التدريب للحصول على خطأ مقبول أما إذا كانت قيمة معدل التعلم صغيرة فإن عملية التعلم ستكون بطيئة والتغيير في الوزن سيكون صغير مما يجعل معدل الوصول إلى أقل خطأ بطيء فضلاً عن إزدياد عدد التكرار في عملية التدريب وعموماً فإن تحديد القيمة المثلى لهذا المعدل تعتمد على طبيعة البيانات وكثرة التجارب [1][3]

وإن صيغة المعادلة (4) هي حاصل ضرب دوال التنشيط ولإجل التبسيط يمكن كتابة المعادلة بدلالة متجه المدخلات ومتجه المخرجات ولعنصر الوزن بالعلاقة :

$$w_{ij}^{new} = w_{ij}^{old} + \alpha a_{iq} P_{jq}$$

3-4-1 : قاعدة هب للتعليم بغير مشرف عام unsupervised learning

تعد قاعدة هب المعرفة بالصيغة (4) بمثابة قاعدة تعلم من دون مشرف عام فهي لا تتطلب أي معلومات تخص مخرجات الهدف وتنظم البيانات المقدمة للشبكة ذاتياً عندها تنفج مصفوفة الأوزان كما يلي : [11]

$$W^{new} = W^{old} + \alpha a_q P_q^T$$

إذ تكون مجموعة التدريب في هذه الطريقة عبارة عن متجهات المدخلات فقط من دون عرض الهدف على الشبكة . [5]

3-4-2 : قاعدة هب للتعليم بوجود مشرف عام supervised Hebbian learning

في قاعدة التعلم بوجود مشرف يتم التعامل مع البيانات التدريبية أمام الشبكة على هيئة زوج يتمثل بمتجه الإدخال ومتجه الإخراج عندها تعالج الشبكة مدخلاتها وتقارن مخرجاتها الناتجة مع مخرجات الهدف المطلوبة [5] والإختلاف بينهما يمثل خطأ عملية التدريب وللقيام بعملية تعديل الأوزان يتم تعويض مخرجات الهدف بمخرجات الشبكة وتكون صيغة معادلة التحديث بدلالة $(\alpha=1)$ كالآتي :

$$w_{ij}^{new} = w_{ij}^{old} + t_{iq} P_{jq}$$

وتكتب بدلالة المصفوفات ولكل أوزان الشبكة :

$$W^{new} = W^{old} + t_q P_q^T \dots\dots\dots(5)$$

3-5 : الشبكات متعددة الطبقات Multi- Layer Networks

إن عملية تدريب هذا النوع من الشبكات تكون معقدة وتستغرق وقت أطول ولكنها أكثر نجاحاً من الشبكات ذات الطبقة المفردة في حل بعض المشاكل وتتكون هذه الشبكات من طبقة واحدة أو أكثر من الطبقات المخفية (hidden layer) التي تحوي على عدد من العقد (الخلايا) المخفية (hidden nodes) ولكل من هذه العقد وزن يربطها مع المستوى السابق (طبقة الإدخال) ووزن يربطها مع المستوى اللاحق (طبقة الإخراج) [2][5]

وبذلك فإن العلاقة التي تصف النموذج العام تكون :

$$a^{m+1} = f^{m+1}(W^{m+1} a^m + b^{m+1}) \dots\dots\dots(6) , m=0,1,\dots,M-1$$

وإن : M : عدد الطبقات في الشبكة

f^{m+1} : دالة التنشيط المستعملة للطبقة $m+1$

a^{m+1} : متجه المخرجات للطبقة $m+1$

b^{m+1} : متجه الحد المطلق (bias) للطبقة $m+1$

W^{m+1} : مصفوفة الأوزان المرافقة للطبقة $m+1$

إذ أن العقد في الطبقة الأولى تستلم مؤشرات خارجية كمدخلات وبذلك فإن المخرجات عند الطبقة الصفرية تمثل مدخلات المتغيرات التوضيحية والتي عددها (R) وتعرف بـ :

$$a^0 = P , \quad P = \begin{bmatrix} P_1 \\ P_2 \\ \vdots \\ P_R \end{bmatrix}$$

وتُعد بمثابة نقاط البداية لتقدير معالم النموذج أما مخرجات العقد في الطبقة الأخيرة تشكل مخرجات الشبكة العصبية وتوصف : $a = a^M$

وإن خوارزمية الانتشار الخلفي (Back Propagation algorithm (BP) من الخوارزميات المهمة لتعليم الشبكات العصبية المتعددة الطبقات والتي استطاعت إيجاد الحلول للعديد من المشاكل خاصة فيما يتعلق بالتصنيف وتمييز الأنماط وبناء النماذج وإن أسلوب (BP) هو تقريب لخوارزمية (Steepest Descent) والتي يكون فيها مقياس الكفاءة هو متوسط مربعات الأخطاء (MSE) الذي يتم تقليصه عبر تقدير الأوزان لنموذج الشبكة العصبية من خلال تزويدها بمدخلات ومخرجات هدف مترافقة بالصيغة :

$$\{P_1, t_1\}, \{P_2, t_2\}, \dots, \{P_q, t_q\}$$

ويُعرف مقياس الكفاءة بالدالة التربيعية : [11] $F(X) = E(e^2) = E[(t-a)^2]$ إذ أن (X) هو متجه يتضمن الأوزان والحد المطلق للشبكة وعند وجود مخرجات مقدرة فإن :

$$F(X) = E(e^T e) = E[(t-a)^T (t-a)]$$

وعملية التعليم تكون على جانبين وذلك من خلال حساب الانتشار الأمامي Forward propagation وكذلك الانتشار الخلفي Backward propagation وفيما يلي وصف لإسلوب التعلم للانتشار الأمامي :

3-5-1 : الانتشار الأمامي Forward propagation [11]

وفيها يتم تعليم الشبكة العصبية ومعالجة البيانات من مدخلات الشبكة متعددة الطبقات وصولاً إلى المخرجات (طبقة الإخراج) إذ يمكن وصف المدخلات في العقدة (i) للطبقة المخفية (m) بالعلاقة :

$$n_i^m = b_i^m + \sum_{j=1}^{S^{m-1}} w_{ij}^m a_j^{m-1} \dots \dots \dots (7)$$

$$n_i^m = b_i^m + w_{i1}^m a_1^{m-1} + w_{i2}^m a_2^{m-1} + \dots \dots \dots w_{iS^{m-1}}^m a_{S^{m-1}}^{m-1}$$

S^{m-1} : عدد العقد في الطبقة المخفية (m-1)

وعند وجود طبقة مخفية واحدة وبعدد من العقد مساوياً لـ (S^1) فإن مخرجات هذه الطبقة توصف :

$$i=1,2,\dots,S^1 \dots \dots \dots (8)$$

$$a^1 = f_i^1(n_i^1)$$

إن صيغة المعادلة (8) تكون مدخلات إلى الطبقة الثانية (طبقة الإخراج) عندها يوصف النموذج :

$$a^2 = f^2\{b^2 + \sum_{i=1}^{S^1} w_i^2 f_i^1(b_i^1 + \sum_{j=1}^R w_{ij}^1 a_j^0)\} \dots \dots \dots (9)$$

وإن كل من $f^2(\bullet)$, $f^1(\bullet)$ هي دوال التنشيط المستعملة في النموذج للطبقة المخفية الأولى وطبقة الإخراج الثانية وعلى التوالي .

فإذا كانت دالة التنشيط المستعملة لعقدة طبقة الإخراج (الطبقة الثانية) هي الدالة الخطية وصيغتها :

$$f^2(a) = a$$

وعلى فرض إن عدد العقد في الطبقة المخفية مساوياً إثنان فإن النموذج (9) يوصف بالصيغة :


$$a^2 = f^2\{b^2 + w_1^2 f_1^1(n_1^1) + w_2^2 f_2^1(n_2^1)\} = b^2 + w_1^2 f_1^1(n_1^1) + w_2^2 f_2^1(n_2^1)$$

ومن خلال استعمال الدالة اللوجستية كدالة تنشيط للعقد المخفية فإن العلاقة الرياضية توصف بالأسلوب :

$$a^2 = b^2 + w_1^2 \left\{ (1 + \exp(-b_1^1 - \sum_{j=1}^R w_{1j}^1 a_j^0))^{-1} \right\} + w_2^2 \left\{ (1 + \exp(-b_2^1 - \sum_{j=1}^R w_{2j}^1 a_j^0))^{-1} \right\}$$

ويمكن تمثيل الشبكة العصبية للصيغة أعلاه في الشكل (2-8) :

شكل (2-8)
" يوضح الشبكة العصبية بطبقة مخفية واحدة "



ومن خلال طريقة (Steepest Descent) فإن التعديل على أوزان الشبكة وبصيغة المصفوفات يكون وفق:

$$W^m(k+1) = W^m(k) - \alpha S^m(a^{m-1})^T \dots\dots\dots(10)$$

$$b^m(k+1) = b^m(k) - \alpha S^m \dots\dots\dots(11)$$

αS^m

إذ أن (S^m) تمثل مقدار التحسس (Sensitivity) للدالة التقريبية $(\hat{F})$ لعقد الإدخال في الشبكة وعند الطبقة (m)

$$S^m = \frac{\partial \hat{F}}{\partial n^m}$$

$$S^m = \left[\frac{\partial \hat{F}}{\partial n_1^m} \quad \frac{\partial \hat{F}}{\partial n_2^m} \quad \dots \quad \frac{\partial \hat{F}}{\partial n_{s^m}^m} \right]$$

وإن

3-6 : طرق التعديل على أسلوب (BP) modifications of back propagation (BP)

توجد عدة طرق افترضت لغرض تعديل خوارزمية (BP) للحصول على الحل بأقل كلفة وبأقل مدة زمنية فعندما تمتلك نماذج الشبكات العصبية أعداداً كبيرة من المعالم (الأوزان) والتي يراد تعديلها فإن طريقة الحل من خلال خوارزمية (BP) تمتاز بأنها تكون بطيئة جداً لأغلب التطبيقات [14] فضلاً عن أن خوارزمية (SD) تُعد طريقة بطيئة لتصغير الدوال والتوصل إلى الحل الأمثل عند ذلك تم إقتراح مجموعة من التعديلات على طريقة (BP) ومنها ما يلي :

3-6-1 : التعديلات الإرشادية (BP) Heuristic modifications of (BP) [11]

وتشمل هذه الطريقة عدة أساليب منها :

- 1- أسلوب الدفع Batching
- 2- أسلوب الزخم Momentum
- 3- معدل التعلم المتغير Variable Learning rate

3-6-2 : طرق الأمثلية العددية Numerical optimization techniques

إن هذه الطرق قائمة على تعديل طريقة الانتشار الأمامي وبالإعتماد على الأساليب العددية إذ يتم الوصول إلى الحل الأمثل بأسرع وقت وبأقل عدد من التكرارات ومن هذه الطرق ما يلي :

1- طريقة التدرج المترافق Conjugate Gradient

تعد خوارزمية (Steepest Descent) أبسط خوارزمية للتوصل إلى الحل الأمثل للدالة ولكنها تمتاز ببطئ التقارب إلى الحل الأمثل، أما طريقة نيوتن فهي تعد طريقة سريعة للحصول على الحل الأمثل إلا أن العمليات التكرارية لها تتطلب حساب مصفوفة هيس ومعكوسها إذ أن طريقة نيوتن تحوي على خاصية

تدعى النهاية التربيعية (quadratic termination) وتعني تصغير الدالة التربيعية بصورة مؤكدة في عدد محدد من التكرارات، إذ تتطلب حساب وخزن المشتقة الثانية لدالة الهدف ولكن عندما يكون عدد المعالم كبير فإن عملية التقدير تكون غير عملية في حساب المشتقة الثانية لذلك يتم اعتماد طريقة (Conjugate Gradient) والتي تستعمل فيها المشتقة الأولى فقط وفي نفس الوقت تمتلك خاصية النهاية التربيعية إذ أن التعديل على طريقة الانتشار الأمامي وفق هذه الطريقة يكون من خلال خوارزمية (CGBP) Conjugate Gradient Back Propagation والتي تتلخص بما يلي :

يتم اختيار أول اتجاه للبحث عن الحل الأمثل والذي يتمثل بالاتجاه (P_0) والذي يساوي سالب التدرج أو الميل إذ أن :
 $P_0 = -g_0$
 وإن $g_0 = \nabla F(x)$ يمثل مشتقة دالة الهدف التي ينبغي تصغيرها عند النقاط (x_k)

ثم يتم اختيار معدل تعلم غير ثابت (α_k) لتصغير دالة الهدف ضمن اتجاه البحث عندها فإن التعديل على الأوزان والمتغيرات يكون بالصيغة :

$$x_{k+1} = x_k + \alpha_k P_k \quad (12)$$

وإن $\alpha_k = \frac{-g_k^T P_k}{P_k^T A P_k}$:
 A : تمثل مصفوفة هيس

بعدها يتم حساب الخطوة التالية للبحث ويكون من خلال تحديث المتغير (P_k) بالعلاقة :
 $P_k = -g_k + \beta_k P_{k-1}$

ويمكن ملاحظة أن التحديث أعلاه يرتبط مع (β_k) والتي يتم تحديدها بأحدى الطرق الثلاثة التالية : [9]
 - طريقة (Hestenes and steifel) وفق العلاقة :

$$\beta_k = \frac{\Delta g_{k-1}^T g_k}{\Delta g_{k-1}^T P_{k-1}}, \quad \Delta g_k = g_{k+1} - g_k$$

$$\beta_k = \frac{g_k^T g_k}{g_{k-1}^T g_{k-1}} \quad \text{طريقة (Fletcher and Reeves) وفق العلاقة :}$$

$$\beta_k = \frac{\Delta g_{k-1}^T g_k}{g_{k-1}^T g_{k-1}} \quad \text{طريقة (Polak and Ribiers) وفق العلاقة :}$$

وإذا كانت الخوارزمية لا تتقارب إلى الحل الأمثل فإنه يتم تكرار العملية بالإعتماد على آخر مرحلة لتقدير المعالم من خلال حساب (x_{k+1}) جديدة .

2- خوارزمية ليفنبرك- ميركوارد Levenberg- Marquardt algorithm [7]
 إن خوارزمية L-M تعد تعديل لطريقة نيوتن إذ تعمل على تصغير دالة مجموع مربعات الأخطاء (SSE) لدوال غير خطية والموصوفة في تدريب نماذج الشبكات العصبية التي يكون مقياس الكفاءة فيها متوسط مربعات الأخطاء وأن صيغة خوارزمية (L-M) توصف :

$$x_{k+1} = x_k - [J^T(x_k) J(x_k) + \mu I]^{-1} \cdot J^T(x_k) V(x_k) \quad (13)$$

إذ أن $J(x_k)$: عبارة عن مصفوفة لمشتقات دالة الأخطاء بالنسبة للأوزان والحد المطلق
 $V(x_k)$: دالة الخطأ

وأن الخوارزمية تمتلك مواصفات جيدة إذ إنه بزيادة (μ_k) فإن الأسلوب يقترب من خوارزمية (SD) وبمعدل تعلم ذو قيمة صغيرة أما بأنخفاض (μ_k) فإن الخوارزمية تقترب من طريقة كاوس- نيوتن ويمكن ذلك باختيار قيمة صغيرة له ولتكن (0.01) .

3-7 : مراحل التنبؤ من خلال الشبكات العصبية الاصطناعية Forecasting of ANN [10]

إن عملية التنبؤ من خلال الشبكات العصبية الاصطناعية تتناول الخطوات التالية :

- 1- تحديد المتغيرات Variables Selection
 - 2- جمع البيانات Data Collocation
 - 3- تهيئة البيانات للتنبؤ Data Preparation for Forecasting
- تتضمن هذه المرحلة إعداد البيانات لإستعمالها في التحليل والتنبؤ والمذكورة في الفقرة (3-3) فضلاً عن تحديد كيفية تجزئة السلسلة الزمنية إلى :
- مجموعة التعلم training set : وهي مجموعة من بيانات السلسلة الزمنية تستعمل لتدريب الشبكة على التنبؤ إذ تستعمل هذه المجموعة في تقدير الأوزان وإن عدد النماذج في مجموعة التعلم كما وصفها Haykin (1995) والتي تتطلب تصنيف المشاهدات بخطأ مقبول (ϵ) توصف $N = \frac{\epsilon}{w}$ ، إذ (w) تمثل عدد الأوزان في الشبكة . [14]
 - مجموعة الاختبار test set : وهي جزء من بيانات السلسلة الزمنية ولعينة لم تستعمل في التدريب تقوم باختيار قابلية الشبكة على التنبؤ بعد عملية التعليم ولا يوجد أساس علمي لتحديد تجزئة البيانات إلى مجموعتين تعلم واختبار ، فقد تؤخذ 90% من بيانات السلسلة للتعلم و 10% للاختبار أو تكون 50% للتعلم و 50% للاختبار وبعض البرامجيات تحدد 70% للتعلم و 30% للاختبار . [7]
 - مجموعة التقييم validation set : تقوم بمراقبة نهائية لتقييم أداء تدريب الشبكة العصبية بصورة عامة وإن إختيار عدد بيانات هذه المجموعة يجب أن يكون مناسب لتقييم كلاً من التدريب والاختبار وذلك للتوصل إلى أفضل تنبؤ . [10]

4- تحديد معمارية الشبكة [7] Network Architecture Determination
يمثل الجزء الأساس لبناء هيكل الشبكة العصبية إذ يتطلب من مصمم الشبكة مهارة عالية وخبرة تجريبية في تحديد العوامل وذلك من خلال إختيار نوع الشبكة ولتحديد المعمارية يتم إتباع الخطوات التالية :

- تحديد عدد عقد الإدخال للشبكة determination of input nodes
- إختيار عدد الطبقات المخفية selection of number of hidden Layer
- إختيار عدد العقد في الطبقة المخفية selection of hidden neurons

5- تحديد عقد الإخراج [10] Determination of output nodes
إن وجود عقدة إخراج واحدة تعد كافية في حالة التنبؤ بخطوة واحدة في الشبكة العصبية أما في حالة التنبؤ لعدة خطوات فإن عدد العقد يكون مناظر وبصورة موازية لخطوات التنبؤ اللاحقة كما وأثبتت التجارب إن إستعمال عقدة واحدة يعطي نتائجاً جيدة مقارنةً مع إستعمال أكثر من عقدة إخراج

6- تحديد وإختيار دوال التنشيط Selection of Activation functions of neurons

7- تدريب الشبكة العصبية Neural Network Training
إن عملية تدريب الشبكات العصبية على التنبؤ تتم من خلال تعديل أوزان الشبكة للحصول على أقل خطأ بالاعتماد على خوارزمية الانتشار الخلفي (BP) وتعديلاتها ومن أهم خطوات تدريب الشبكة هي :

- تحديد قيم الأوزان الأولية select the weight initialization
- معدل التعلم وعامل الزخم Learning rate and momentum
- معيار التوقف stopping criterion

8- التنفيذ Implementation
وتعد الخطوة الأخيرة ومن أهم الخطوات إذ تختبر الشبكة من حيث قدرة التكيف مع حالة التغير في الدورة وإمكانية إعادة التدريب والوصول إلى أقل مربع خطأ عند تغير البيانات وتعتمد على البرنامج المستعمل والمزود بوسائل لتدريب الشبكة العصبية . [10]

4- الجانب العملي Applicative Side


يتضمن هذا الفصل تحليل البيانات الخاصة بمعدلات تصاريف المياه بوحدة م³/ثا الواردة والمطلقة لسد الموصل وقد تم الحصول على البيانات من وزارة الموارد المائية / المركز الوطني لإدارة الموارد المائية وإن التحليل الإحصائي لهذه السلاسل قسّم إلى ثلاث جوانب رئيسية :

- بناء نماذج السلاسل الزمنية وبالتحديد إنموذج بوكس- جنكينز لبيانات وارد ومطلق المياه للسد مع إختيار عدة نماذج وفق منهجية هذا الأسلوب وتشخيص الإنموذج الملائم والأفضل من خلال حساب المقاييس الإحصائية
- بناء نماذج الشبكات العصبية الاصطناعية بإستعمال خوارزمية الانتشار الخلفي بعد تحديد معمارية مختلفة للشبكة إذ تعتمد على عدد متغيرات الإدخال والطبقات المخفية وعدد العقد في كل طبقة مخفية ودوال التنشيط الخطية وغير الخطية المستعملة في تدريب الشبكة العصبية لإختيار أفضل قيم للأوزان والتي تقابل أقل خطأ ممكن للحصول على التنبؤات والتمثلة بمخرجات الشبكة العصبية
- بناء نماذج الإنحدار الخطي المتعدد بمتغيرات توضيحية مزاحة زمنياً لكل من السلاسل الزمنية لوارد ومطلق مياه السد وإختبار هذه النماذج وبيان أفضلها مع مقارنة النماذج ضمن كل جانب من جوانب التحليل السابقة بالإعتماد على المقاييس الإحصائية وإختيار الإنموذج الملائم لكل طريقة بعدها تمت المقارنة بين نماذج الطرق الثلاثة (بوكس- جنكينز، الشبكات العصبية، الإنحدار الخطي المتعدد) لمعرفة كفاءة هذه الأساليب وفق بعض المقاييس الإحصائية للتوصل إلى أفضل طريقة وإنموذج للتنبؤ.

4-1 : نماذج بوكس- جنكينز لتحليل السلاسل الزمنية لوارد ومطلق المياه لسد الموصل :
إن الخطوة الأولى لوصف وتحليل السلسلة الزمنية هو رسمها إذ يمكن ملاحظة مكوناتها الأساسية كالإتجاه العام والموسمية والدورية ولتحقيق ذلك تم الإعتماد في هذا الفصل على تطبيق البرنامجين (MINITAB 14 & SPSS 18) لتحليل البيانات الخاصة بالمعدلات الشهرية لتصاريف المياه الواردة والمطلقة لسد الموصل للمدة (1987-2010) وبعد رسمهما تبين عدم وجود إتجاه عام إلا إن التغيرات الموسمية واضحة فيها وبطول موسم (S =12) كما في الأشكال (4-1) و (4-2) :


شكل (4-1)

" السلسلة الزمنية لمعدلات تصاريف المياه الواردة لسد الموصل "



شكل (4-2)

" السلسلة الزمنية لمعدلات تصاريف المياه المطلقة لسد الموصل "



وبحساب معاملات الارتباط الذاتي (ACF) والارتباط الذاتي الجزئي (PACF) تم تأكيد عدم استقرارية السلسلتين الزمنية لوارد ومطلق السد لذلك كان لا بد من أخذ الفروقات اللازمة للسلاسل الأصلية لتحقيق الاستقرار في المتوسط وكذلك بالإمكان استعمال التحويلات اللوغاريتمية لغرض تحقيق الاستقرار في التباين عندها تصبح السلسلة الزمنية لوارد السد ومطلق السد مهيئة للتحليل لذا تم أخذ الفرق الأول الاعتيادي والأول الموسمي ($\nabla \nabla_{12}$) وبطول موسم 12 من دون التعامل مع التحويل اللوغاريتمي وبإعادة احتساب المعاملات تبين تحقيق الاستقرار وبعد فحص معاملات الارتباط الذاتي تبين إن النموذج الملائم لوارد ومطلق السد هو النموذج الموسمي المضاعف ولزيادة دقة تشخيص النموذج تم احتساب وتوفيق نماذج أخرى قريبة من النموذج المحدد فضلاً عن مقاييس تلك النماذج والجدول (4-1) يوضح هذه النماذج وأفضلها من ناحية التقدير والمتمثل بالنموذج SARIMA (0,1,1)x(0,1,1)

جدول (4-1)

" نماذج بوكس- جنكينز الموفقة لوارد ومطلق المياه لسد الموصل "

سد الموصل	النموذج	المعالم المقدرة	R ²	SSE	$\hat{\sigma}$	AIC	BIC	SBC
وارد السد	1- (0,1,1)x(0,1,1) ₁₂	MA= 0.2204 SMA= 0.9365	76%	66.36	0.493	-387	-378	-380
	2- (1,1,0)x(0,1,1) ₁₂	AR= - 0.135 SMA= 0.9280	75%	67.16	0.496	-384	-375	-377
	3- (0,0,1)x(0,1,1) ₁₂	MA= - 0.5377 SMA= 0.9427	74%	67.41	0.497	-383	-374	-376
	4- (0,0,0)x(0,1,1) ₁₂	SMA= 0.9492	61%	100.88	0.607	-274	-269	-269
	5- (1,1,1)x(0,0,1) ₁₂	AR= - 0.1391 MA= - 0.2545 SMA= - 0.3985	58%	119.17	0.662	-224	-210	-229
مطلق السد	1- (0,1,1)x(0,1,1) ₁₂	MA= 0.1655 SMA= 0.9591	49%	134.38	0.699	-193	-184	-186
	2- (1,1,0)x(0,1,1) ₁₂	AR= - 0.0959 SMA= 0.9573	48%	136.15	0.706	-189	-180	-182
	3- (0,0,1)x(0,1,1) ₁₂	MA= - 0.6109 SMA= 0.9605	47%	151.56	0.742	-160	-151	-153
	4- (0,0,0)x(0,1,1) ₁₂	SMA= 0.9670	12%	208.19	0.872	-75	-70	-70
	5- (1,1,1)x(0,0,1) ₁₂	AR= 0.7135 MA= 0.9993 SMA= - 0.2701	51%	141.21	0.721	-177	-163	-166

ومن خلال جدول (4-1) نلاحظ ارتفاع قيمة معامل ($R^2=76\%$) بالنسبة للنموذج الملائم لوارد السد صاحبه انخفاض في مجموع مربعات البواقي وإن المقاييس AIC و BIC و SBC تأخذ أقل القيم وأفضلها كان لمقياس AIC حيث بلغ -387.

أما النموذج الموسمي رقم (1) فهو الأفضل للسلسلة الزمنية الخاصة بمطلق السد وفق المقاييس AIC و BIC و SBC ولكن بالمقابل فإن قيمة ($R^2=49\%$) وهذا يشير إلى انخفاض درجة تفسير النموذج للبيانات مقارنة بالنموذج السابق .

وبمعرفة الارتباط بين المعلمة الاعتيادية والموسمية للنموذج وجد إن الارتباط ضعيف ويبلغ - (0.095) لوارد السد مما يعني إستقلالية كل معلمة في التأثير على النتائج ويعكس ذلك عدم إمكانية تجاهل

أي منهما في الإنموذج وذلك يدل على كفاءة الإنموذج وأيضاً فإن ارتباط المعلمتين لمطلق السد ضعيف إذ يساوي (- 0.045) ويشير إلى اعتمادية المعالم وبالتالي جودة الإنموذج الموفق .
وقد وُصفت النماذج الموسمية المختارة في جدول (4-2) :

جدول (4-2)


" نماذج بوكس- جنكينز المختارة لوارد ومطلق المياه لسد الموصل "

سد الموصل	النموذج	ME	MAE	MAPE	Box - Pierce	$\chi^2_{(0.05,17)}$
وارد السد	$(1 - B)(1 - B^{12})y_t$ $= (1 + 0.2204 B)(1$ $+ 0.9365 B^{12})a_t$	0.001	0.316	222.33	33.83	8.67
مطلق السد	$(1 - B)(1 - B^{12})y_t$ $= (1 + 0.1655 B)(1$ $+ 0.9591 B^{12})a_t$	0.074	0.439	181.06	28.48	

وبالاعتماد على النماذج في جدول (4-2) تم رسم القيم التنبؤية الموفقة من خلال إنموذج بوكس- جنكينز المضاعف مع قيم السلسلة الزمنية الأصلية في الشكل (4-3) و (4-4) لوارد ومطلق سد الموصل :


شكل (4-3)

" يوضح مطابقة الإنموذج مع بيانات السلسلة الزمنية لوارد سد الموصل "




شكل (4-4)

" يوضح مطابقة النموذج مع بيانات السلسلة الزمنية لمطلق سد الموصل "



4-2 : نماذج الشبكات العصبية لتحليل السلاسل الزمنية لوارد ومطلق المياه لسد الموصل:
تم إستعمال منهجية الشبكات العصبية لتحليل السلاسل الزمنية لوارد ومطلق المياه لسد الموصل إذ أعتمد على إحدى أنواع الشبكات العصبية الاصطناعية (ANN) والمستعملة في الدراسة وهي الشبكات متعددة الطبقات Multilayer Perceptron ذات التغذية الأمامية Feed Forward وبطبقة مخفية واحدة لغرض التنبؤ بالقيم المستقبلية للسلاسل الزمنية من خلال إستعمال دوال التنشيط الخطية وغير الخطية للبيانات السابقة فالشبكات العصبية بصورة عامة تُعد كصيغة للبحث عن إنموذج شبه معلمي غير خطي

ولتحديد معمارية الشبكة تم اختيار متغيرات الإدخال (مدخلات الشبكة) لبيانات السلسلة من y_{t-1} إلى y_{t-13} والمتغيرات المتداخلة بينها فقد تم اختيار متغيرات الإدخال عند الإزاحة (1) و(12) والمتمثلة بالمتغيرين (y_{t-1}, y_{t-12}) ولعقدتين في الطبقة المخفية (وحدة المعالجة) بدالتي تنشيط غير خطية هي الدالة اللوجستية والمسؤولة عن العمليات الرياضية وحساب الأوزان وتعديلها أما القيمة التنبؤية $(\hat{y}_t)$ فتمثل مخرجات الشبكة العصبية وتُعرف بدالة خطية وبما إن النموذج للشبكة يزود بالمدخلات والمخرجات فإن تدريب الشبكة يكون من نوع مشرف عام **Supervised Learning** إذ يتطلب معرفة النموذج المرافق للإدخال والإخراج معاً ويمكن تمثيل هذه الشبكة بالشكل (4-5) لبيانات السلسلة الزمنية لوارد ومطلق سد الموصل كما يلي :



ومن خلال الشكل نلاحظ إن متغيرات الإدخال مرتبطة بعقد الطبقة المخفية والتي عددها (2) وكلاهما مرتبطتان بعقدة الإخراج وإن قوة العلاقة ما بين العقد سواء كانت للإدخال والإخراج يتحدد من خلال الأوزان (w_{ij}) والتي نسعى إلى حسابها من خلال عملية تدريب (تقدير) الشبكة العصبية إذ تكون صيغة الإدخال للبيانات عبارة عن تركيبة خطية وتتمثل بالمعادلة (2) وإن متغيرات الإدخال في النموذج تمثل

$p_0 = 1, p_1 = y_{t-1}, p_2 = y_{t-12}$
وللقيام بعملية التدريب تم تجزئة بيانات السلسلة الزمنية لوارد ومطلق السد والمتكونة من (288) مشاهدة لكل سلسلة إلى (70%) بيانات التدريب (تقدير) و(30%) للإختبار ويمكن تغيير هذه النسب بما يلائم بيانات الإدخال وتحديد معدل للتعلم $(\alpha = 0.4)$ ومعامل الزخم $(\gamma = 0.9)$ بقيم أولية عشوائية للأوزان إذ يُعد مجموع هذه الأوزان المضروبة مع قيم متغيرات الإدخال كمدخلات لتركيبية خطية وتؤخذ هذه المدخلات إلى دالة التنشيط اللوجستية في عقدتي الطبقة المخفية إلا إن ذلك يتطلب تهيئة البيانات بصورة أولية من خلال تحويلها إلى إحدى الصيغ المذكورة بالفقرة (3-3) إذ تم إستعمال الصيغة المعيارية لتحقيق مدى هذه الدالة الذي يكون ما بين (0,1) لإجراء العمليات الحسابية للتقدير فضلاً عن وجود الحد الثابت (bias) أو التحيز لكل من العقد المخفية فيوصف ناتج هذا العقد بـ (a_1^1) و (a_2^1) وبنفس الأسلوب تم تطبيق العلاقة الخطية **Linear activation function** التي تجمع ما بين الطبقة المخفية وطبقة الإخراج بدلالة المتغيرات (a_1^1) و (a_2^1) إذ توصف المعادلة التنبؤية عند الفترة الزمنية t بالعلاقة التالية :

$$\hat{y}_t = f^2 \{ b^2 + \sum_{i=1}^2 w_i^2 f_1^1 (b_1^1 + \sum_{j=1}^R w_{ij}^1 y_{t-ij}) \}$$

وهي تمثل الصيغة (9) وبشكل أكثر تفصيلاً فإن النموذج الذي نسعى إلى تقديره وبدوال التنشيط اللوجستية ودالة إخراج خطية يوصف :

$$\hat{y}_t = b^2 + w_1^2 \left\{ (1 + \exp(-b_1^1 - \sum_{j=1}^R w_{1j}^1 \cdot a_j^0))^{-1} \right\} + w_2^2 \left\{ (1 + \exp(-b_2^1 - \sum_{j=1}^R w_{2j}^1 \cdot a_j^0))^{-1} \right\}$$

ولإجل تنظيم عملية التحليل وبناء النماذج تم إستعمال الصيغة $(NN(j_1, j_2, \dots, j_k; h))$ والتي تشير إلى الشبكة العصبية بمدخلات مزاحة زمنياً للمدة $(j_1, \dots, j_k)$ وإن (h) عدد العقد في الطبقة المخفية وعليه فنعني بالعلاقة $NN(1, 12; 2)$ نموذج الشبكة العصبية المتكون من مدخلين وبعدة مخفية عددها (2) وإن تقدير الأوزان في الشبكة العصبية يكون عبر تصغير مجموع مربعات الأخطاء للنموذج الموفق بتكرار معين خلال مرحلة التدريب ولكن هذا ليس بالأمر السهل إذ إن عدد الأوزان يتزايد فضلاً عن إن دالة الهدف تمتلك عدة نقاط موضعية (Local minima) فقد تم التعامل مع عدة طرق وخوارزميات للبحث

والوصول إلى الحل الأفضل، ولأن معظم هذه الطرق تتطلب عدة عمليات تكرارية للإقتراب من الحل الأمثل لذا تم إستعمال وتطبيق خوارزمية الانتشار الخلفي (BP) لتدريب دالة الهدف الغير خطية وإستعمال طريقة كاوس- نيوتن Gauss- Newton كطريقة تكرارية وصولاً إلى الحل الأمثل .
فضلاً عن إن عدد المعالم (الأوزان) في نماذج الشبكات العصبية يكون كبير جداً بالمقارنة مع الطرق التقليدية للتنبؤ ومنها أسلوب بوكس- جنكينز إذ يساوي عدد المعالم :

$$p = (n_i + 2)n_u + 1$$

وإن n_i : تمثل عدد متغيرات الإدخال بدون الحد الثابت و n_u : عدد العقد في الطبقة المخفية
فالإنموذج NN(1,12;2) فيه $n_i = n_u = 2$ عندها عدد المعالم يساوي (9) وبسبب هذا العدد الكبير من المعالم فإن عملية التدريب قد تؤدي إلى وقوع حالة فوق التدريب (overtrain) أي الحصول على تقدير جيد للمعالم ولكنه ليس الأفضل من ناحية التنبؤ وبذلك فإنه لا بد من إستعمال مقاييس الكفاءة مثل AIC و BIC ودوال الأخطاء للحصول على الإنموذج الأكفأ من خلال المقارنة بين هذه المقاييس وعند إزاحات مختلفة لمتغيرات الإدخال فقد تم بناء مجموعة من نماذج الشبكات العصبية بمتغيرات مزاحة زمنياً وتوضيحها في جدول (4-3) لوارد ومطلق السد :

جدول (4-3) " نماذج الشبكات العصبية لوارد ومطلق المياه لسد الموصل "

سد الموصل	نماذج الشبكات العصبية	عدد العقد في الطبقة المخفية	عدد المعالم	SSE	$\hat{\sigma}$	AIC	BIC	SBC	ME	MAE	MAPE
وارد السد	NN(1,12)	2	9	28.54	0.402	- 331	- 293	- 302	14.59	195.92	121.42
	NN (1,12)	4	17	27.63	0.404	- 321	- 249	- 266	- 34.59	194.62	128.16
	NN (1,12)	8	33	25.68	0.414	- 293	- 154	- 187	0.324	197.43	119.49
	NN (1-13)	2	31	24.14	0.392	- 324	- 193	- 224	7.325	174.08	107.23
	NN (1-13)	4	61	18.83	0.367	- 354	- 91	- 152	1.259	161.89	108.00
	NN (1,2,12,13)	2	13	24.53	0.381	- 346	- 291	- 304	10.95	178.73	112.74
	NN (1,2,12,13)	4	25	19.90	0.383	- 348	- 241	- 266	- 1.737	161.50	111.68
	NN (1,12,13)	2	11	24.07	0.372	- 354	- 309	- 320	- 7.119	192.36	117.03
	NN (1,12,13)	4	21	22.01	0.368	- 352	- 263	- 285	- 10.56	180.33	115.98
	NN (1,12,13)	8	41	20.23	0.379	- 318	- 155	- 187	0.336	171.64	108.77
مطلق السد	NN(1,12)	2	9	39.74	0.474	- 269	- 231	- 240	11.65	162.32	109.31
	NN (1,12)	4	17	36.18	0.457	- 281	- 209	- 226	6.776	162.02	110.49
	NN (1,12)	8	33	37.61	0.489	- 242	- 102	- 135	-0.249	162.44	112.32
	NN (1-13)	2	31	50.96	0.568	- 183	- 54	- 142	15.23	180.96	125.42
	NN (1-13)	4	61	31.43	0.254	- 206	- 51	-10	-18.04	170.65	111.92
	NN (1,2,12,13)	2	13	41.73	0.472	- 287	- 231	- 244	4.918	160.08	106.51
	NN (1,2,12,13)	4	25	37.25	0.483	- 247	- 141	- 166	- 1.436	158.84	109.21
	NN (1,12,13)	2	11	38.67	0.471	- 268	- 222	- 233	1.663	167.67	111.23
	NN (1,12,13)	4	21	34.02	0.451	- 279	- 190	- 211	3.297	155.51	109.75
	NN (1,12,13)	8	41	41.53	0.526	- 209	- 35	- 76	2.125	161.24	109.19

- ومن خلال الجدول لوارد ومطلق السد نلاحظ أن نماذج NN(1, 12) بالمتغيرات (y_{t-1}, y_{t-12}) يوضح انخفاض كفاءة النماذج بزيادة عدد العقد في الطبقة المخفية بدلالة المقاييس AIC و BIC و SBC إذ تزداد قيم هذه المقاييس بزيادة عدد العقد وعدد المعالم (الأوزان) مع ارتفاع قيمة $(\hat{\sigma})$ فضلاً عن زيادة فترة المعالجة
- أما النماذج NN(1, 2, 12, 13) لوارد السد فتؤكد أن زيادة عدد العقد وعدد المعالم لا يؤدي إلى توفيق إنموذج جيد لأن قيم مقاييس الكفاءة تزداد أو تكون متقاربة وذات فرق بسيط وإن الإنموذج الأفضل لوارد السد NN(1, 12, 13; 2) لإمتلاك المقاييس أقل القيم والإنموذج NN(1, 2, 12, 13; 2) هو الأفضل لمطلق السد وبالنسبة إلى النماذج NN(1-13) لوارد ومطلق السد فإنه يفضل الإنموذج NN(1-13; 2) بدلالة المقاييس BIC و SBC بينما يفضل الإنموذج NN(1-13; 4) بالإعتماد على مقياس AIC و $(\hat{\sigma})$ مما يدل على أن مقياس AIC لم يكشف الفروقات الجوهرية مقارنة بمقياس BIC الذي أشار بصورة واضحة إلى عدم جودة الإنموذج NN(1-13; 4) بارتفاع عدد المتغيرات والمعلم المقدرة مما يثبت أن بعض متغيرات الإدخال ذات أهمية قليلة في التحليل ولتحديد المتغيرات (متغيرات الإدخال) بصورة دقيقة يتم من خلال بناء إنموذج الشبكة العصبية NN(1-13; 2) للمتغيرات المزاحة y_{t-1} إلى y_{t-13} بثلاثة عشر متغير إذ وصفت أوزان هذا الإنموذج لوارد السد بالجدول (4-4) ومطلق السد بالجدول (4-5) ومنها نلاحظ ما يلي:
- إن الأوزان التي تربط متغيرات الإدخال بالعقدة المخفية الثانية تمتلك قيم صغيرة وقريبة من الصفر والخاصة بالمتغيرات ذات الإزاحة (2-11) وهذا يدل على عدم أهمية هذه المتغيرات وإنه بالإمكان اعتماد إنموذج الشبكة العصبية NN(1, 12; 2)
 - إن قيمة الأوزان لسلسلة وارد السد والتي تربط ما بين الطبقة المخفية وعقدة الإخراج هي (0.710) و (1.391) على التوالي، مما يدل على أن تأثير العقدة المخفية الثانية على المخرجات أكبر من الأولى وكذلك الحال لأوزان مطلق السد والتي تساوي (- 0.493) للعقدة الأولى و (0.926) للعقدة الثانية وهذا التحليل يوضح أن تحديد عقدتان في الطبقة المخفية كافٍ للحصول على إنموذج جيد .

جدول (4-4)
"أوزان الإنموذج (2 ; 1-13) NN لوارد سد الموصل"

العقد	1	2	3	4	5	6	7	8	9	10	11	12	13
1	0.801	-0.331	-0.201	-0.026	-0.358	0.261	-0.147	0.236	-0.118	0.417	-0.108	0.113	0.188
2	0.491	-0.023	0.081	0.054	0.043	-0.051	0.073	-0.435	-0.023	-0.136	0.190	0.271	-0.382

جدول (4-5)
"أوزان الإنموذج (2 ; 1-13) NN لمطلق سد الموصل"

العقد	1	2	3	4	5	6	7	8	9	10	11	12	13
1	-0.121	0.185	-0.503	0.018	0.569	-0.316	-0.138	0.38	-0.199	0.204	-0.198	-0.567	0.367
2	1.160	0.102	-0.559	0.074	0.043	-0.035	-0.503	0.025	0.113	0.055	-0.009	0.236	-0.258

ومن خلال مجموعة الاختبار (test set) التي تختبر مدى قوة الإنموذج على التنبؤ إذ إن الإنموذج يزودنا بتنبؤ خطوة واحدة وللحصول على التنبؤ لخطوات لاحقة تم استعمال التغذية الأمامية (Feed Forward) وفيها يُعد التنبؤ لخطوة واحدة كمتغير للمدخلات مع إعادة تطبيق نفس المعمارية للتنبؤ بخطوة أخرى وهكذا.....وقد تم الحصول على القيم التنبؤية للإنموذج (2 ; 1, 12) NN لوارد ومطلق سد الموصل بالجدول (4-6) :

جدول (4-6) "القيم المتنبئ بها وفق الإنموذج (2 ; 1, 12) NN لوارد ومطلق المياه لسد الموصل"

الفترة	القيم التنبؤية لمطلق السد	القيم التنبؤية لوارد السد
1	442	180
2	464	291
3	478	256
4	496	309
5	515	343
6	525	397
7	535	622
8	541	828
9	545	863
10	548	832
11	550	808
12	551	758

4-3 : نماذج الإنحدار الخطي المتعدد لتحليل السلاسل الزمنية لوارد ومطلق المياه لسد الموصل :
تم التطرق في هذا الجزء إلى أحد أساليب التقدير التقليدية وهو تحليل إنموذج الإنحدار الخطي المتعدد Multiple Linear Regression model لدراسة العلاقة بين بعض من المتغيرات التوضيحية المزاحة زمنياً $(y_{t-1}, y_{t-12}, y_{t-13})$ ومتغير الاستجابة (y_t) dependent variable ووصف هذه العلاقة على هيئة معادلة خطية وتم تقدير معالم الإنموذج باستعمال طريقة المربعات الصغرى (Least Squares method (OLS) إذ تتميز هذه الطريقة بأنها تقلص مجموع مربعات الخطأ أقل ما يمكن وبالتالي توفيق أفضل إنموذج يمثل هذه المتغيرات والجدول (4-7) يبين نماذج الإنحدار الخطية لوارد ومطلق السد :

جدول (4-7)

" نماذج الإنحدار الخطي المتعدد بمتغيرات توضيحية مزاحة زمنياً لسد الموصل "

النماذج		F	R ²
سد الموصل	وارد السد	209.2	70%
	مطلق السد	90.0	50%

وإن الجدول (4-8) يبين مقاييس الكفاءة لنماذج الإنحدار الخطي وكما يلي :

جدول (4-8)

" مقاييس الكفاءة لنماذج الإنحدار الخطي المتعدد لسد الموصل "

السدود	SSE	$\hat{\sigma}$	AIC	BIC	SBC	MAE	MAPE
وارد السد	80.77	0.533	- 358	- 340	- 344	0.341	225.45
سد الموصل	125.65	0.665	- 231	- 213	- 216	0.403	137.44
وارد السد							



إن تحديد المتغيرات التوضيحية المزاحة زمنياً لنماذج الإنحدار الخطي إستند على طريقة بوكس- جنكينز من خلال التحليل الأولي لهذه المتغيرات وهذا يعني وجود تداخل في وصف النماذج من طريقة أخرى لذا ومن خلال جدول (4-7) نلاحظ إن قيم معاملات المتغير المزاح زمنياً (y_{t-13}) تقترب من الصفر وبمقارنة قيمة إختبار الإحصاءة (t) لمعلمة هذا المتغير مع القيمة الجدولية التي تساوي ($t = 1.645$) يؤكد عدم معنوية المتغير في وصف النموذج الخطي وبالتالي إنحسار تأثيره على التنبؤ بقيم الظاهرة المدروسة وهذا يعزز التحليل بطريقة بوكس- جنكينز في تحديد متغيرات النموذج وإن إحصاءة الإختبار لمعالم المتغيرين (y_{t-12}) و (y_{t-1}) تكون كبيرة لكلا النموذجين مما يعكس أهمية هذه المتغيرات وبالتالي قوة تفسيرهما الطردية للتنبؤ في قيمة الظاهرة ($\hat{y}_t$) وبصورة عامة فإن نماذج الإنحدار معنوية وذلك بعد مقارنة قيمة (F) الخاصة لكل إنموذج بقيمتها الجدولية وتبلغ (2.60) تحت مستوى معنوية (0.05)

4-4 : المقارنة بين أساليب التقدير وبناء النماذج لوارد ومطلق المياه لسد الموصل :

تمت المقارنة بين الأساليب الثلاثة المستعملة في تقدير النماذج بالإعتماد على مجموع مربعات الإخطاء ومقاييس الكفاءة الإحصائية بين هذه النماذج والجدول (4-9) يوضح هذه المقارنة لوارد ومطلق سد الموصل إذ تم إعتداد إنموذج الشبكة العصبية ($2 ; NN(1,12)$) للمقارنة لإمتلاكه أقل عدد من المعالم من بين نماذج الشبكات والذي أعتمد في التنبؤ وتبين كفاءة أسلوب الشبكات العصبية على طرق التنبؤ الكلاسيكية لإنموذج مطلق السد وفقاً للمقاييس AIC و BIC و SBC التي تمتلك أقل القيم ونلاحظ إن قيم هذه المقاييس لوارد السد تكون كبيرة لنموذج الشبكة العصبية بالمقارنة مع باقي الطرق وذلك يعود إلى طبيعة البيانات فضلاً عن إن نماذج الشبكة العصبية الإصناعية لوارد ومطلق السد تمتلك أقل قيمة لمجموع مربعات الأخطاء مما يدل على إن التنبؤ بإستعمال الشبكات العصبية هو الأفضل .

جدول (4-9)

" المقارنة بين نماذج التقدير الثلاثة لوارد ومطلق المياه لسدود العراق "

سد الموصل	النماذج	عدد المعالم	SSE	$\hat{\sigma}$	AIC	BIC	SBC	MAPE
وارد السد	بوكس- جنكينز	2	66.36	0.493	- 387	- 378	- 380	222.33
	الشبكات العصبية	9	28.54	0.402	- 331	- 293	- 302	121.42
	الإنحدار الخطي	4	80.77	0.533	- 358	- 340	- 344	225.45
مطلق السد	بوكس- جنكينز	2	134.38	0.699	-193	-184	-186	181.06
	الشبكات العصبية	9	39.74	0.474	- 269	- 231	- 240	109.31
	الإنحدار الخطي	4	125.65	0.665	- 231	- 213	- 216	137.44

الاستنتاجات Conclusions

- 1- يُعد أسلوب الشبكات العصبية ذو كفاءة ودقة، وذلك لإملاكه أقل مجموع مربعات الأخطاء وإنخفاض قيم المقاييس الإحصائية لنماذج السلاسل الزمنية المستعملة في هذا البحث والتحليل بواسطة هذا الأسلوب يحتاج إلى وقت وجهد أقل مما تحتاجه طرق التنبؤ الكلاسيكية والتي تفترض شروط صعبة لتحليل السلاسل الزمنية .
- 2- قدرة الشبكة العصبية على التعامل مع أعداد كبيرة من المعالم بعدد وحجم مختلف من متغيرات الإدخال فضلاً عن تعامله مع العلاقات الخطية وغير الخطية في عملية التدريب ولعدة مرات .
- 3- أوضح تحليل الإنحدار الخطي معنوية المتغيرين (y_{t-1}) و (y_{t-12}) وأكد ذلك التحليل بطريقة بوكس- جنكينز للسلاسل الزمنية الموسمية وبطول موسم (12) بالإعتماد على قيم المقاييس الإحصائية لإختيار نموذج التنبؤ الأفضل أما إختيار المتغيرات ذات التأثير الأكبر في نماذج الشبكات العصبية فإنه يعتمد على قيم المعالم (الأوزان) الرابطة بين طبقات الشبكة لأن بعض المقاييس ومنها (AIC) لم يكشف عن الفروقات الجوهرية بين نماذج الشبكة مقارنة بمقياس (BIC) .
- 4- للحصول على نتائج أكثر دقة باستعمال الشبكات العصبية الإصطناعية يجب الإهتمام بإختيار معمارية مناسبة للشبكة تتمثل بعدد متغيرات الإدخال وعقد الطبقة المخفية ودوال التنشيط المستعملة لمعالجة البيانات في هذه العقد وتحديد التدريب الذي يعطي أقل قيمة للخطأ .

التوصيات Recommendations

- 1- تطبيق أسلوب الشبكات العصبية في الدراسات الإحصائية التطبيقية المختلفة للدقة والمرونة التي تميز هذا الأسلوب
- 2- استعمال دوال تنشيط غير الدالة اللوجستية في تدريب الشبكة العصبية ومقارنة النتائج .
- 3- استعمال أسلوب الشبكات العصبية الشعاعية (RBF) في دراسة الظواهر الإقتصادية ومقارنتها بالطرق التقليدية إذ تجمع هذه الطريقة بين الموصفات الإحصائية لدوال التنشيط فضلاً عن صيغة الإنموذج الشبه معلمية
- 4- توسيع نماذج الدراسة التي تتضمن المقارنة مع طرق الشبكات العصبية ومنها الشبكات العصبية للإنحدار العام (GRNN)
- 5- استعمال طريقة التعليم من دون مشرف عام لبناء النماذج الإحصائية ومقارنتها بالطرق التقليدية
- 6- توسيع تقدير النماذج لحالة تنقيب البيانات (data mining)

المصادر References

- 1- الشبخلي، أيفان علاء ناظم (2003) " تصميم نظام رياضي ديناميكي لا خطي باستخدام الشبكات العصبية (NARMAX) لإغراض تحليلية وتنبؤية لنشاط المبيعات في شركة كهرباء بغداد " / كلية الإدارة والاقتصاد/ جامعة بغداد
- 2- الكسو، ابتهاج عبد الحميد محمد علي (2005) " استخدام الشبكات العصبية في تقدير رتب سلاسل ماركوف مع التطبيق على سلسلة جبل بطمة في محافظة نينوى " /كلية علوم الحاسبات والرياضيات/ جامعة الموصل
- 3- الكيلاني، محمد- خضير، سلمى- رؤوف، نهى- البكري، نورية عبد (2002) " استخدام الشبكات العصبية الإصطناعية في التنبؤ وتحليل البيانات ،الجزء الأول: التصنيف، التوفيق والتوقعات ، CLASSIFICATION, FITTING & PREDICTION " / قسم المعلوماتية وبحوث العمليات/ الشركة العامة لتوزيع كهرباء بغداد
- 4- جاسم، سليمة حمادي (2006) " الارتباط القويم والشبكات العصبية الإصطناعية (دراسة تطبيقية)" /كلية الإدارة والاقتصاد/ جامعة بغداد
- 5- جواد، فردوس حسين (2006) "دعم القرار الاستراتيجي باستخدام الشبكات العصبونية (تصميم نظام مقترح) دراسة تطبيقية في عدد من الجامعات العراقية في بغداد " /كلية الإدارة والاقتصاد/ الجامعة المستنصرية
- 6- محمود، أفاق عبد الرهيب حسين (2010) " استعمال البرمجة الديناميكية والشبكات العصبية لإيجاد الخزين الأمثل لمخازن الشركة العامة للزيوت النباتية" /كلية الإدارة والاقتصاد/ جامعة بغداد
- 7- Ajoy K . Palit and Dobrivoje Popovic , (2005) " Computational intelligence in time series forecasting , theory and engineering applications ".USA
- 8- Ani bin Shabri , Fakulti Sains UTM/ Skudai Johor Malaysia " comparision of time series forecasting methods using Neural Networks and Box- Jenkins model "
- 9- CHAN Man- Chung , WONG Chi- Cheong , LAM Chi- chung , The polytechnic University , Hong Kong " Financial Time Forecasting by Neural

Network Using Conjugate Gradient Learning Algorithm and Multiple Linear Regression Weight Initialization

- 10- Dr.Andranik Macrdechian, (2003) " Designing a neural network for forecasting financial and economic time series "
- 11- Martin T. Hagan , Howard B. Demuth , (1996) " Neural Network Design"
- 12- Michael Sampson , (2001) " Time Series Analysis "
- 13- P.Ram Kumar , M.V.Ramana Murthy , D.Eashwar , M.Venkatdas , (2005) "TIME SERIES MODELING USING ARTIFICIAL NEURAL NETWORKS " Journal of Theoretical and Applied Information Technology
- 14- Simon Haykin, (1998) " FEEDFORWARD NEURAL NETWORKS : AN INTRODUCTION " 15- YU HEN HU , Jenq- Neng Hwang , (2001) " NEURAL NETWORK SIGNAL PROCESSING "

.....
.....
.....