

المقارنة بين آلة الدعم الموجه للانحدار وأسلوب الانتشار الخلفي للشبكة العصبية-دراسة تطبيقية على تدفق مياه نهر دجلة في مدينة الموصل

رضوان يوسف صديق *

احمد نجم شيت الشلاوي **

المخلص

فكرة البحث هي تبني أسلوب آلة دعم الموجه في التقدير والتنبؤ لنماذج الانحدار ومقارنته مع إحدى الشبكات العصبية المتعددة الطبقات neural network ذات الانتشار العكسي back-propagation، وبيان مميزاته وإمكانية استخدامه في التطبيقات العلمية موضحين مدى دقته بالتنبؤ مقارنة مع الشبكات العصبية باستخدام مقياس متوسط مربعات الأخطاء mean square errors (MSe)، وقد استخدمت بيانات السلسلة الزمنية للتدفق الشهري لكميات مياه نهر دجلة عند بداية دخوله إلى مدينة الموصل للفترة من (1950-1995) لانجاز عملية المقارنة وباستخدام البرنامجين الجاهزين برنامج (MATLAB, v2011) وبرنامج R.

الكلمات المفتاحية: آلة الدعم الموجه للانحدار، شبكة الانتشار الخلفي للخطأ، البرمجة التريبية.

A Comparison Between Support Vector Machine for Regression (SVR) and Neural Network Back- Propagation (BPNN): Applied Study for Tigris Water Monthly Flow in Mosul City .

Abstract :

The idea of this research is based on adopting Support Vector Machine for Regression (SVR) in estimating and predicting regression models and comparing it with one of the multi layer neural network that has back propagation((MLP). Therefore ,this will lead to demonstrate the advantages and possibility to use it in scientific application by illustrating how it is accurate in comparison with the ((MLP) by using Mean Square Errors(MSe)

The time sequence data are that used for month flow for the water from Tigris that incomes in to Mosul city for the period between (1950-1995) to accomplish the comparison process by using the employment of two computers softwares.

Key words : support vector machine for regression, BPNN , quadratic programming

* مدرس / قسم هندسة تقنيات القدرة / الكلية التقنية / الموصل

** مدرس مساعد / قسم هندسة تقنيات القدرة / الكلية التقنية / الموصل

تاريخ استلام البحث 2013/4/7 تاريخ القبول 2013/6/2

1- المقدمة:

يعد تحليل الانحدار analysis of regression من أكثر الأساليب الإحصائية استعمالاً في مختلف العلوم الإنسانية والاقتصادية والطبية وغيرها من العلوم ويهدف إلى دراسة العلاقة بين متغيرين أو أكثر مع بعضهما البعض، ويضم التحليل الانحدار متغيرين أو أكثر من المتغيرات التي تربطها علاقة منطقية تحدد قيم مشاهداتها على وفق التجربة وتدعى بالمتغيرات التوضيحية explained variables وتؤثر هذه المتغيرات في تحديد قيم المتغير ويدعى بالمتغير المعتمد dependent variables أي انه يعتمد على قيم المتغيرات التوضيحية.

ويستخدم تحليل الانحدار في تحليل العلاقة بين المتغيرات لتحقيق الكثير من الأهداف المهمة منها وصف البيانات data description والسيطرة control والتنبؤ prediction، ولوصف نموذج الانحدار نقوم بتقدير معالم الأنموذج (الراوي، 1987).

أخذ في الآونة الأخيرة اهتمام كبير من قبل مجموعة من الباحثين في العالم بتقنيات جديدة للتقدير وللتنبؤ كأمثال الباحث Speelakshmt الذي قام بالتنبؤ لتأثير سرعة الرياح في سير السفن والصواريخ وطائرات النقل والصواريخ الموجهة باستعمال تقنية آلة الدعم الموجه لتصنيف support vector machine of classification (SVM)، وكذلك قام كل من الباحثين Jaikla & Jintwawet باستخدام support vector machine of regression (SVR) في التنبؤ بنسبة الهدرجين في وزن التربة ومدى تأثير قيمته في الساق والحبوب لمحصول الرز، لمزيد من المعلومات أنظر (Jaikla & Jintwawet, 2008; Sreelakshmi & Kumrr, 2008).

ولتسليط الضوء على محتوى هذا البحث فقد شمل جانبين إذ تضمن الأول الجانب النظري وفيه تم شرح أسلوب آلة الدعم الموجه والشبكات العصبية ذات الانتشار الخلفي. في حين تضمن الثاني الجانب التطبيقي الذي تم من خلاله كيفية البناء والتنبؤ بالنموذج تحت الدراسة وإجراء المقارنة بين الأسلوبين. فضلاً عن الاستنتاجات والتوصيات التي تم التوصل إليها بوصفها نتائج لهذه الدراسة.

هدف البحث:

يهدف البحث إلى إجراء استخدام أسلوب آلة دعم الموجه للانحدار والشبكة العصبية ذات الانتشار الخلفي وأجراء المقارنة لبيان أي الأسلوبين أفضل.

1- الشبكات العصبية الاصطناعية: Artificial Neural Network (ANN)


تعرف الشبكات العصبية الاصطناعية (ANN) على إنها نظام حسابي مكون من عدد من وحدات (عصبونات) المعالجة *processing elements* المترابطة مع بعضها وتتصف بطبيعتها الديناميكية والمتوازية في معالجة البيانات الداخلة إليها. إن الإشارة الخارجة من أية خلية من خلايا الشبكة العصبية الاصطناعية تعتمد على الإشارات الداخلة، وهذه الشبكات تكون عادة غير دورية أو غير تكرارية، وأن الارتباطات بين العقد غير دورية. وتستند الشبكة الخطية إلى مفهوم تدريب الشبكة المعتمد على حجم الخطأ (متوسط مربعات الخطأ)، حيث تحدث الأوزان بين الطبقات بقدر مساهمة التدريب في الوزن في تكوين الخطأ وتستمر الشبكة في تحديث الأوزان حتى الحصول على الأوزان المثلى التي تحقق أفضل توفيق للنموذج. ويجري تعليم الشبكات العصبية بواسطة خوارزميات متخصصة تسمى خوارزميات التعلم *learning algorithms* تتولى تعديل أوزان الشبكة لتحسين أدائها وتقليل إشارة الخطأ فيها *error signal* استناداً إلى مقياس معلوم للوصول إلى النتيجة المثلى لهذه الأوزان التي تمكن الشبكة من تحقيق أفضل نتيجة أو قريبة من النتيجة المطلوبة. ويجري تعديل هذه الأوزان جزئياً في كل دورة وتؤخذ إشارة الخطأ دليلاً ومؤشراً على مدى القرب أو البعد عن القيم الصحيحة (عيسى، 2000).

تقسم الشبكات العصبية من حيث التدريب إلى نوعين (عيسى، 2000): النوع الأول هو التدريب بمشرف *supervised training* أما النوع الثاني فهو التدريب من دون مشرف *unsupervised training* وقد تم اعتماد النوع الأول في دراستنا. تصنف الشبكات العصبية الاصطناعية من حيث التغذية إلى صنفين هي الأمامية والتغذية الخلفية للخطأ ويطلق على النوع الثاني أيضاً ذات الانتشار الخلفي للخطأ.

أما أنواع الشبكات العصبية من حيث عدد الطبقات فمنها ذات الطبقة الواحدة التي تحوي على طبقة إدخال وطبقة إخراج *input layer/ output layer* ومنها متعددة الطبقات التي تحوي على طبقة مخفية *hidden layer* أو أكثر مابين طبقة الإدخال وطبقة الإخراج.

2-1 خوارزمية الانتشار الخلفي للخطأ:

من الخوارزميات المشهورة جداً في التعليم الموجه، هي خوارزمية الانتشار الخلفي للخطأ **back-propagation** وتسمى أيضاً بخوارزمية قاعدة دلتا العمومية **generalized delta Rule** التي تمثل الطريقة القياسية في تدريب الشبكة العصبية الاصطناعية (ANN) والتي تم اعتمادها في هذا الدراسة (عيسى، 2000)، وهذه الطريقة الشائعة تعمل على تقليل قيمة خطأ مربعات المتوسطات الصغرى القياسية **Least Means Square (LMS)** لأنها بكل بساطة عبارة عن طريقة الانحدار التدريجي **stepwise regression principles** وذلك لإيجاد القيمة الصغرى لمربع الخطأ لقيمة الإخراج المحسوب من قبل الشبكة وبالنتيجة نحصل على الأوزان المثلى التي يمكن اعتمادها في التنبؤ لبيانات جديدة لم تخضع للتدريب أو التعلم، وهذا هو الهدف من تدريب الشبكات العصبية الاصطناعية. كما إن هذه الخوارزمية تستخدم لتعليم الشبكات متعددة الطبقات.



الشكل (1): عمل الشبكة ذات الانتشار الخلفي للخطأ تتكون من إدخالين وطبقة واحدة مخفية وطبقة الإخراج.

إن تدريب الشبكة العصبية الاصطناعية باستعمال الانتشار الخلفي للخطأ تشمل ثلاث مراحل (عيسى، 2000)، (العبيدي، 2000) وهي كالاتي:

- خطوة الانتشار الأمامي للخطأ (error forward propagation step).
- خطوة الانتشار الخلفي للخطأ (error back propagation step).
- خطوة توليف أوزان الشبكة (net weights synthetic step).

وتكون المعادلة لتعديل الأوزان على النحو الاتي (العبيدي، 2000):

$$\Delta w_{ji}(k+1) = \eta \delta_j x_i + \theta \Delta w_{ji}(k)$$

$$\delta_j = f'(net)(d_j - y_j)$$

$$\delta_j = f'(net) \sum \delta_j w_{ji} \quad \text{حيث أن:}$$

θ : معامل الزخم momentum term .

Δw_{ji} : مقدار التعديل على وزن الخليتين i, j .

η : معامل نسبة التعلم.

δ : معامل تعديل الأوزان (الفرق بين الإشارة الخارجية والقيمة المطلوبة).

d : القيمة المطلوبة desired value.

y : قيمة الإشارة الخارجة.

K : مؤشر التكرار iteration index.

2 - آلة الدعم الموجه: (SVM) Support vector machine

أسلوب يجمع ما بين النظرية الإحصائية والتعليم الموجه، طُوِّر من قبل فانبك, Vanpik (1998) بدايةً وهو يعمل على تحويل نمط البيانات الأصلية إلى نمط جديد بشكل يميز البيانات في فضاء أعلى من فضاءها الأصلي بصورة مشابهة للنماذج غير الخطية حيث يمكننا من خلاله فصل البيانات وتصنيفها بجعلها مجاميع منفصلة عن بعضها ومتجانسةً وهذا ما يُعرف بالآلة الدعم الموجه للتصنيف (SVM) support vector machine for classification، بعد ذلك تم استعماله في السنوات العشرة الأخيرة بتقدير معالم نماذج الانحدار والتنبؤ عن طريقها وسميت آلة الدعم الموجه بالآلة الدعم الموجه للانحدار (SVR) support vector machine for regression، وقد تم استعمال النوع الأخير في دراستنا وذلك لبيان المقارنة مع الشبكات العصبية واثبات كفاءته.

3-1 آلة الدعم الموجه للانحدار: (SVR) (Support Vector Machine for Regression)

هي من أساليب التعليم الموجه (التعليم بإشراف) مبدأ عملها يأخذ بتقسيم البيانات إلى مجموعتين الأولى تدعى مجموعة بيانات التوزيع والثانية مجموعة بيانات الاختبار أو فحص النموذج وتعرف أيضا

بالهدف والتي من خلالها نبين مدى كفاءة آلة موجه الدعم للانحدار في ألتنبؤ والمعادلة الرياضية لدالة الانحدار تأخذ شكلاً جديداً كما موضح أدناه (Smola & Scholkopf, 1998):

إذا كان لدينا مجموعة البيانات

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x, y)\} \subset R^n \times R \quad \dots(1)$$

حيث إن:

D تمثل مجموعة البيانات.

$x_1, x_2, \dots, x_n$ تمثل منطلقها و هي عدد متغيرات الإدخال.

$y_1, y_2, \dots, y_n$ تمثل مدى المجموعة تحت الاختبار وتدعى أيضا بالهدف (target).

فان المعادلة الرياضية لدالة آلة الدعم الموجه للانحدار هي:

$$f(x, \omega, b) = \langle \omega, \phi(x) \rangle + b \quad \dots(2)$$

حيث إن:

$f(x, \omega, b)$ دالة الانحدار.

$\langle \cdot, \cdot \rangle$ حاصل الضرب النقطي (inner product) لقيم الإدخال.

ω : تمثل المعالم أو الأوزان.

b : يمثل حد القطع (intercept term)، ويطلق عليه التحيز (bias).

إن الهدف الأساسي من أسلوب آلة الدعم الموجه للانحدار هو إيجاد قيم الدالة $f(x, \omega, b)$ المعطاة في المعادلة (2) ويتم ذلك على وفق الخطوات الآتية:

1. حساب قيم الأوزان $\omega_1, \omega_2, \dots, \omega_n$ والتي تجعل قيمة معيار الأوزان لاقل قدس اقل ما يمكن:

$$\frac{1}{2} \|\omega\|^2 \quad \dots(3)$$

2. تحديد نوع دالة الخسارة التربيعية (quadratic loss function) فهناك دالة الخسارة التربيعية لابلاسين (Laplacian) ودالة الخسارة التربيعية لكوسيان (Gaussian) ودالة الخسارة التربيعية لهايبر (Hubers Robust) ودالة الخسارة المعروفة (ε -insensitive loss) التي تم للاعتماد عليها في دراستنا هذه (Smola & Scholkopf, 1998) وهي:

$$L_{\varepsilon}(y, f(\mathbf{x}, \omega)) = \begin{cases} 0 & \text{if } |y - f(\mathbf{x}, \omega)| \leq \varepsilon \\ |y - f(\mathbf{x}, \omega)| - \varepsilon & \text{otherwise} \end{cases} \quad \dots(4)$$

كما أشرنا في أعلاه بجعل دالة الخسارة التربيعية للخطأ اقل ما يمكن وهي:

...(5)

$$R_{emp}(\omega) = \frac{1}{n} \sum_{i=1}^n L_e(y_i, f(x_i, \omega))$$

3. بالاعتماد على أسلوب البرمجة التربيعية (quadratic programming) من خلالها نعمل على تقليل دالة الخسارة التربيعية وجعلها اقل ما يمكن وتأخذ الصيغة الآتية:

$$\min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*)$$

...(6)


S.to:

$$\begin{cases} y_i - f(x_i, \omega) \leq \varepsilon + \xi_i^* \\ f(x_i, \omega) - y_i \leq \varepsilon + \xi_i \\ \xi_i, \xi_i^* \geq 0, i = 1, \dots, n \end{cases}$$

حيث أن:

C: هي معيار يعمل بالموازنة بين خطأ التقدير ومقدار التباعد عن المحور الرئيسي (التسطح).

ϵ : يمثل نصف قطر الأنبوب (أي المسافة بين المحور الرئيسي ونقاط آلة الدعم الموجه)، ويتم تحديد قيمها من قبل المستخدم (Smola & Scholkopf, 1998).
 ξ_i, ξ_i^* : تمثل المسافة أو الفرق بين النقاط الواقعة خارج المحور الثانوي والمحور الثانوي نفسه من الأسفل والأعلى على التوالي وكما في الشكل (2):



الشكل (2): يوضح مصدر الخطأ في آلة الدعم الموجه للانحدار.

4. ولأجل الحصول على قيم الأوزان (معالم دالة آلة موجه الدعم) نعمل على تحويل دالة البرمجة التربيعية باستخدامنا طريقة التحويل الثنائي dual method والتي تعمل على تحويل المسألة المراد الوصول إلى حلها في حالة تحدب (Convex) أي في حالة ممكن حلها لاقترب نحو الحل الأمثل معتمدين على طريقة مضاعف لاكرانج (lagrange multipliers methods) من أجل تحققها لشروط كرش كان توكر (KKT) (Karush - Kuhn - Tucker) (Jaikla & jintwawet, 2008):

$$\max_{\alpha_i, \alpha_i^*} \omega = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle + \sum_{i=1}^n [\alpha_i (y_i - \epsilon) - \alpha_i^* (y_i + \epsilon)]$$

S. to :

$$\sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0$$

$$\alpha_i^* \in [0, c] \quad \dots(7)$$

α_i, α_i^* تمثل مضاعفات لاكرانج (lagrange multipliers).

ويحل مسألة البرمجة التربيعية بعد تحويلها كما ذكر في أعلاه نحصل على قيم الأوزان من المعادلة الرياضية:

$$w_i = \sum_{i=1}^n (\alpha_i - \alpha_i^*) y_i \quad \dots(8)$$

5. حساب قيمة دالة الكرنل kernel function (Smola & Scholkopf, 998) لقيم الإدخال

والمعادلة الرياضية هي:

$$k(x_i, x_j) = \sum_{j=1}^m g_j(x) g_j(x_i) \quad \dots(9)$$

تهدف دالة الكرنل (kernel function) إلى تغيير نمط بيانات الإدخال مثلاً من الحالة غير خطية إلى نمط جديد يكون ذا شكل خطي، وكلمة النواة (kernel) اشتقت من نظرية عملية التكامل وهناك أربعة أنواع لهذه الدالة انظر (Jhean & Jocelyn, 2011) وقد استخدمت في دراستنا هذه دالة الكرنل لكافوس RBF Radial basis function وهي:

... (10)

$$k(x_i, x_j) = e^{(-\beta \|x_i - x_j\|^2)}$$

6. إيجاد قيم الإخراج (out put) لآلة الدعم الموجه للانحدار من المعادلة (11):

$$\hat{y} = f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x, x_i) \quad \dots(11)$$

3- الجانب التطبيقي:

يستند البحث إلى بيانات واقعية تتمثل بالتدفق الشهري لكميات مياه نهر دجلة عند دخولها إلى مدينة الموصل للفترة (1950-1995) والمقاسة متر مكعب لكل ثانية (م³/ثا) وكما مبين في

الملحق(1) (مطر والياس، 2010)، لانجاز عملية المقارنة بين آلة الدعم الموجه للانحدار والشبكة العصبية ذات الانتشار الخلفي معتمدين على معيار متوسط مربعات الخطأ ومعادلته الرياضية هي:

$$MSe = \frac{\sqrt{\sum_{i=1}^n (y_i - \hat{y}_i)^2}}{n} \quad \dots(12)$$

تمت المقارنة بين الأسلوبين على ثلاث مراحل هي:

أ. المرحلة الأولى:

تضمنت هذه المرحلة التنبؤ بنموذج الانحدار لتدفق كميات مياه نهر دجلة بأسلوب آلة الدعم الموجه وبايجادنا قيم الأوزان المعطاة في المعادلة (8) ومن ثم حساب القيم التنبؤية لقيم الإخراج حساب ما جاء في المعادلة الرياضية المذكورة أنفاً في (11) وافترض قيمة $C=1000$ وقيمة $\varepsilon = 0.00001$ (Sreelakshmi & Kumrr, 2008)، باستعمال (kernel package) على برنامج R كانت نتائج الاختبار لآلة دعم الموجه للانحدار كما موضحة في الجدول (1):


الجدول (1): النتائج الإحصائية لمقدرات آلة الدعم الموجه للانحدار

تسلسل	Y real	Y Estimate	Error
1	884	883.9103	0.0897
2	1439	1438.414	0.5859
3	2397	2396.801	0.1989
4	4730	4730.262	-0.2624
5	2938	2937.636	0.364
6	1231	1231.703	-0.7029
7	549	549.4667	-0.4667
8	348	348.0484	-0.0484
9	285	285.0753	-0.0753
10	348	348.1361	-0.1361
11	381	380.9032	0.0968
12	522	522.4646	-0.4646


ب. المرحلة الثانية:

شملت هذه المرحلة بناء وتدريب واختبار الشبكة العصبية الاصطناعية المتعددة المراحل ذات الانتشار الخلفي للخطأ (BPE)، بواسطة استخدام برنامج ماتلاب (MATLAB, V.2011) إذ تكونت معمارية الشبكة في هذا الجانب من ثلاث طبقات هي طبقة الإدخال والطبقة المخفية وطبقة الإخراج، حيث تتألف طبقة الإدخال من 23 خلية عصبية والتي تمثل إدخال ثلاث وعشرين سنة لشهر واحد معين، وعشر خلايا عصبية في الطبقة المخفية وخلية عصبية واحدة في طبقة الإخراج التي تمثل إحدى قيم تصريف المياه للشهر المحدد قيد التدريب [1,10,23] كما جاء في الشكل (3).

وقد قسمت تم تقسيم البيانات المدروسة على مجموعتين كل مجموعة تألفت من (23 سنة)، حيث شملت المجموعة الأولى السنوات الفردية لتدفق كميات مياه نهر دجلة واعتمدت كمجموعة تدريب للشبكة إما المجموعة الثانية فقد تضمنت بيانات السنوات الزوجية وأخذت كبيانات للاختبار. وكانت نتائج التدريب لقيم الخطأ اقل ما يمكن حيث كانت (0.00001) كما في الشكل (4) .



الشكل (3): يبين رسومات الشبكة العصبية [23,10,1] باستخدام خوارزمية الانتشار الخلفي للخطأ



الشكل (4): يبين وصول تدريبات الشبكة باستخدام خوارزمية الانتشار الخلفي

وكانت نتائج الاختبار بعد التدريب هي كما موضحة في الجدول (2) الآتي:


الجدول (2): يوضح النتائج الإحصائية لاختبار الشبكة العصبية ذات الانتشار الخلفي للخطأ

تسلسل	Y real	Y Estimate	Error forecasting of MLP(23-10-1)
1	884	883.2167	0.6136
2	1439	1438.900	0.0101
3	2397	2396.064	0.8753
4	4730	4729.363	0.4054
5	2938	2936.417	2.5046
6	1231	1229.686	1.7263

7	549	548.483	0.2670
8	348	347.701	0.0893
9	285	284.619	0.1447
10	348	347.552	0.2000
11	381	380.864	0.0183
12	522	521.440	0.6136

ج. المرحلة الثالثة:

بعد أكمل المرحلتين السابقتين من البحث في الجانب التطبيقي تمت عملية إجراء المقارنة بين كلا الأسلوبين تحت الدراسة وكانت نتائجها كما في الشكل (5) ادناه والذي نلاحظ فيه تفوق آلة الدعم الموجه للانحدار على أسلوب الشبكات العصبية ذات الانتشار الخلفي للخطأ (BPE) في تقدير تصريف كميات مياه نهر دجلة عند دخولها مدينة الموصل في الشهر الواحد، حيث كانت قيم مربعات الخطأ للأشهر (1-3-4-5-6-8-9-10) للتنبؤ باستخدام آلة الدعم الموجه للانحدار أقل من قيم التنبؤ باستخدام الشبكة العصبية ذات الانتشار الخلفي للخطأ.



الشكل (5): يوضح نتائج معيار المقارنة بين أسلوب آلة الدعم الموجه للانحدار والشبكات العصبية ذات الانتشار الخلفي للخطأ.

وكانت نتائج متوسط مربعات الخطأ للتنبؤ MSe لكلا الأسلوبين كما في الجدول (3) الآتي:

الجدول (3): المقارنة الإحصائية بين أسلوب آلة الدعم الموجه للانحدار مع أسلوب الشبكات العصبية

متوسط مربعات الخطأ للتنبؤ للشبكات العصبية ذات الانتشار الخلفي للخطأ	متوسط مربعات الخطأ للتنبؤ لآلة الدعم الموجه لانحدار
0.597308	0.129656

5- الاستنتاجات:

1. أثبتت آلة الدعم الموجه لانحدار كفاءتها في التنبؤ بالتدفق الشهري لكميات مياه نهر دجلة الداخلة إلى مدينة الموصل مقارنةً بأسلوب الشبكة العصبية الاصطناعية ذات الانتشار الخلفي لمعظم اشهر السنة كما جاء في الجداول (1)، (2) و (3)، وهذا يوضح أفضلية آلة الدعم الموجه لانحدار من أسلوب الشبكات العصبية الاصطناعية ذات الانتشار الخلفي للخطأ (BPE) وفقاً لقيمة مقياس متوسط مربعات الخطأ لكلا الطريقتين.

2. استخدام آلة موجه الدعم في التنبؤ وبناء النماذج عوضاً عن أسلوب الشبكات الاصطناعية ذات الانتشار الخلفي.

6- التوصيات:

1. دراسة استخدام آلة الدعم الموجه لانحدار في تقدير نماذج الانحدار اللوجستية والتنبؤ بها .
2. استخدام آلة الدعم الموجه لانحدار في علاج مشكلة تعدد العلاقة الخطية ومقارنتها بأسلوب انحدار الحرف.

7- المصادر:

1. الراوي، خاشع محمود، (1987)، " المدخل الى تحليل الانحدار"، جامعة الموصل، دار الكتب للطباعة والنشر، العراق.
2. عيسى، علام زكي، (2000)، " الشبكات العصبية، البنية الهندسية-الخوارزميات - التطبيقات"، الطبعة الأولى، شعاع للنشر والعلوم، حلب، سوريا.

3. العبيدي، محمود خليل إبراهيم، (2000)، "الشبكات العصبية الاصطناعية"، مجلة أبحاث الحاسوب، المجلد 4، العدد1، الجامعة التكنولوجية، بغداد، العراق.

4. مطر والياس، ظافر رمضان وانتصار ابراهيم، (2010) " تحليل ونمذجة السلسلة الزمنية لتدفق المياه الداخلة الى مدينة الموصل، المجلة العراقية للعلوم الاحصائية، 18، ص 1 ص 32.

5. Vapnik V.N., (1998), "Statistical Learning Theory". New York, Springer, PP.375-378.

6. Smola A.J., Scholkopf B., (1998)"A Tutorial on Neural Network", Nero COLT Tech. Rep.TR-1998-030, Royal Holloway College London, U.K.

7.Sreelakshmi K. , Kumrr. P. Ramakanth , (2008),"Short Term Wind Speed prediction Using Support Vector Machine", Wseas transaction on computer, issue, volume7,PP.1109-2750. www.ivsl.org

8. Jaikla Ratchaphum, Jintwawet, (2008), "Rice Yield Predication Using a Support Vector Regression Method", IEEE, PP29-32. www.ivsl.org

9. Jhean-Matthieu Monnet, Jocelyn Chanussot, (2011), "Support Vector Regression for the Estimation Forest Stand Parameters Using Airborne Laser Scanning", IEEE,VOL.8, NO.3, PP.580-584. www.ivsl.org

الملحق (1): بيانات التدفق الشهري لكميات مياه نهر دجلة عند دخولها مدينة الموصل مقاسة (م³ / ثا) للفترة (1950-1995).

سنة	JAN	FEB	MAR	APR	MAY	JUN	JUL	AUG	SEP	OCT	NOV	DEC
1950	1082	2516	4393	5910	4607	2351	1130	629	438	474	814	825
1951	1945	2685	6187	9098	6589	3214	1369	720	531	552	695	1128
1952	1187	1108	1853	2483	2759	899	504	399	311	364	490	1736
1953	1484	2564	3509	4121	3777	2356	994	479	420	479	570	763
1954	798	1572	4901	2825	6053	2556	1173	696	565	549	682	913
1955	1588	1483	3107	3707	2839	1664	825	485	397	402	435	932
1956	1248	798	2095	4044	3321	1490	643	418	350	434	480	489
1957	1371	1212	2526	4588	3723	1192	528	346	288	287	415	514
1958	804	898	1219	2644	2866	1016	471	289	254	313	670	1907
1959	1195	2039	3348	3318	2973	1255	565	348	298	402	459	1926
1960	2786	3097	3134	8761	8973	4380	1754	884	643	1050	1151	1154

1154	1151	1050	428	544	846	2053	3777	4380	5812	1841	905	1961
1811	933	1002	303	348	691	1778	3696	4251	2946	1790	820	1962
1288	630	603	342	407	795	1719	3616	4251	2547	3218	3643	1963
3294	1742	568	469	552	1117	2929	8758	6324	4259	1710	1765	1964
4446	858	512	456	568	1007	2722	6000	7413	6428	2390	3080	1965
1026	806	793	596	694	1149	2722	8142	7983	8678	2830	4741	1966
1122	754	637	505	557	707	933	1658	3084	2786	2342	1270	1967
913	541	554	391	426	541	1060	2531	4640	1963	905	905	1968
597	664	498	522	688	1015	2618	7955	4977	2349	1205	651	1969
729	599	423	311	351	589	1239	2413	2219	1591	694	544	1970
503	367	350	351	536	1104	2469	4692	4312	721	734	734	1971
511	367	327	356	554	1304	3375	3784	2204	1468	718	731	1972
1058	870	513	635	1149	1989	6750	9056	2895	2414	2151	820	1973
451	404	298	394	635	1327	3396	3779	2555	1444	1042	1511	1974
443	421	378	466	836	1897	3787	4202	4189	4548	1778	1256	1975
1312	868	345	386	576	1317	2502	2932	2020	1517	2065	1007	1976
689	562	513	573	771	1506	3943	6579	3785	1706	1412	1543	1977
837	426	394	469	865	2035	3557	3722	3750	2393	1738	1205	1978
648	662	391	517	873	2227	5847	5752	2274	1817	1663	1074	1979
2224	512	391	442	600	1348	3367	3056	2590	927	704	579	1980
832	410	306	362	675	1387	2408	2859	2400	1386	860	1765	1981
381	335	293	340	429	1301	3458	6032	2836	1955	940	761	1982
1014	410	223	249	439	910	1963	2271	1604	1466	991	587	1983
1591	627	298	351	771	1903	4944	5378	4055	2714	1832	865	1984
980	686	438	637	1334	3173	7234	8818	6053	3191	2936	4462	1985
1623	375	171	161	196	381	962	1423	1545	602	742	1176	1986
570	319	264	297	520	1350	2917	3590	2231	2487	1154	2831	1987
718	354	166	158	206	638	1812	2786	3747	975	469	533	1988
664	308	311	479	929	2392	4808	5249	2024	2315	1085	1189	1989
933	442	312	380	1037	3087	8732	6060	3069	1689	1374	1487	1990
1498	421	215	225	429	995	2759	4435	2619	1686	1390	916	1991
767	404	332	386	712	1996	4717	5884	3546	2535	2510	2196	1992
435	442	324	356	571	1058	3292	5111	3238	1536	1138	544	1993
661	530	254	287	579	1519	3736	4751	1789	1200	1299	1551	1994
522	381	348	285	348	549	1231	2938	4730	2397	1439	884	1995