مجلة المثنى للعلوم الادارية والاقتصادية
المجلات الاكاديمية العراقية

مقارنة بين الخوارزمية الجينية MWCD والشبكة العصبية متعددة الطبقات الارجاعية (الارتدادية) لتحديد المؤشرات المسببة لتلوث المياه

فاطمة عبد الحميد جواد [a]* ، صباح منفي [b]
جامعة بغداد /كلية الادارة والاقتصاد/ قسم الاحصاء

معلومات المقالة

تاريخ البحث
الاستلام :
تاريخ التعديل :
قبول النشر :٢٠٢٠/١١/١٩
متوفر على الأنترنيت:٢٠٢١/٨/٢٩

الكلمات المفتاحية :
الشبكة العصبية
مهلنوبس
شرائح التمهيد
الخوارزمية الجينية
الشبكات متعددة الطبقات

الملخص

تستعمل الطرق اللامعلمية في البيانات التي تحتوي على قيم شاذة ،الاهمية الاساسية في استعمال الطرق اللامعلمية هو تحديد موقع الوسيط ،ففي انموذج الانحدار متعدد المتغيرات يكون من الصعوبة تحديد موقع الوسيط لوجود اكثر من بعد وتشتت القيم وزيادة بيانات الظاهرة المدروسة .فقد تم تطبيق الخوارزمية الجينية Minimum Weighted Covariance Determinant Estimator (MWCD) وتكتب باختصار ومقارنتها مع الشبكة العصبية متعددة الطبقات الارجاعية (الارتدادية)(Back Propagation Algorithm) Multilayer Network في ايجاد التقدير لموقع الوسيط بالاعتماد على مسافة مهلنوبس Mahalanobis Distance(MD) واصغر محدد لمصفوفة التباين المشترك Minimum Covariance Determinant (MCD) كواحدة من الطرق اللامعلمية الحصينة. وقد طبقت الدراسة على الاحصاءات البيئية لتلوث مياه الشرب لسنة 2013 شملت محافظات العراق كافة عدا اقليم كردستان ،مقسمة الى 10 اشهر وقد استخدمت 9 انواع من المؤشرات الكيمائية والفيزيائية المسببة لتلوث مياه الشرب عند تجاوز الحد الاعلى للقياس. ولتحديد المؤشرات المسببة للتلوث تم استخدام شرائح التمهيد Smoothing Spline في تقدير معاملات انموذج الانحدار متعدد المتغيرات للمعالم المتغيرة زمنيا وقد قدرت المعالم الممهدة بطريقة تثبيت التقاطع Cross Validation (CV). اثبتت نتائج المقارنة بفاعلية الشبكة العصبية متعددة الطبقات الارجاعية.

A comparison between the genetic algorithm MWCD and the Multi-Layered (Back Propagation Algorithm)network to identify the indicators causing water pollution

Fatimah Abdul Hmeed Jawad [*a] , Sabah manfi redha [b]
University of Baghdad/college of Economics &Administration/department of statistics.

Abstract

Nonparametric methods are used in the data that contain outliers values. The main importance in using Nonparametric methods is to locate the median in the multivariate regression model . It is difficult to locate the median due to the presence of more than one dimension and the dispersion of values and the increase of the studied phenomenon data .The genetic algorithms Minimum Weighted Covariance Determinant Estimator (MWCD), was applied and compared with the multilayer neural network Back propagation to find the estimate of the median location based on the minimum distance (Mahalanobis Distance) and smallest specified for the variance matrix . Joint Minimum Covariance Determinant (MCD) as one of the most nonparametric methods robust .

The study has been applied on environmental pollution statistics of drinking water for the year (2013) including all the Iraqi provinces except Kurdistan region , divided into (10) months .To determine the contaminating indicators ,Smoothing Spline slides were used to estimate the multivariate regression model parameters for the time – variable parameters . The parameters smoothed by the cross validation (CV) method were estimated the results of the comparison proved the effectiveness of the retrospective Multi – Layer neural network.

Key words: genetic algorithm , neural network , mahalanobis ,smoothing spline , multiLayer networks.

* Corresponding author : E-mail addresses :.

2021 AL – Muthanna University . DOI:10.52113/6/2021-11/290-304

المقدمة

لتقدير نموذج الانحدار متعدد المتغيرات في حالة زيادة عدد المشاهدات n وعندما تكون عدد المتغيرات p≥2 وتشتت البيانات ووجود اكثر من بعد وكذلك وجود القيم الشاذة (المتطرفة) اذ ان الطرق التقليدية تتاثر في التقدير ،فقد تم استعمال الطرق اللامعلمية في التقدير والتي تعتمد على تحديد موقع الوسيط بالاعتماد على مسافة Mahalanobis Distance(MD) والتي يتم ايجادها من المتغيرات التوضيحية وعلى اصغر محدد لمصفوفة التباين المشترك Minimum Covariance Determinant(MCD) ،وقد تم تطبيق الخوارزمية الجينية MWCD والشبكة العصبية متعددة الطبقات الارجاعية (الارتدادية) Multilayer Network (Back Propagation Algorithm) للمقارنة من حيث الدقة في النتائج والسرعة في ايجاد موقع الوسيط ، ثم تقدير معالم النموذج لتحديد المؤشرات المسببة لتلوث مياه الشرب .

من الباحثين الذين استخدموا الخوارزمية الجينية MWCD في عام (2003) م قام الباحثون (Peter J.Rousseeuw) و(Van Aelst Stefan) و(Katrien Van Driessen) و(Jose Agullo') بتقديم الطرق الحصينة للتقدير لانموذج انحدار متعدد المتغيرات مستندا بذلك على الموقع ومصفوفة الانتشار باستعمال المتغيرات التوضيحية والاستجابة في التقدير، وقد استعمل اسلوب المحاكاة لمختلف احجام العينات ولزيادة الكفاءة اقترح عدة اوزان للتقدير، وهي اوزان الموقع (reweighting location –L) واوزان للقيم الاولية لانموذج الانحدار (reweighted regression estimators – R) وكانت اكثر كفاءة بالمقارنة بينها وبين التقديرات الى (MCD)،اما عند الدمج في حالة الوزن للموقع والانموذج (LR-weighted MCD) اضافت خصائص للتحيز bias متوسط مربع الخطأ(MSE) اقل قيمة بالمقارنة مع التقدير بطريقة (Least square regression).

في عام (2003) م قدم الباحثان (Greet Pison) و (Stefan Van Aelst) اقترحت عدة مقدرات حصينة منها محدد اصغر لمصفوفة التباين المشترك (MCD) الخطوة الاولى في تقدير موقع الوسيط هو اعادة الوزن الى الوسط الحسابي ومصفوفة التباين المشترك وذلك لزيادة الكفاءة وسميت اعادة وزن محدد اصغر لمصفوفة التباين المشترك (Reweighted Minimum Covariance Determinant (وتكتب بأختصار (RMCD) ، وتم اختيار نقطة التوقف 50% عندما تكون $\gamma = 0.5$ اما نقطة التوقف 25% عندما تكون $\gamma = 0.75$.

في عام (2009) قام الباحث Ella Roelant و Stefan Van Aelst و Gert Willems بتقدير الموقع والتشتت لبيانات متعدد المتغيرات مع مجموعة من الاوزان بالاعتماد على رتبة المسافة Mahalanobis ، حيث تم استخدام دالة الوزن a_n وقد فسر ان مقدر MWCD اكثر عموما من مقدر (MCD) والاعتماد على دالة الوزن يمكن ان يعالج المتوسط لمختلف القيم المتطرفة.

الإطار النظري

أولاً: مفهوم الإدارة المفتوحة

- التقديرات اللامعلمية الممهدة لانموذج المعلمات المتغيرة زمنيا للبيانات الطولية

- Nonparametric Smoothing Estimates of time Varying Coefficient Models with Longitudinal data

سيتم في هذا المبحث تقدير معلمات الانموذج المتغيرة زمنيا (Z.Huang, Colin O.wu, & Lan Zhou, 2004) (بيانات القياسات المتكررة – repeated measurement) الطولية (Longitudinal) التي توضح تأثير متغيرات الاستجابة خلال الزمن (t) حسب الاشهر او السنوات ، فقد تم استعمال التقديرات اللامعلمية لتحليل البيانات ذات القياسات المكررة (الطولية) وذلك باستعمال شرائح التمهيد (Smoothing Spline) لتقدير المعلمات $\beta(t)$ (R.Hoover, John A.Rice, Colin O.wu, & LI-PING YANG, 1998) ويمكن توضيح أنموذج المعلمات المتغيرة زمنيا (Time Varying Coefficient) وتكتب بأختصار (TVC) كالاتي :-

$$Y(t) = X'(t)\, B(t) + \varepsilon(t) \quad \ldots(2\text{-}1)$$

اذ ان :-

i=1,…,n تمثل n عدد القطاعات ، اما j=1,…,n_i تمثل n_i عدد المشاهدات للقطاع i^{th} .

t_{ij} : الزمن للقياسات j^{th} للقطاعات i^{th} .

$Y(t)$: المتغير المعتمد ($n n_i * 1$) متجة الاستجابةj^{th} .

$X(t)$: مصفوفة المتغيرات المستقلة (التوضيحية) ($n n_i * dn_i$) للقطاع i^{th} .

d : تمثل عدد المتغيرات المستقلة (r =1,…,d) .

$\beta(t)$: دوال المعالم التمهيدية في الزمن(t_{ij}) متجة ($\mathrm{d}n_i * 1$) .

$\varepsilon(t)$: متجة الخطأ العشوائي $(\mathrm{n}n_i * 1)$.

يمكن اعادة كتابتها كالاتي :-

$$y_{ij}=x'_{ij}\beta(t_{ij}) + \varepsilon_i(t_{ij}) \quad \ldots(2\text{-}2)$$

$(n_i * 1)$ متجة $y_i=(y_{i1},\ldots,y_{in_i})'$, $(\mathrm{n}n_i * 1)$ متجه $Y=(y'_1,\ldots,y'_n)'$

$X=(x'_1,\ldots,x'_n)$ مصفوفة , $x_i=(x_{i1},\ldots,x_{in_i})'$ مصفوفة $(\mathrm{n}n_i * dn_i)$ $(n_i * dn_i)$

ـ خصائص التقدير بطريقة الشرائح الممهدة (Smoothing Spline)

ان تكون دوال المعالم $(\beta_1(t) , \ldots , \beta_k(t))$ مستمرة وقابلة للاشتقاق ، المشتقة الثانية لها

$(\beta''_1(\mathrm{t}) , \ldots , \beta''_k(\mathrm{t}))$ محددة ويمكن تكامل مربع المشتقة (Brabanter, Johan A.K.suykens, & Bart De Moor, 2013) .

اما تقدير المعالم يكون بتصغير دالة المربعات الصغرى الجزائية J (β , λ) :-

$$\mathrm{J}(\beta,\lambda) = \sum_{i=1}^{n}\sum_{j=1}^{n_i}[y_{ij} - \{\sum_{r=1}^{d} x_{ijr}\beta_r(t_{ij})\}]^2 + \sum_{r=1}^{d}\lambda_r \int\{\beta''_r(t)\}^2 \mathrm{dt} \quad \ldots(2\text{-}3)$$

وان :-

$\lambda_r = (\lambda_1 , \ldots , \lambda_d)'$ تمثل قيم موجبة للمعالم الممهدة تتغير بتغير دوال المعاملات ، ومن اهم شرائح التمهيد هي شرائح التمهيد التكعيبية (cubic smoothing splines) (css)

يتم ايجاد التكامل الذي يعرف بالجزاء غير الممهد وتقدير المعالم الذي يتزايد عددها بزيادة عدد المشاهدات.

ولاختيار معلمة التمهيد (smoothing parameter selection) (sps) سيتم اختيار معيار العبور الشرعي (Cross Validation) وتكتب باختصار (CV) كالاتي :-

$$\mathrm{CV}(\lambda) = \frac{1}{N}\sum_{i=1}^{n}\sum_{j=1}^{n_i}\{y_{ij} - x'_{ij}\hat{\beta}^{(-i)}(t_{ij})\}^2 \ldots(2\text{-}4)$$

وان :-

$\hat{B}^{(-i)}(\mathrm{t})$ مقدر B(t) باستعمال جميع المشاهدات ما عدا تلك المشاهدات من القطاع i .

$\lambda = (\lambda_1, \ldots, \lambda_d)'$ تكون صعبة عندما d عدد المتغيرات يزداد وعدد القطاعات n او عدد القياسات لكل قطاع يكون كبير n_i .

لذا سيتم استخدام طريقة تقدير المرحلتين (Two – Step Estimation Method) لموائمة أنموذج المعاملات المتغيرة زمنيا" (P.P.B.Eggermont, R.L.Eubank, & V.N.Lariccia, 2005)،فأن طريقة css تستعمل d من معالم التمهيد يتم استعمال خوارزمية Backfitting على الرغم انها تحل مشكلة تعدد الابعاد لكنها تعاني من مشكلة اذ ان حجم المصفوفة يزداد بزيادة عدد القطاعات n او زيادة عدد نقاط الزمن المحددة n_i والذي يؤدي الى زيادة معالم التمهيد ، فأن النهج البديل هو اجراء تقدير المرحلتين .

يتم اولا حساب المقدرات الخام لموائمة أنموذج خطي قياسي ، وثانيا نمهد المقدرات الخام على المقدرات التمهيدية لدوال المعاملات .

إن اجراء المرحلتين (Two – step) (WANG, Hongzhe L1, & Jianhua UANG, 2008) يمتلك خصائص جيدة كثيرة، فهي بسيطة الفهم، سهلة التنفيذ، سريعة الحساب وفعالة في الاداء، إن هذا الاجراء له دوافع بواسطة هيكل خاص من العديد من مجموعات البيانات الطولية، حيث يتم جمع القياسات على نفس نقاط الزمن المحددة الى جميع القطاعات (على الرغم من إن عدد القياسات لكل قطاع غير متساوية او حتى مفقودة).

لنفترض t_j، j=1,…,n_i هي نقاط زمن محددة، حيث تم جمع البيانات. لأن هناك عدد من المشاهدات التي جمعت في الزمن t_j ، فمن الممكن لهذا الثابت t_j استعمال البيانات المجمعة هناك لموائمة أنموذج المعاملات المتغيرة زمنيا" والحصول على المقدرات الخام (Raw estimates) .

$$b(t_j) = \left(b_1(t_j) , \ldots . , b_d(t_j)\right)'$$

$$B(t_j) = \left(B_1(t_j) , \ldots . , B_d(t_j)\right)'$$

هذه هي المرحلة الأولى، عادةً المقدرات الخام هي غير ممهدة تحتاج الى تمهيدها للحصول على المقدرات الممهدة الى دوال المعاملات لذلك، في المرحلة الثانية لكل مركبة معطاة r = 1,2,…,d نطبق تقنية تمهيد الى البيانات $\{(b_r(t_j),t_j)$, j = 1,2,…,m}

إن مرحلة تقديرات التمهيد (Smoothing estimates) هذه حاسمة لأنها تعطي مقدرات تمهيدية لدوال معاملات التمهيد الاساسية، وإضافة الى ذلك فان مرحلة التمهيد عادةً ذات بعد واحد (one-dimensional) .

إن إجراء المرحلتين سهل التنفيذ ، حيث لكل ثابت t_j ، أنموذج (TVC) هو أنموذج خطي قياسي مع هيكل أخطاء مستقل، وهذا الاجراء سريع في الحساب، وان الاسباب الرئيسية لسرعة الحساب، في المرحلة الاولى الحساب يركز فقط على نقطة معينة وبالتالي البيانات المعنية هي قليلة جداً بالمقارنة مع بيانات المجموعة الكاملة، وفي المرحلة الثانية يتم تنفيذ العملية الحسابية لمجرد تمهيد عدة مشاكل ذات بعد واحد.

- مقدمة في الخوارزمية الجينية

بين كل من (شعبان، حسن ياسين طعمة، و حسن ثابت كرماشة، ٢٠٠٩) الخوارزمية هي مجموعة محددة من خطوات الحل التي تؤدي الى انجاز وظيفة معينة ويجب ان تتوفر فيها الشروط التالية:-

١- المدخلات (INPUT) : صفر او اكثر من قيمة .

٢- المخرجات (OUTPUT) : قيمة واحدة على الاقل .

٣- الوضوح (DEFINITENESS) : كل خطوة في الخوارزمية واضحة المعاني وغير غامضة اي يجب ان تفهم من قبل الجميع .

٤- المحدودية (FINITENES) :كل خطوات الخوارزميات يمكن حلها في فترة زمنية محددة .

٥- المحلولية (EFFECTIVENESS) : كل خطوة تكون ممكنة الحل.

- خوارزمية أصغر محدد للتباين المشترك الموزون (MinimumWheighited Covariance Determinant)

تستخدم المقدرات المرجحة لتقدير الموقع لتشتت بيانات متعدد المتغيرات بالاستناد الى رتبة مسافة (Mahalanobis Distance) (Roelant, Stefan Van Aelst, & Gert Willems, 2009) حيث قام باعطاء تقديرات المتوسط ومصفوفة التباين المشترك الى نصف البيانات يتم فيها الحصول على اصغر محدد لمصفوفة التباين المشترك (MCD) والتي تكون فيها دالة الوزن مساوية الى الصفر ، لذا فأن دالة الوزن اكثر عمومية واكثر ملائمة يمكن توضيح دالة الوزن كالاتي :-

$$a_n(i) = \mathrm{I} \quad , \quad (\mathrm{i} \le \mathrm{h}) \quad , \quad \frac{n}{2} \le \mathrm{h} \le \mathrm{n}$$

n : تمثل عدد المشاهدات

h : تمثل اعلى نقطة توقف $\mathrm{h}=\frac{n+p+1}{2}$

اي ان مقدر (MWCD) اكثر عموما من مقدر (MCD) ويتم فيها خفض دالة الوزن ، يضع وزنا اكبر على النقاط القريبة من المركز ، في حين ان وزن الدالة يعطي وزنا اكبر لمزيد من النقاط البعيدة عن المركز ، الاعتماد على وظيفة الوزن (MWCD) تعالج المتوسط لمختلف القيم المتطرفة (Zuo, 2004) .

لتقدير المركز M يتم ايجاد دالة الوزن كالاتي :-

$$a_n(i) = h^+\left(\frac{n_i}{(n+1)}\right) \quad , \quad \ldots(2\text{-}5)$$

$$\mathrm{i} = 1, \cdots, n$$

$$h^+(0\,,1) \Rightarrow [\,0\,, \infty\,)$$

$$\mathrm{Sup}\,\{\mathrm{u}; h^+(u) > 0\} = 1 - \alpha \;,\; 0 \le \alpha \le \frac{1}{2}$$

Sup : اعلى قيمة الى h^+ عندما تكون $0 \le \alpha \le \frac{1}{2}$

$$h^+(u) > 0 \quad \text{for u} \in (\,0\,, 1\text{-}\alpha\,]$$

α النسبة للمشاهدات x_i تأخذ الوزن صفر وبذلك نحصل على التقدير الحصين .

اما الخوارزمية المستعملة لايجاد (MWCD) التقريبية والمشابه الى خوارزمية (MCD) وذلك بأعتبار دالة الوزن غير متزايدة وأجراء بعض التعديلات وتعتبر تعميم الى (c – step) كالاتي :-

$X_n = \{X_1, \cdots, X_n\} \subset \mathbb{R}^p$ دالة الوزن a_n دالة غير متزايدة موضحة في المعادلة (2-5) .

الخطوة الاولى :

$$Q_1 = \sum_{i=1}^{n} a_n R_{1i} MD_1^2(\mathrm{i}) \quad \ldots(2\text{-}6)$$

a_n : تمثل دالة الوزن

$MD_1^2(i)$: تمثل مسافة مهلنوبس

R_{1i} : تمثل الرتبة الى مسافة مهلنوبس

- نجد المسافة

$$MD_1^2(\mathrm{i}) = \left(x_i - \widehat{M}_1\right)' V_1^{-1} \left(x_i - \widehat{M}_1\right)$$

i=1,⋯,n …(2-7)

$\widehat{M}_1 \in \mathbb{R}^p$ تمثل الوسط الحسابي و $\widehat{V}_1 \in \mathbb{R}^{p\times p}$ تمثل مصفوفة التباين المشترك و $\left|\widehat{V}_1\right| = 1$

- نجد الرتبة R=$(R_{11}, \cdots, R_{1n})$ الى متجه المسافة $MD_1^2\ (i)$

الخطوة الثانية :

- نجد الوسط الحسابي الموزون ومصفوفة التباين المشترك الموزون كالاتي :-

$$\widehat{M}_2 = \widehat{M}(R_1) = \frac{\sum_{i=1}^{n} a_n(R_{1i})x_i}{\sum_{i=1}^{n} a_n(R_{1i})} \quad \ldots(2\text{-}8)$$

$$\widehat{\sum}_2 = \widehat{\sum}(R_1) = c_h^+ \frac{\sum_{i=1}^{n} a_n(R_{1i})(x_i - \widehat{M}(R_{1i})(x_i - \widehat{M}(R_{1i})'}{\sum_{i=1}^{n} a_n(R_{1i})} \quad \cdots (2\text{-}9)$$

وان :-

c_h^+ عامل متسق (Chakraborty (Fisher – consistenty & Brobal Chaudhuri, 2005) حيث ان :-

$$c_h^+ = \alpha / F(\chi^2_{p+2}), (\chi^2_p) \quad \ldots(2\text{-}10)$$

الخطوة الثالثة :

$$\widehat{V}_2 = \left|\widehat{\sum}_2\right|^{-\frac{1}{p}} \widehat{\sum}_2 \quad \cdots \quad (2\text{-}11)$$ - نجد

- نجد مسافة مهلنوبس بالاستناد الى الوسط الحسابي $\widehat{M}_2$ ومصفوفة التباين المشترك $\widehat{V}_2$

$$MD_2^2(i) = \left(x_i - \widehat{M}_2\right)' \widehat{V}_2^{-1} (x_i - \widehat{M}_2) \quad \ldots(2\text{-}12)$$

i=1,⋯,n

- نجد الرتبة R_2 الى المسافة $MD_2^2(i)$

الخطوة الرابعة :

$$Q_2 = \sum_{i=1}^{n} a_n\ (R_{2i})^2 d_2^2(i) \quad \ldots(2\text{-}13)$$

$\widehat{M}_2 = \widehat{M}_1$, $\widehat{V}_2 = \widehat{V}_1$ اذا كان $Q_2 \le Q_1$

a_n : تمثل دالة الوزن

$MD_2^2(i)$: تمثل مسافة مهلنوبس

R_{2i} : تمثل الرتبة الى مسافة مهلنوبس

بالاستناد الى الخوارزمية العامة c-step الموضحة كالاتي :-

1- نبدأ بسحب عشوائي (n+1) , مجموعه جزئية j_m الى x_n .

2- نحسب متوسط العينة المطابقة $\widehat{M}_m$ ومصفوفة التباين المشترك $\widehat{V}_m$

(اذا $\left|\widehat{V}_m\right| = 0$ لكل j_m نضيف نقطة الى j_m الى ان نحصل على $\left|\widehat{V}_m\right| > 0$ او $j_m = n$) .

3- لكل مجموعة جزئية نحسب الدالة Q_1 بالاعتماد على $(\widehat{M}_m\ , \widehat{V}_m)$.

4- نطبق الخطوة 2 من c-step .

5- نختار 10 مجموعة جزئية والتي تعطي اقل قيمة الى الدالة Q_1ننفذ مرة اخرى (c-step).

6- الحل النهائي يقرر بواسطة الخوارزمية الى $\widehat{M}$ و $\widehat{V}$ مطابقة الى اقل قيمة الى الدالة Q_1 بين القيم (10) .

تحدد العينة الوسيطة تكون لديها اقل قيمة الى الدالة Q_1 .

ملاحظة بسبب اختيار عدد من التوافيق الى رتبة المتجه R لذا يمكن تحديد عدد من المعدل الموزون والتباين المشترك الموزون بالمعادلة (8-2) و (9-2).

الشكل (1) المخطط الانسيابي لخوارزمية MWCD

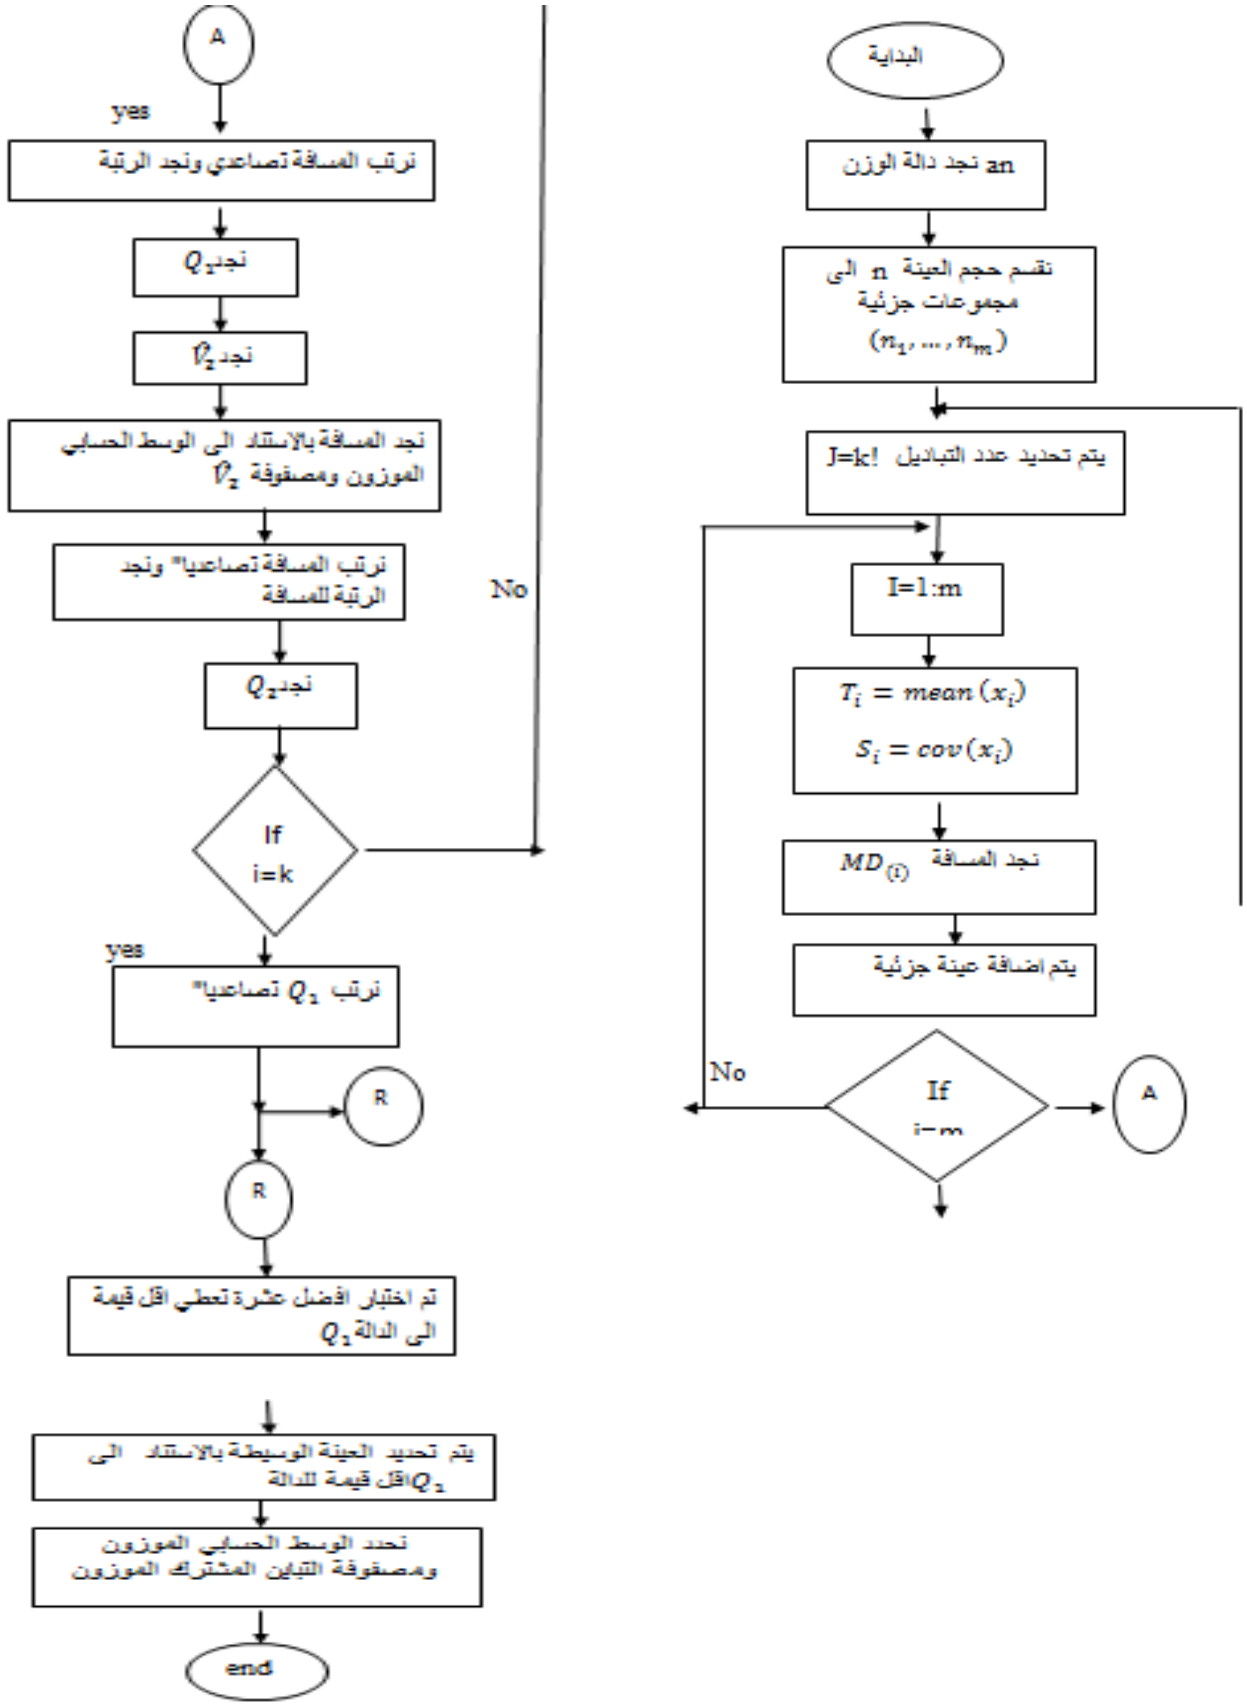

- مقدمة في الشبكات العصبية

الشبكات العصبية يمكن ان تعرف بأنها نظم او تقنية لمعالجة المعلومات منبثقة من دراسة المخ والنظام العصبي للانسان ، او هو نظام معالجة معلومات يحاكي اسلوب الشبكات العصبية الحيوية وله مميزات اداء معينة او خوارزميات او نماذج رياضية لمعالجة المعلومات .

تتكون الشبكة العصبية من مجموعة من العصبونات او الوحدات او الخلايا او العقد موزعة في طبقات وهي -: (D.crawford & Rogerl.wainwright, 1995)

1- طبقة الدخل

2- طبقة الخرج

3-طبقة المعالجة

تربط العقد مع بعضها البعض بروابط اتصال وترفق بها قيم عددية (اوزان) وتعتبر المعلومات الاساسية لحل المشكلة وفيها يبدأ الحل حيث تستقبل طبق الدخل الاشارة وتعمل على توزيعها الى الطبقات الاخرى حسب نوع الاشارة (Wu,j.1994) .

- الخلية العصبية تستقبل الاشارة وتعالجها ونحصل على مخرجات

Input → process → output

- الخلية العصبية تستمد مميزاتها من الخلية العصبية الحيوية .

- كل عصبون له Active معين ناتج من عملية المعالجة .

- الروابط هي عبارة عن connection واوزان و sum وهي العملية الاساسية في العصبون ونعني بها المحاكاة للخلية العصبية الحية فالعصبون الصناعي هو محاكاة للعصبون الحي .

اما ال sum هو جمع اشارة الدخل مضروبة في الاوزان $\sum x_i w$

x⇒cell /unit/node

w⇒weight on connection

- العصبون في طبقة الدخل لاتتم عليه اي عملية معالجة بل ادخال فقط.

- المحاكاة هي العملية الاساسية للعصبون وهناك عمليات اخرى اساسية لعملية المعالجة في الشبكة العصبية هي :-

1- neurons / node

2- connection /link

3- weights

4- summation

5- activation function

اهم نقطة في الشبكات العصبية هي الاوزان وهي الحل الامثل لحل المشكلة بالاضافة الى معمارية الشبكة Activation Function الميزة الاساسية للتفريق بين انواع الشبكات العصبية ، شبكة عصبية وحيدة الطبقة Linear وشبكة عصبية متعددة الطبقات Non Linear .

- الشبكات متعددة الطبقات MultiLayer Networks

تمتلك هذه الشبكات طبقة واحدة او اكثر من العقد المخفية Hidden Nodes

هذة العقد لا تمثل وحدات ادخال او اخراج ، ولها استخدامات عديدة مثل تميز النماذج ، تميز الاصوات ، تحليل البصمة الصوتية ، في خوارزميات الضغط والخوارزميات الجينية ...الخ.

كدالة تحويلية (sigmoid function)وتستخدم الدالة الاسية وهناك ثلاث (Despagne & D.Luc massart, 1998) انواع من الدوال :-

1- F(x) =Tanh (x B)

2- $F(x)=\frac{e^{Bx}-e^{-Bx}}{e^{Bx}+e^{-Bx}}$

B>0 3- $F(x)=\frac{1}{1+e^{-Bx}}$

وقبل البدء باستخدام الشبكات العصبية لابد من تحديد الاتي :-

1- العتبة Threshold

2- الدالة التفعيلية Activation function

الشكل رقم (2) معمارية الشبكات متعددة الطبقات (Heikki .2008)

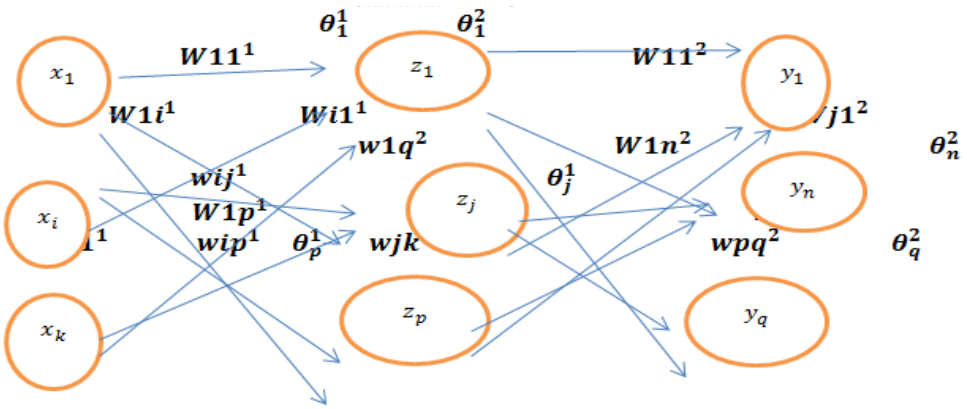

امـا افضـل خوارزميـة مسـتخدمة فـي تطبيـق الشـبكات العصبية متعددة الطبقات هي خوارزمية الانبعاث الخلفي Back Propagation Algorithm يـتم فـي هـذه الخوارزميـة ايجـاد الخطأ بين المخرج المطلوب والفعلي وتعديل الاوزان بـالرجوع به من الطبقة الاخيرة الى الطبقات الخفية ثم الـى طبقـة المـدخلات ، حيـث يسـتخدم التعلـيم المراقـب لتقليـل الخطـأ باتجـاه الصـفر ، خلال عملية التعليم يتم تدريب الشبكة باستخدام الدالـة السيبية (الدالـة التفعيليـة) Activation functions والتـي تكـون قابلـة للتفاضل

(Differentiation) بالاضـافة ان لا تكـون ثنائيـة القيمـة وان تكون قادرة على النمذجة اللاخطية ، وتوجد انـواع مختلفـة مـن الدوال التفعيلية :-

1- الدالـة الخطيـة (Linear function) وتستعمل عادتـا فـي خلايا طبقة المخرجات .

2- Sigmoid function تستعمل في الطبقات الاخرى .

من خواص الانبعاث الخلفي (الارتدادي) تقليل الخطـأ وقابليتهـا للتعامـل مـع البيانـات المشوشـة وكـذلك قـدرتها علـى التعامـل مـع الدوال الخطية واللاخطية القابلة للاشتقاق .

امـا خطـوات خوارزميـة الانبعـاث الخلفـي (الارتداديـة) هـي كالاتي :-

1- اعطاء قيم عشوائية للاوزان w .

2- تعريف معامل التعليم (قيمة معامل التعلم الدقيقة a=0.5) .

3- ادخـال مصـفوفة تمثـل مـدخلات ومخرجـات التـي تـم التـدرب عليها .

4 - تطبيق عملية الانتشار الامامي لتحديد مخرجات الشبكة

$$z_p=\sum_k w_{kp}^1 x_k$$

x_k : تمثل المدخلات التي تم التدرب عليها .

w_{kp}^1 : تمثـل الاوزان العشـوائية التـي تـربط طبقـة المـدخلات والعقد الخفية .

بعد مـرور هـذه القيمـة علـى الخليـة والممثلـة فـي الدالـة السـيبية sigmoid function يكـون مخـرج كـل خليـة فـي طبقـة المخرجات

$$\theta_p^1 = \frac{1}{1+e^{-z_p}}$$

$$y_q=\sum_p w_{pq}^2 \theta_p^1$$

$$\theta_q^2=\frac{1}{1+e^{-y_q}}$$

5 - مقارنـة المخرجـات الفعليـة مـع المخرجـات المطلوبـة وتحديـد قيمة الخطأ

$$\delta_1 = (t_k-\theta_q^2)\ \theta_p^2\ (1-\theta_q^2)$$

t_k : تمثل مخرج الخلية .

δ_1 : الخطأ .

تعديل الاوزان التي تربط الطبقة الخفية وطبقة المدخلات في الطبقة الثانية

$$w_{pq}\text{new} = w_{pq}\text{old} + a\delta_1\theta_q^2$$

a = 0.5 تمثل معامل التعلم .

6 - بعد الوصـول الـى الطبقـة الخفيـة نعيـد العمليـات السـابقة فـي تعديل الاوزان بعد تحديد قيمة الخطأ

$$\delta_2=\theta_q^2(1-\theta_q^2)\ \sum_q w_{pq}^2\delta_1$$

وبالتالي يتم تحديد الاوزان الجديدة بين طبقة المدخلات والطبقة الخفية

$$w_{kp}\ \text{new} = \text{old} + a\ \delta_2\ x_k$$

w_{kp}

تكرر هذة الخطوات لعدة مرات وذلك للحصـول علـى اقل نسبة للخطأ .

الاطار العملي

في هذا الفصل سوف يتم تطبيق ما تم التطرق الية في الجانب النظـري باسـتخدام بيانـات تشـمل انـواع المؤشـرات الكيمياويـة والفيزياوية المسببة لتلوث مياه الشرب ، حيث ان زيـادة فـي نسبة المؤشرات يؤدي الى تلوث الماء، وقد تم استخدام تسع انـواع مـن المؤشرات لكافة محافظات العراق عدا اقليم كردستان.

امـا المقارنـة فقد كانـت بين الخوارزميـة الجينيـة MWCD والشبكة العصبية متعددة الطبقات الارجاعية (الارتدادية) Back Propagation

من حيث السرعة والدقة في ايجاد موقع الوسيط عندما يكون لـدينا نموذج انحدارمتعدد المتغيرات اللامعلمي .

وقد تم استخدام برنامج Matlab في التطبيق .

- جمع البيانات

اعتمـدت الدراسـة علـى الاحصـاءات البيئيـة للعـراق لسـنة 2013 الصـادرة من الجهاز المركزي للاحصاء مقسمة الى (10) أشهر وتشمل المحافظات كافة عدا اقليم كردستان وقد تم استخدام (9) انـواع مـن المؤشـرات الكيمياويـة والفيزياويـة المسببة لتلـوث ميـاه الشـرب موضـحة فـي الجـدول رقـم (1) والـذي يبـين فيـه المؤشـرات الداخلـة فـي ميـاه الشـرب مـع الرمـز ووحـدة القيـاس المطابقـة للمواصـفات العراقيـة اذ ان الزيـادة فـي الحـدود الـدنيا للقياس تسبب تلوث في مياه الشرب .

اما البيانات المستخدمة في هذة الدراسة موضحة كالاتي :-

جدول رقم (1) المؤشرات الداخلة في مياه الشرب مع الرمز الحدود الدنيا للقياس ووحدة القياس للمواصفات العراقية

المؤشر	الرمز	وحدة القياس	الحدود الدنيا للقياس
العكورة	Turbidity	NTU	5
العسرة الكلية	T.H	mg/ L	500
القاعدية	ALK.	mg/ L	0.2
الأملاح الذائبة الكلية	T.D.S	mg/ L	1000
الكلوريدات	Cl	mg/ L	350
الكالسيوم	Ca	mg/ L	150
المغنسيوم	Mg	mg/ L	100
الصوديوم	Na	mg/ L	200
الكبريتات	SO4	mg/ L	400

المصدر:الاحصاءات البيئية للعراق لسنة 2013 الصادر من الجهاز المركزي للاحصاء .

-Minimum Weighted Covariance Determinant (MWCD)

يتم في هذه الخوارزمية الاعتماد على الرتبة الى المسافة ، يتم فيها تحديد دالة الوزن الموضحة في المعادلة (5-٢) كالاتي :-

an=0.499443826

≃0.5

المرحلة الاولى

الخطوة الاولى :

بعد تحديد الوزن يتم السحب العشوائي للعينات مع اخذ التباديل (permutations) لكل العينات ، يتم ايجاد المسافة (Md) للعينة الاولى بالاعتماد على الوسط الحساي $\widehat{M}_1$ ومصفوفة التباين المشترك ثم يتم سحب عينة عشوائية اخرى واضافتها للعينة الاولى ، يتم ايجاد المسافة لكل عينة (لكل اضافة) وتكرر عملية السحب والاضافة لحين الحصول على (N=898) التي تمثل العينة الكلية .

الخطوة الثانية :

يتم ترتيب المسافة تصاعديا Md وايجاد الرتبة الى المسافة R_i ثم نجد Q_1 الموضحة في المعادلة (2-6) .

الخطوة الثالثة :

بعدها يتم ايجاد الوسط الحسابي الموزون $\widehat{M}_2$ و $\widehat{\sum}$ الموضحة في المعادلة (2-8) و (2-9) على التوالي ،اما قيمة العامل المتسق (Fisher- consistenty) $(ch^+ = 0.0057)$ لمستوى معنوي (0.5) وعددالمتغيرات (p=9) .

الخطوة الرابعة :

يتم ايجاد $\widehat{V}_2$ بعدها يتم ايجاد المسافة بالاستنادالى الوسط الحسابي $\widehat{M}_2$ الموزون ومصفوفة التباين المشترك $\widehat{V}_2$ وايجاد الرتبة المقابلة للمسافة ثم يتم ايجاد Q_2 الموضحة في المعادلة (2-13) .

الخطوة الخامسة :

بعد اخذ التباديل لجميع العينات الجزئية حيث ان عدد التباديل 737 تتم المقارنة بين Q_1 و بتطبيق الخوارزمية العامة c-step بعد ترتيب Q_1 تصاعديا" لجميع التباديل يتم عند ذلك اختيار افضل عشرة التي تكون لديها اصغر دالة (Q_1) ،ثم نحدد $(\widehat{M}, \widehat{V})$ يكون لديها اقل قيمة للدالة (Q_1) من بين القيم العشرة التي تم اختيارها و قيمتها (Q_1=8.4356e+03) ، اما العينة الوسيطة

$$N=n_7+n_3+n_4+n_8+n_1+n_2+n_5+n_6+n_9+n_{10}$$

- الشبكات العصبية متعددة الطبقات

لتطبيق الشبكات متعددة الطبقات لابد من تحديد عدد الطبقات وعدد العصبون neuron لكل طبقة بالاضافة الى تحديد الاوزان التي سيتم توليدها والشكل التالي يوضح مخطط الشبكة التي سيتم التطبيق عليها :-

الشكل رقم (٣) تطبيق مخطط الشبكة

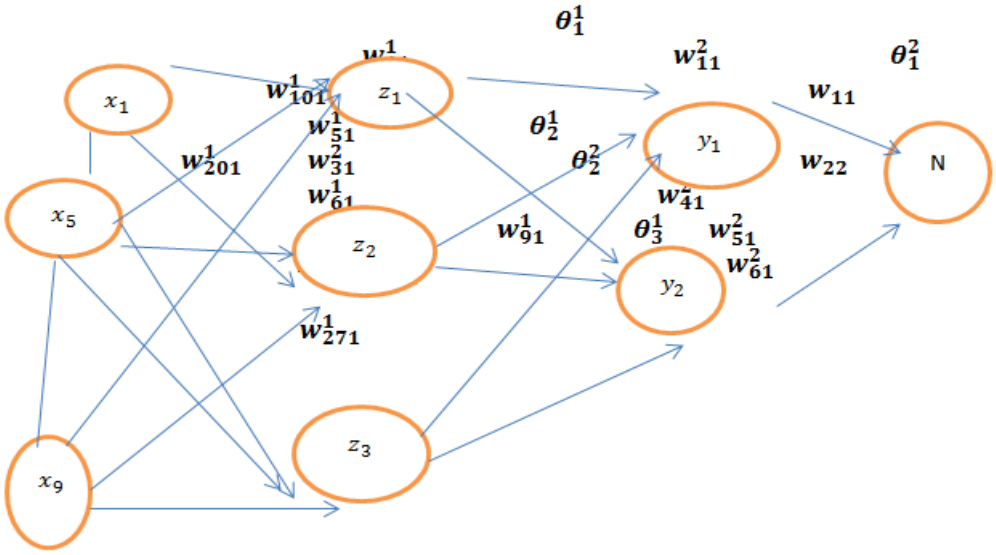

x_n : تمثل المدخلات (المؤشرات الداخلة في تلوث مياه الشرب) و n=1,2,…,9

z_p : الطبقة الخفية و p=1,2,3

y_q : الطبقة الخفية و q=1,2

w_{kp}^1 : الاوزان العشوائية في الطبقة الاولى و k=1,2,…,27

w_{jq}^2 : الاوزان العشوائية في الطبقة الثانية و j=1,2,…,6

w_{11} و w_{22} الاوزان العشوائية

θ_p^1 : العصبون في الطبقة الاولى الذي يربط طبقة المدخلات مع الطبقة الخفية

θ_q^2 : العصبون في الطبقة الثانية

تم استعمال خوارزمية الانبعاث الخلفي (الارتدادية) والتعليم المراقب لتدريب الشبكة العصبية متعددة الطبقات ، ففي المرحلة الاولى تم توليد الاوزان العشوائية التي تدخل طبقة المدخلات وفيها يتم ضرب الاوزان مع كل عنصر دخل x_i ثم يتم ايجاد مجموع المدخلات للخلية الاولى في الطبقة الخفية كالاتي :-

$$z_p=\sum_k w_{kp}^1 x_i$$

يتم تمرير المدخلات وصولا الى طبقة المخرجات وذلك باستخدام الدالة السيبية

$$\theta_p^1 = \frac{1}{1+e^{-z_p}}$$

جدول رقم (2) جدول الاوزان العشوائية التي تم توليدها في الطبقة الاولى

الاوزان العشوائية في الطبقة الاولى
0.8234578283
0.6948286229
0.3170994800
0.9502220488
0.0344460805
0.4387443596
0.3815584570
0.7655167881
0.7951999011

0.1868726045
0.4897643957
0.4455862007
0.6463130101
0.7093648308
0.7546866819
0.2760250769
0.6797026768
0.6550980039
0.1626117351
0.1189976815
0.4983640519
0.9597439585
0.3403857266
0.5852677509
0.7546866819
0.7512670593
0.2550951154

يتم بعدها توليد اوزان الطبقة الثانية حيث تضرب الاوزان مع المخرجات التي تم الحصول عليها من الطبقة الاولى وتجميعها في الطبقة الخفية كالاتي :-

$$y_q=\sum_p w_{pq}^2\theta_p^1$$

جدول رقم (3) جدول الاوزان العشوائية في الطبقة الثانية

اوزان الطبقة الثانية
٠.٥٦٤٥٠٣٦٣٨٩
٠.٧٧٤٢٧٤٩٦٢٠
٠.٩٤٩٤٤٩٨٣٩٨
١.٠٣٤٤٨٩٦٦٤٥
٠.٦٠٥٧٦٢١١٧٢
٠.٢١٣٨٢٢٦٨٢٢

يتم تمرير مدخلات الطبقة الخفية باستخدام الدالة السيبية الاتية :

$$\theta_q^2=\frac{1}{1+e^{-y_q}}$$

يتم بعدها تحديد قيمة الخطأ وذلك من خلال مقارنة المخرجات الفعلية مع المخرجات المطلوبة (t_k) اذ ان قيمة المخرجات الفعلية يتم ايجادها من ضرب الاوزان العشوائية w_{11} و w_{22} مع θ_q^2 وايجاد مجموع المدخلات لخلية طبقة المخرجات N

وبهذا يكون المخرج الفعلي للشبكة $O=\frac{1}{1+e^{-N}}$ و

$N=w_{11}\theta_1^2+w_{22}\theta_2^2$

اما قيمة الاوزان العشوائية التي تم توليدها هي كالاتي :-

w_{11}= 1.0062466544

w_{22}= 1.1013133923

لتعديل الاوزان نبدأ اولا بتحديد قيمة الخطأ

$\delta_1=(t_k\text{-O})*O*(1\text{-O})$

بعد تحديد قيمة الخطأ يتم تعديل الاوزان التي تربط بين الطبقة الخفية وطبقة المخرجات من المعادلة التالية :-

$w_{11}\text{new} = w_{11}\text{old} + a\delta_1\theta_1^2$

$w_{22}\text{new} = w_{22}\text{old} + a\delta_1\theta_2^2$

اما قيمة معامل التعلم a=0.5

ثم الانتقال في هذة المرحلة من طبقة المخرجات الى الطبقة الخفية .

ولتعديل اوزان الطبقة الثانية يتم اولا ايجاد قيمة الخطأ

$\delta_{11}=\theta_1^2(1-\theta_1^2)w_{11}new\delta_1$

$\delta_{22}=\theta_2^2(1-\theta_2^2)w_{22}new\delta_1$

ثم تعدل الاوزان في الطبقة الثانية كالاتي :-

$w_{11}^2new = w_{11}^2\ old + a\delta_{11}\theta_1^1$

$w_{21}^2new = w_{21}^2\ old + a\delta_{22}\theta_1^1$

$w_{31}^2new = w_{31}^2\ old + a\delta_{11}\theta_2^1$

$w_{41}^2new = w_{41}^2\ old + a\delta_{22}\theta_2^1$

$w_{51}^2new = w_{51}^2\ old + a\delta_{11}\theta_3^1$

$w_{61}^2new = w_{61}^2\ old + a\delta_{22}\theta_3^1$

والان يمكن تعديل الاوزان في طبقة المدخلات بعد ايجاد قيمة الخطأ بين الطبقة الخفية الاولى وطبقة المدخلات كالاتي :-

$\delta_1^1=\theta_1^1(1-\theta_1^1)(w_{11}new\delta_{11}+w_{21}new\delta_{22})$

$\delta_2^1=\theta_2^1(1-\theta_2^1)(w_{31}new\delta_{11}+w_{41}new\delta_{22})$

$\delta_3^1=\theta_3^1(1-\theta_3^1)(w_{51}new\delta_{11}+w_{61}new\delta_{22})$

اما الاوزان يمكن ايجادها من المعادلات التالية :-

$w_{11}new=w_{11}old + a\delta_1^1x_1$ ⋮

$w_{91}new=w_{91}old + a\delta_1^1x_9$

$w_{101}new=w_{101}old + a\delta_2^1x_1$ ⋮

$w_{181}new=w_{181}old + a\delta_2^1x_9$

$w_{191}new=w_{191}old + a\delta_3^1x_1$ ⋮

$w_{271}new=w_{271}old + a\delta_3^1x_9$

تم تكرار خطوات خوارزمية الشبكة العصبية (50) مرة للحصول على اقل نسبة للخطأ بعدها يتم ايجاد مصفوفة التباين والتباين المشترك للعينات ثم تحديد افضل عينة من خلال ايجاد اصغر مسافة Mahalanobis Distance وقد تمثلت في مشاهدات العينة (n_4) .

جدول رقم (4) الجدول يوضح النتائج مبين فية التباين والمسافة والمحدد لافضل عينة محددة

الشبكات العصبية المؤشرات	الشبكة العصبية Multilayer التباين	الخوارزمية الجينية MWCD التباين
Turb	48.2349	1.318e+9
T.H	9.1019e+03	1.0808e+12
ALK.	186.0992	1.3969e+11
T.D.S	3.5928e+05	3.9629e+12
CL	6.9147e+03	1.6613e+11
Ca	580.0939	6.2401e+10
Mg	264.4959	1.1083e+10
Na	1.9738e+03	5.0443e+10
SO4	7.1561e+03	3.6397e+11
المسافة (md)	6.4933e-26	8.4356e+03
المحدد (sd)	7.4450e+23	9.6518e+058

يشير الجدول اعلاه الى ان التقدير لموقع الوسيط باستخدام الشبكة العصبية الارجاعية (الارتدادية) افضل وذلك من خلال مقارنة التباين والمسافة والمحدد اقل بكثير من الخوارزمية الجينية MWCD .

- تقدير معاملات الانموذج المتغيرة زمنيا

في هذا المبحث سيتم تقدير معاملات الانموذج المتغيرة زمنيا" (بيانات القياسات المتكررة repeated measurement) بايجاد معالم التمهيد لدالة المعاملات $(B_1(t_j),\ldots,B_r(t_j))$ باستعمال معيار CV , ويمكن توضيح الانموذج كالاتي :-

$y_i(t_j)=x_{r,i}(t_j)\beta_r(t_j)+\epsilon_i(t_j)$

r= 1,2,…,9

i=1,2,…,15

j=1,2,…,n_4

و ان :-

$y_i(t_j)$ متجه : 87*1

$x_{r,i}(t_j)$ مصفوفة : 87*135

$\beta_r(t_j)$ متجه : 135*1

$\epsilon_i(t_j)$ متجه : 135*1

ومن خـــلال كفاءة التقدير للشبكـــة العصبيـــة الارجاعية (الارتداديـة) التـي تـــــم مقارنتهـا مـع الخوارزميـة الجينيـة (MWCD) الممثلـة بالعينـة n_4 ، لـذا سـيتم تقـدير معـاملات الانمـوذج للعينـــة n_4 باســتعمال شــرائح التمهيــد التكعيبيــة والموضحة نتائجها في الجدول رقم (5) و (6) و(7) اما نتائج معالم التمهيد فهي كالاتي :-

(λ_1 =0.5672 , λ_2 = 1.9326 , λ_3 =0.3284 , λ_4 = 0.4037 , λ_5 = 0.3035 , λ_6=0.3350 , λ_7 = 0.3009 , λ_8 = 0.3213 , λ_9 = 0.3063)

رقم (5) تقدير معاملات العينةn_4 لانموذج الشبكة العصبية متعددة الطبقات الارجاعية (الارتدادية)

المحافظة / المعاملات	بغداد	صلاح الدين	الانبار	نينوى	ديالى
$B_1(t_j)$	-0.1368	2.1029	3.4633	-1.4551	0.0671
$B_2(t_j)$	0.0194	-0.0074	0.0186	0.0124	0.0659
$B_3(t_j)$	2.0679e+08	-1.9640e+06	1.0215e+16	5.6548e+08	-6.1498e+09
$B_4(t_j)$	4.4688	503.9278	-359.9195	3.6856e+03	-152.965
$B_5(t_j)$	-6.2180e+29	-4.7957e+27	-1.0987e+26	-2.7939e+39	8.4498e+35
$B_6(t_j)$	-1.3882e+28	-5.7626e+29	-1.2624e+29	1.2600e+25	-1.7703e+27
$B_7(t_j)$	1.1806e+41	-3.3466e+38	3.9549e+38	6.7824e+45	-1.1895e+44
$B_8(t_j)$	-6.0566e+35	1.0358e+48	1.3925e+31	-3.6822e+49	4.5829+22
$B_9(t_j)$	-7.6579e+16	-8.8761e+22	1.9365e+20	6.7159e+28	-8.7902e+20

الجدول رقم (6) تقدير معاملات العينةn_4 لانموذج الشبكة العصبية متعددة الطبقات الارجاعية (الارتدادية) .

المحافظة / المعاملات	بابل	ذي قار	كربلاء	النجف	المثنى
$B_1(t_j)$	0.4447	0.1076	2.2284	0.8020	1.0677
$B_2(t_j)$	0.0029	0.0242	-0.0090	0.0088	0.0084
$B_3(t_j)$	-2.1315e+14	-8.4631e+08	-8.1258e+14	-7.0947e+19	1.6457e+12
$B_4(t_j)$	21.8447	-0.0667	-1.7809	-0.8350	0.0462
$B_5(t_j)$	-3.4744e+25	-3.2466e+21	4.1191e+26	-1.4570e+24	-4.4188e+17
$B_6(t_j)$	-4.6586e+27	-7.5678e+28	3.3603e+29	-3.7317e+26	-1.3052e+27
$B_7(t_j)$	-1.1859e+44	-5.8282e+38	1.9075e+41	-3.5059e+40	-8.3386e+45
$B_8(t_j)$	3.5592e+32	4.4087e+31	1.0717e+31	5.8199e+25	-3.8251e+24
$B_9(t_j)$	-6.5662e+13	-1.4949e+19	-2.6762e+16	2.3564e+16	-1.3322e+16

الجدول رقم (7) تقدير معاملات العينةn_4 لانموذج الشبكة العصبية متعددة الطبقات الارجاعية (الارتدادية) .

المحافظة / المعاملات	كركوك	القادسية	البصرة	ميسان	واسط
$B_1(t_j)$	-3.0743	0.0133	-7.5232	0.0162	1.4622
$B_2(t_j)$	0.0349	-0.0133	0.0080	-0.0448	-0.0040
$B_3(t_j)$	-1.0614e+06	-1.8191e+14	8.6728e+13	-2.9273e+15	-8.1519e+08
$B_4(t_j)$	-7.8626e+05	0.0397	-1.1918	4.2009	1.3392
$B_5(t_j)$	2.6791e+38	-2.7138e+26	4.7743e+16	3.9796e+16	6.5721e+23
$B_6(t_j)$	-1.4852e+27	3.3167e+29	-8.9767e+36	9.4747e+32	3.6500e+31
$B_7(t_j)$	-5.6134e+38	8.2124e+42	-4.5204e+44	4.5480e+38	-9.7334e+31
$B_8(t_j)$	4.9315e+47	-3.9929e+23	-1.3023e+37	1.2212e+28	-2.2046e+26
$B_9(t_j)$	1.4907e+34	1.9410e+19	-7.0228e+23	3.0293e+24	8.0225e+19

يوضح الجدول رقم (5) و(6) و(7) تقارب في قيم المعاملات للعكورة وكذلك العسرة الكلية والذي يدل على عدم تلوث للمياه في كافة المحافظات ، ارتفاع القاعدية في المحافظات (بغداد ، الانبار ، نينوى ، المثنى ، البصرة) ، اما الاملاح الذائبة الكلية نلاحظ ارتفاع في قيم معاملاتها في محافظة (نينوى) عن الحد المسموح به ، وارتفاع الكلوريدات في المحافظات (ديالى ، كربلاء ، كركوك ، البصرة ، ميسان ، واسط) اما الكالسيوم فقد كانت نسبته مرتفعة عن الحد الادنى في المحافظات (نينوى ، كربلاء ، القادسية ، ميسان ، واسط) .

اما المغنيسيوم نلاحظ ارتفاعه في المحافظات (بغداد ، الانبار ، نينوى ، كربلاء ، القادسية ، ميسان) ، وارتفاع الصوديوم في المحافظات (صلاح الدين ، الانبار ، ديالى ، بابل ، ذي قار ، كربلاء ، النجف ، كركوك ، ميسان) ، اما ارتفاع الكبريتات كان في المحافظات (الانبار ، نينوى ، النجف ، كركوك ، القادسية ، ميسان ، واسط) ارتفاع قيم المعاملات عن الحد الادنى للقياس المسموح به يؤدي الى تلوث المياه .

الاستنتاجات والتوصيات

الاستنتاجات

١. انخفاض التباين باستعمال الشبكة العصبية متعددة الطبقات الارجاعية (الارتدادية) وكذلك المحدد والمسافة مقارنتا بالخوارزمية الجينية MWCD ، سرعة الشبكة العصبية متعددة الطبقات الارجاعية (الارتدادية)اذ ان عدد تكرارات 50 في حين ان الخوارزمية الجينية MWCD عدد تكراراتها 737 حيث تم فيها اخذ التباديل للعينات الجزئية .

٢. بعد تحديد العينة الوسيطة المتمثلة بالعينة n_4 وتقدير قيم المعاملات لوحظ ان مؤشر العكورة والعسرة الكلية لم تتجاوز الحد الاعلى للقياس مما يدل على عدم تلوث المياه فيما يخص المؤشرين اعلاه لكل المحافظات .

٣. بعد تحديد العينة الوسيطة وتقدير معاملات العينة n_4 والتي يمكن من خلالها الاستدلال على تلوث المياه في بعض المحافظات والتي ظهرت في بعض من مؤشرات التلوث وذلك من خلال الحد الادنى للقياس المسموح به، حيث يمكن معالجة تلوثات المياة وتحديد المحافظة ونوع المؤشرالمسبب للتلوث .

التوصيات

تطبيق الشبكة العصبية متعددة الطبقات عند زيادة حجم العينة في نموذج متعدد المتغيرات لسرعتها ،وكذلك مقارنتها مع شبكات عصبية وكذلك خوارزميات جينية اخرى.

المصادر

هند رستم محمد شعبان، حسن ياسين طعمة، و حسن ثابت كرماشة. (٢٠٠٩). تحليل وتصميم الخوارزميات. ٢٣ فبراير.

Azzini, A., Andrea G.B.Tettamanzi, & Vincenzopiuri. (2005). Anew Genetic Approach for Neural Network Design and optimization. UNIVERSITA DEGLISTUDI.

Brabanter, K. D., Johan A.K.suykens, & Bart De Moor. (2013). Nonparametric Regression Via stat Lssvm. journal of statistical software, 1-22.

Chakraborty, B., & Brobal Chaudhuri. (2005). On An optimization problem in robust. Retrieved from www2.ims.nus.sg/preprints/2005-26

measurements. Journal of the American statistical Asso-ciation, 1556-1569.

WU, J. (1994). Neural Network and simulation methods. In I. Marcel Dakker. New york.

Z.Huang, J., Colin O.wu, & Lan Zhou. (2004). Polynomial spline estimation and inference for varying coefficient model with ligitudinal data. statistica sinica, 763-788.

Zuo, Y. (2004). Projection-Based Affine Equivariant Multivariate Location Estimators with the Best Possible Finite sample Breakdown Point. statistics sinica, 1199-1208.

D.crawford, K., & Rogerl.wainwright. (1995). Applying Genetic Algorithm to outlier Detection Morgan Kaufmn. Retrieved from Euler.mcs.utulsa,edu/~rogerw/.../Crawford-icga95.

Despagne, F., & D.Luc massart. (1998). Neural Network in Multivariate Calibration. Analyst, 157-178.

J.Rousseeuw, P., Stefan Van Aelst, Katrien Van Driessen, & Jose Agullo. (2003). Robust Multivariate Regression. Retrieved from Users.ugent.be/~svaelst/.../multi MCD-report.

Johnston, R. (1996). Are speech Recognitionstill98% Accurate or has the time come Repeal HYDE Law. BTTehnoly, 165-176.

Kinnerbrock, W. (1995). Neural Network. Suneel Galgotia.

N.Koivo, H. (2008). NEURAL NETWORKS:Basics using MATLAB Neural Network Toolbox. pp. 1-59.

P.P.B.Eggermont, R.L.Eubank, & V.N.Lariccia. (2005, May 18). Convergence Rates for smoothing spline Estimators in varying coefficient model. Retrieved from www.udel.edu/FREC/eggemont/.../Time Varying.

pison, G., & Stefan Van Aelst. (2003). Retrieved from Diagnostic Plots for Robust Multivariate Methods: https://Iirias.kuleuven.be/../diagnostic plots-report.pdf

R.Hoover, D., John A.Rice, Colin O.wu, & LI-PING YANG. (1998). Nonparametric smoothing estimates of time - varying coefficient models with longitudinal data. Biometrika, 809-822.

Roelant, E., Stefan Van Aelst, & Gert Willems. (2009). The minimum weighted covariance determinant estimator. DOI1007/soo184-0186-3, 177-204.

WANG, L., Hongzhe L1, & Jianhua UANG. (2008). Variable selection in Nonparametric varying - coefficient models for Analysis of Repeated