

مقارنة بين طريقتي التنقية المكيفة والشبكات العصبية مع التطبيق
صفاء يونس الصفاوي*
عزة حازم زكي**

الملخص

ان دراسة السلاسل الزمنية من المواضيع المهمة وخاصة في تحليل سلوك الظواهر المختلفة وتفسيرها وذلك من خلال دراسة وتحليل تطورها التاريخي عبر فترات زمنية مختلفة بهدف التنبؤ المستقبلي.

من الأهداف الأساسية للعلوم الإحصائية التنبؤ بالسلوك المستقبلي للظاهرة قيد البحث. اذ نجد يومياً، ومن خلال وسائل الاعلام، الاهتمام اليومي بالتكهنات الجوية والمتغيرات الاقتصادية المختلفة. وقد أولى تحليل السلاسل الزمنية اهتماماً كبيراً للتنبؤ واقترحت العديد من الأساليب لغرض إجراء التنبؤ. ويهدف هذا البحث الى مقارنة طريقتي التنقية المكيفة والشبكات العصبية الاصطناعية في التنبؤ للقيم المستقبلية لنماذج السلاسل الزمنية.

**Comparative Between Adaptive Filtering And Neural
Networks Methods With Application**

ABSTRACT

The study of time series is one of first important subjects especially with study of analysis behavior of different phenomenon's and discussed it throw the historical in different period to forecasting.

The initial aims of statistical sciences to know the behavior of feature search, we found each day throw the media the care of different economic and wether forecasting. The aim of this search to compare Adaptive Filtering and Artificial Neural Networks to forecasting of time series models.

* استاذ مساعد/ كلية علوم الحاسبات والرياضيات/جامعة الموصل

** مدرس مساعد/ مركز الحاسبة الالكترونية/ جامعة الموصل

1- المقدمة

من احدى الطرائق المستخدمة لاغراض التنبؤ هي طريقة التنقية المكيفة Adaptive Filtering حيث قدم Makridakis و Wright سنة (1973) خوارزمية لمراجعة معاملات الفروق العشوائية (التصادفية) الخطية والمضاف اليها حد التصحيح النسبي من المعلمات القديمة الى حاصل ضرب بواقى التكهّنات الاكثر حداثة وقيم المشاهدات الاولية وكانت التنقية المكيفة في ذلك الوقت تستخدم نماذج الانحدار الذاتي Autoregressive Models. وفي عام (1977) قاما بتوسيع المفردات لتشمل الانحدار الذاتي المتسلسل مع نماذج المتوسطات المتحركة والسلاسل الزمنية غير المستقرة Non-Stationary Time Series.

ومن الأساليب الحديثة التي أخذت اهتماماً ملحوظاً، وخاصة في مجال علوم الحاسبات، الشبكات العصبية الاصطناعية Artificial Neural Networks (ANNs)، اذ كانت في البداية بسيطة متمثلة بطبقة واحدة (Single layer) من الخلايا العصبية الاصطناعية التي أطلق عليها خلية الإدراك الحسي (Perceptrons)، افترضها الباحث (Frank Roseblatt, 1958) وكانت عملية التعلم فيها مقتصرة على النماذج الخطية (Linear Model) لأغراض التقدير أو التصنيف أو التنبؤ، ثم تم التوصل إلى شكل جديد للإدراك الحسي بإضافة مستوى جديد أطلق عليه المستوى المخفي (Hidden Level)، اكسب الإدراك الحسي القدرة على حساب الدوال والعلاقات لنماذج البيانات الخطية واللاخطية. وتطور هذا المستوى بإضافة أوزان تربط بين مستوى الإدخال والمخفي من قبل العالم (Paul Werbos, 1974)، اذ لم يُنرَ هذا التطور اهتمام الباحثين في حقل الشبكات العصبية الاصطناعية الا في منتصف الثمانينات بعد استخدام خوارزمية انتشار الخطأ خلفاً (Backpropagation Error) كي يساعد الشبكات متعددة الطبقات على التعلم (الشيخلي، 2003).

2- الجانب النظري

2-1 طريقة التنقية المكيفة

ان الصيغة العامة لطريقة التنقية المكيفة في النماذج المختلطة ARMA(1,1) تكون كالآتي:

$$X_t = \phi_{1t}X_{t-1} + a_t - \theta_{1t}a_{t-1} \quad (1)$$

حيث ان

a_t : مركبة الخطأ العشوائي بمتوسط صفر وتباين σ_a^2

ϕ_{1t} و θ_{1t} : معاملات غير معلومة وليست ثابتة وتتغير من فترة لآخرى.

ان المعلمات ϕ_{1t} و θ_{1t} يمكن تقديرها من خلال طريقة المربعات الصغرى غير الخطية Non Linear Least Square Method باستخدام طريقة الهبوط شديد الانحدار Steepest descent أي البحث عن اقل ميل. ويمكن ايجاد الميل gradient عند اية نقطة على سطح الاستجابة عن طريق اشتقاق دالة متوسط مربعات الخطأ (MSe) والممثلة a_t^2 حيث

$$a_t = X_t - \phi_{1t}X_{t-1} + \theta_{1t}a_{t-1} \quad (2)$$

او

$$a_t^2 = (X_t - \phi_{1t}X_{t-1} + \theta_{1t}a_{t-1})^2$$

$$\frac{\partial a_t^2}{\partial \phi_{1t}} = -2a_t X_{t-1}$$

$$\frac{\partial a_t^2}{\partial \theta_{1t}} = 2a_t a_{t-1}$$

$$\phi_{1t}^* = \phi_{1t} - k \overline{\nabla a^2} \quad (3)$$

حيث ان

ϕ_{1t}^* : المعلمة المكيفة الجديدة

ϕ_{1t} : المعلمة القديمة

k: ثابت اختياري والذي يسيطر على سرعة التقارب وعلى عدد التكرارات المستخدمة.

∇a^2 موجه الميل الى $\overline{a^2}$ والمعادلة

$$\phi_{1t}^* = \phi_{1t} + 2ka_t X_{t-1} \quad (4)$$

تستخدم في تقدير قيم الانحدار الذاتي اما المعادلة

$$\theta_{1t}^* = \theta_{1t} - 2ka_t a_{t-1} \quad (5)$$

فتستخدم لتقدير قيم المتوسطات المتحركة.

عادة، نبدأ بقيم اولية للمعاملات θ_1 و ϕ_1 ثم يتم تعديل هذه المعلمات تباعاً، النقطة التي تصل الى اقل قيمة ممكنة لمتوسط مربعات الخطأ MSE فان تكرار المعلمات يمكن ان يحدد والقيم النهائية تستخدم للتنبؤ. بتعويض (4) و (5) في المعادلة (1) نحصل على

$$\begin{aligned} a_t^* &= X_t - \phi_{1t}^* X_{t-1} + \theta_{1t}^* a_{t-1} \\ \Delta a_t &= a_t^* - a_t \\ &= -(\phi_{1t}^* - \phi_{1t}) X_{t-1} + (\theta_{1t}^* - \theta_{1t}) a_{t-1} \\ &= -2ka_t (X_{t-1}^2 + a_{t-1}^2) \end{aligned}$$

لذلك

$$\frac{|\Delta a_t|}{a_t} = 2k(X_{t-1}^2 + a_{t-1}^2) \quad (6)$$

$$0 < k < \frac{1}{X_t^2 + a_{t-1}^2} \quad \text{ويمكن ان نستنتج ان}$$

(Al-Nassir, 2005).

1-1-2 التنقية المكيفة لنموذج المتوسطات المتحركة من الرتبة q.

ان نموذج المتوسطات المتحركة من الرتبة q MA(q) يكتب وفق

الصيغة الآتية:

$$X_t = a_t - \theta_{1t} a_{t-1} - \theta_{2t} a_{t-2} - \dots - \theta_{qt} a_{t-q} \quad (7)$$

حيث ان

$\theta_{1t}, \theta_{2t}, \dots, \theta_{qt}$ عبارة عن المعلمات غير المعلومة.

وان طريقة Steepest descent للامتلية يمكن ان تطبق على المعادلة كما يأتي:

$$a_t = X_t - \theta_{1t}a_{t-1} - \theta_{2t}a_{t-2} - \dots - \theta_{qt}a_{t-q} \quad (8)$$

او

$$a_t^2 = (X_t - \theta_{1t}a_{t-1} - \theta_{2t}a_{t-2} - \dots - \theta_{qt}a_{t-q})^2$$

بالاشتقاق بالنسبة الى كل من $\theta_{1t}, \theta_{2t}, \dots, \theta_{qt}$ نحصل على

$$\frac{\partial a_t^2}{\partial \theta_{ji}} = 2a_t a_{t-j}$$

وعليه فان موجه الميل gradient يمكن ان يقرب بواسطة

$$\nabla a^2 \cong 2a_t a_{t-j}$$

وباستخدام الاسلوب التكراري نحصل على المعادلة المكيفة الجديدة على وفق

الصيغة الاتية:

$$\theta_{jt}^* = \theta_{jt} + 2ka_t a_{t-j} \quad (9)$$

(محمود، 2005)

2-2 طريقة الشبكات العصبية الاصطناعية

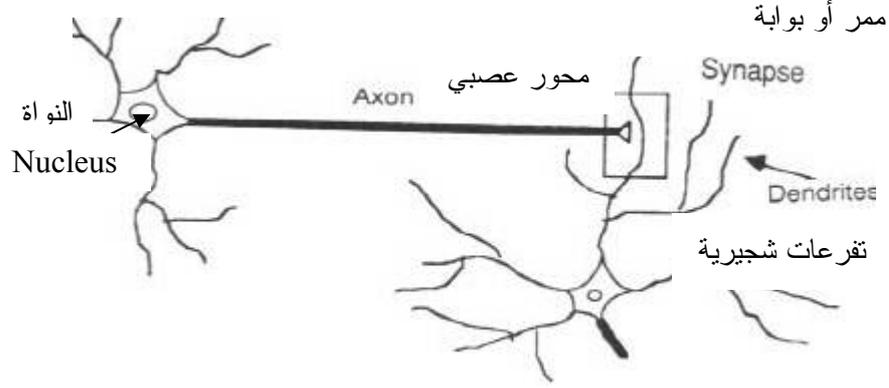
ان الخلية العصبية الاصطناعية صممت لتحاكي الخصائص الأساسية للخلية العصبية البيولوجية، اذ تمثل ترابطات الإدخال بخطوط تقابل التفرعات الشجرية والتي بدورها تمثل الإخراج لعصب اخر، فعندما تأتي الإشارة متمثلة بالمتجه \underline{X} (الإدخال) من ترابط معين تضرب برقم يسمى وزن الترابط (Weight of Connection) ومجموعة الأوزان تُمثل بالمتجه \underline{W} الذي يقابل اتساع الفرع الشجري البيولوجي، وتجمع الإشارات أو الإدخالات (Weighted Inputs) في صندوق الجمع الذي يقابل جسم الخلية العصبية لتحديد مستوى التأثير (الفاعلية) (Level activation) لها لتنتج إشارة الإخراج (Output) ممثلة للإدخال (Input) لخليا أخرى مرتبطة معها، وهكذا تجمع جميع الإدخالات الموزونة جبرياً لانتاج الإخراج المتحقق المسمى بمصطلح نيت (Net) محسوباً بالصيغة الاتية:

$$\text{Net} = \underline{XW}$$

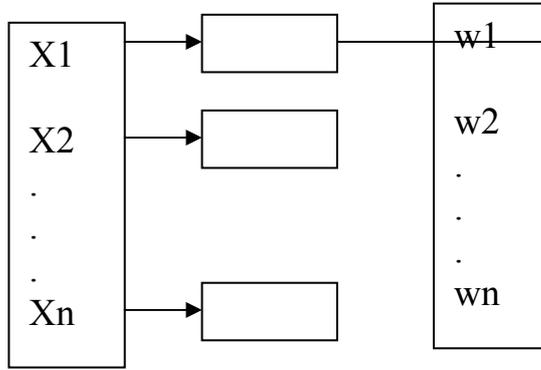
حيث أن:

\underline{X} : متجه الإدخال الذي يضم مجموعة الإدخال وهي X_1, X_2, \dots, X_n .

W : متجه الأوزان الذي يضم مجموعة الأوزان w_1, w_2, \dots, w_n .
 مُشكلةً بذلك العصب الاصطناعي (Artificial Neuron). والشكل (1) يوضح
 مكونات الخلية العصبية البيولوجية وما يناظرها في الخلية العصبية الاصطناعية.



مكونات الخلية العصبية البيولوجية.



مكونات الخلية العصبية الاصطناعية.

الشكل (1): مكونات الخلية العصبية البيولوجية وما يناظرها في الخلية العصبية الاصطناعية

إن الشبكة العصبية الاصطناعية هي عبارة عن نظام حاسوبي لمعالجة المعلومات، مكون من عدد كبير جداً من عناصر المعالجة (Processing Element) المترابطة فيما بينها ذوات طبيعة ديناميكية وظيفتها هي التقسيم المتوازي لحسابات الشبكة أو تتكون الشبكة العصبية من عدد من وحدات المعالجة المتداخلة والمتجانسة، كل وحدة بمفردها أداة حسابية يمكن نمذجة سلوكها، بمعادلات رياضية بسيطة.

ومعمارية (هيكلية- بنية) الشبكة العصبية الاصطناعية هي ترتيب العقد في المستويات أو الطبقات وشكل الترابط ضمن المستويات (الطبقات) أو بينها، فهي من أهم خصائص الشبكة العصبية التي توصف على أساسها الشبكة. تصنف الشبكات حسب عدد مستوياتها (طبقاتها) إلى صنفين رئيسين:

1- شبكات وحيدة المستوى أو الطبقة (Single-level or layer) وهي لا تمتلك مستوى (طبقة) مخفية.

2- شبكات متعددة المستويات (الطبقات) (Multi-level or layers) لها مستوى (طبقة) مخفي واحد أو أكثر وهي نوعان أيضاً شبكة أمامية التغذية (Feed Forward N.) وشبكة عكسية التغذية (Feed Backward N.).

وبشكل عام، فإن معمارية الشبكة العصبية الاصطناعية النموذجية مكونة من ثلاثة مستويات أو طبقات هي:

1- مستوى (طبقة) الإدخال (Input level (layer)) : هو المستوى الأول في الشبكة العصبية، يحوي على عدد من العقد التي تمثل عدد المتغيرات المستقلة (الإدخالات).

2- المستوى (طبقة) المخفي (Hidden Level) : وهو المستوى الأوسط الذي يقع بين المستوى الأول (الإدخال). والمستوى الأخير (الإخراج)، فهو يلي المستوى الأول.

3- مستوى (طبقة) الإخراج (Output Level) : وهو المستوى الأخير في الشبكة العصبية الاصطناعية الذي يمثل اخراجات الشبكة العصبية. ويتكون كل مستوى من المستويات الثلاثة أعلاه من:

- أ. العقد أو الخلايا (Nodes): تشكل نقاط الترابط العصبي بين مستويات (طبقات) الشبكة العصبية.
- ب. المستوى (Level): يمثل مجموعة العقد أو الخلايا التي تستلم الإدخال ولها إخراج.
- ج. الأوزان (Weights): تشير الأوزان إلى مدى قوة الارتباط العصبي بين مستويات (طبقات) الشبكة العصبية فكل عقدة (خلية) وزن يربطها مع المستوى السابق، ووزن يربطها مع المستوى اللاحق. إن القيم الأولية للأوزان (Initial Weights) في بداية تدريب الشبكة (Network Training) قيم عديدة عشوائية يتم توليدها من توزيعات إحصائية (الشيخلي، 2003).

وهناك طريقتان لتدريب الشبكات العصبية الاصطناعية هما

التعليم بواسطة معلم **Supervised Learning**:

في هذه الطريقة تحتاج الشبكات إلى مدرب ليعلم الشبكة بالمرجات المرغوب فيها Desired وتكون فئة التدريب عبارة عن زوجين من المتجهات، متجه المدخلات وهو عبارة عن القيم المدخلة للشبكة، ومتجه المخرجات وهو عبارة عن القيم التي يجب أن تخرجها الشبكة ومنها شبكة الانتشار العكسي للخطأ.

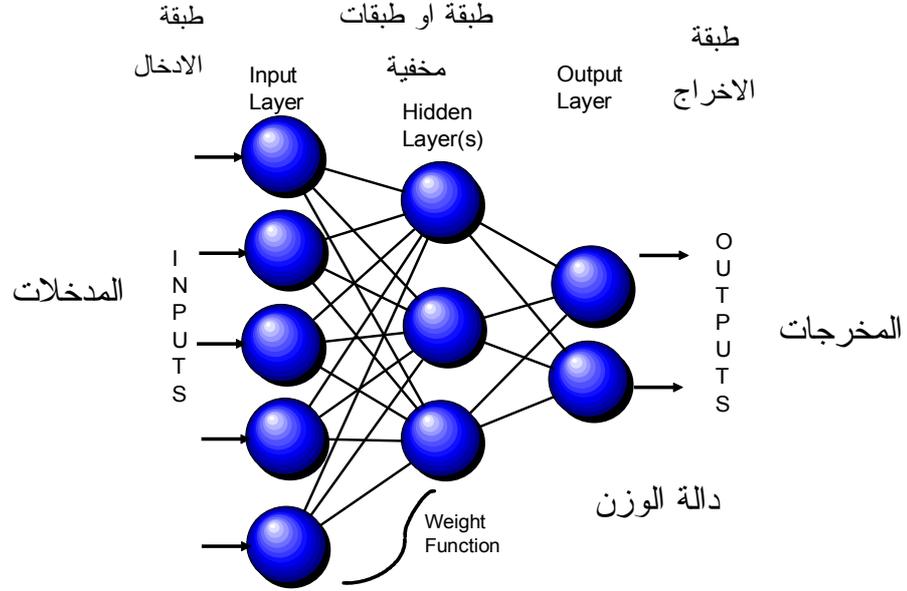
التعليم بدون معلم **Unsupervised learning**:

في هذه الطريقة تتكيف الشبكة بسهولة في الاستجابة للمدخلات، وتتعلم أن تختار الهيكلية من المدخلات فقط وتكون فئة التدريب عبارة عن متجه المدخلات فقط (Smith, 2003).

2-2-1 الشبكات العصبية ذات الانتشار العكسي

إن شبكات التغذية الخلفية أو العكسية يمكنها أن تمتلك إشارات تتحرك أو تنتقل في كلا الاتجاهين بواسطة دارات Metroducing في الشبكة، إن شبكات التغذية العكسية قوية جدا وهي معقدة جدا، وهي شبكات حركية تتغير استقراريتها باستمرار إلى حين الوصول إلى نقطة التوازن، وتبقى في نقطة التوازن إلى أن يتغير الإدخال وعندئذ تحتاج إلى إيجاد توازن جديد (Stergiou and Siganos, 2001). والشكل (2-6) يوضح شكل الشبكة العصبية ذات الانتشار العكسي. تستند الشبكة العصبية

ذات الانتشار العكسي للخطأ الى مفهوم تدريب الشبكة المعتمد على متوسط مربع الخطأ، وذلك بإيجاد القيمة الصغرى لمربع الخطأ الكلي لقيمة المخرجات المحسوبة من قبل الشبكة حيث تحدت الأوزان بين الطبقات لحين الوصول إلى الأوزان المثلى التي تحدث افضل توفيق للنموذج (البك، 2005).



الشكل (2-6): الشبكة العصبية ذات الانتشار العكسي.

إن شبكة الانتشار العكسي للخطأ تستخدم التعلم بإشراف Supervised learning وهذا يعني تزويد الشبكة بمثال الإدخال والإخراج المطلوب حسابه، ويحسب الخطأ (الفرق بين القيم الحقيقية والمتوقعة). وفكرة شبكة الانتشار العكسي هو تقليل الخطأ، إلى أن تتعلم الشبكة عن طريق التدريب، ويبدأ التدريب بأوزان عشوائية بهدف تكييف الشبكة إلى أن يصل الخطأ إلى اقل ما يمكن (Gershenson, 1998). والشكل (2) يبين خطوات تدريب الشبكة .

2-2-2 عوامل انجاز الشبكة العصبية الاصطناعية

ان جودة التنبؤات المستقبلية لظاهرة معينة التي يمكن الحصول عليها من الشبكة العصبية تعتمد على مدى كفاءة تدريب الشبكة العصبية ومن تلك العوامل (الشيخلي، 2003)

1- عامل معدل التعلم (Learning Rate (η))

يُعد معدل التعلم من العوامل المؤثرة في عملية تحديث الاوزان في الشبكة العصبية اذ ان معدل التعلم يحدد حجم الخطوة في عملية تعلم الشبكة العصبية ومقدار تغير الوزن.

2- عامل العزم (Momentum (α))

هو من العوامل المهمة الذي يجعل عملية التعلم متزنة ويجعل مقدار التغير في الوزن متزناً ومستقراً نسبياً.

3- عامل عدد المتجهات في الشبكة العصبية

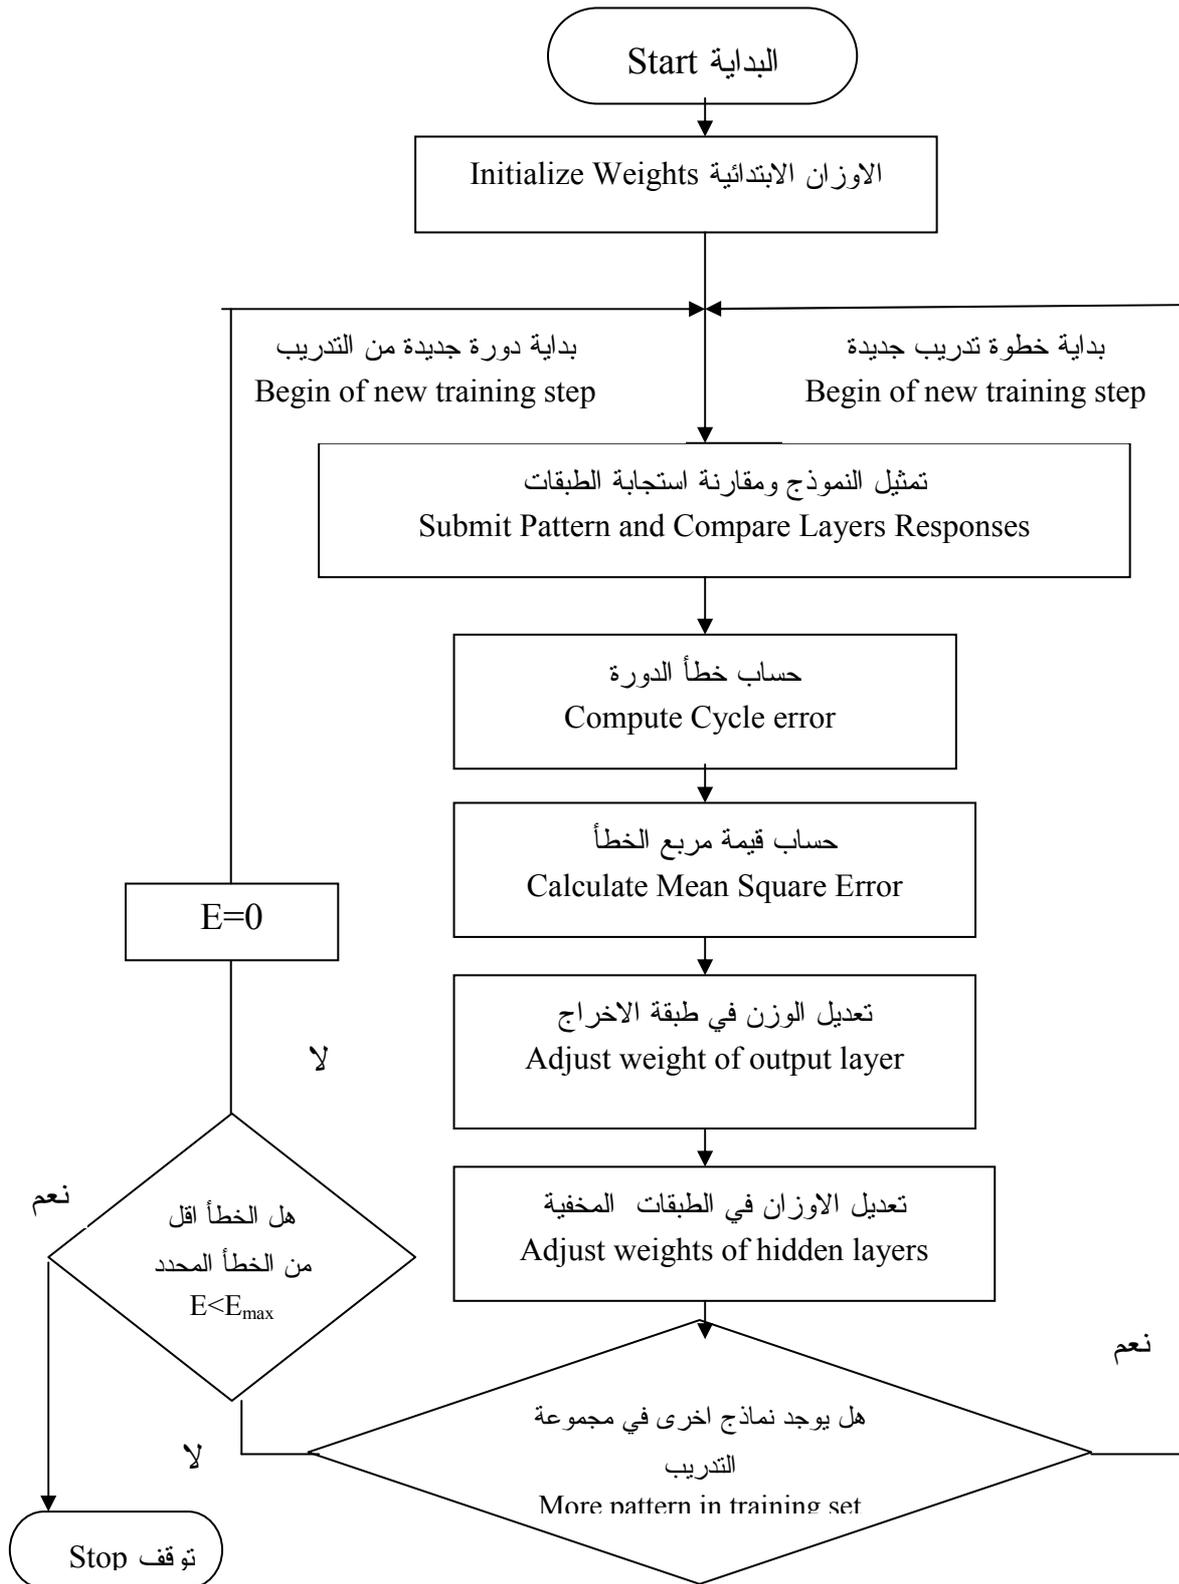
ان عدد المتجهات (Exemplars) يؤثر في اداء الشبكة بشكل مباشر، وذلك لانه يمثل المتغيرات المستقلة، فاذا كان عدد المتجهات مناسباً فان الشبكة العصبية بإمكانها استخلاص نموذج يمثل البيانات، اما اذا كانت مدخلات الشبكة على درجة من التعقيد فيجب زيادة عدد المتجهات لكي تتعلم الشبكة على سلوك البيانات.

4- عامل عدد العقد المخفية

ان افضل طريقة في تحديد عدد العقد المخفية للشبكة العصبية هي اختيار عدد قليل من العقد المخفية عند البدء بتدريب الشبكة العصبية ثم ملاحظة النتائج وبعدها تزداد العقد المخفية الى ان نصل الى اقل خطأ ممكن وافضل نتائج في معايير المقارنة.

5- عامل عدد المستويات المخفية

هو من العوامل المهمة في كفاءة تدريب الشبكة العصبية، حيث يبدأ تدريب الشبكة العصبية بمستوى مخفي واحد وتستمر عملية التدريب او التعلم على صفات بيانات الشبكة العصبية، الى الوصول الى اقل خطأ ممكن، وفي حالة عدم تعلم الشبكة العصبية على اغلب صفات البيانات تتم زيادة مستوى مخفي اخر الى الشبكة العصبية.



الشكل (2): خطوات تدريب شبكة الانتشار العكسي.

3- الجانب التطبيقي

تم اخذ البيانات من سجلات مستشفى حازم الحافظ في محافظة نينوى وتمثل السلسلة عدد المصابين بمرض سرطان الرئة وللأعوام 1980-2000.

والجدول (1) يبين اعداد المرضى

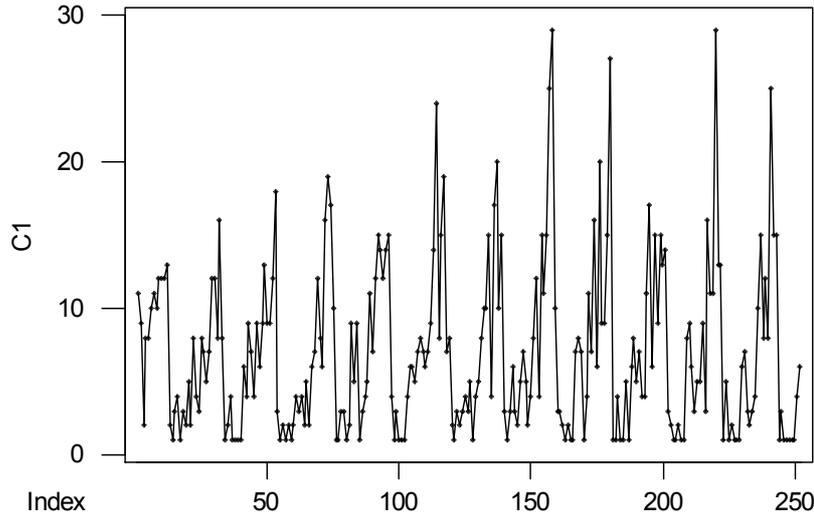
الجدول (1): اعداد المرضى المصابين بسرطان الرئة (Lung Cancer)

للأعوام 1980-2000

الاشهر												السنوات
كانون الاول	تشرين الثاني	تشرين الاول	أيلول	آب	نوفمبر	أكتوبر	سبتمبر	أغسطس	تموز	يونيو	كانون الثاني	
3	6	5	7	5	5	5	1	2	9	8	11	1980
2	3	7	1	2	1	7	3	5	7	4	9	81
3	5	4	4	4	4	8	4	2	4	3	2	82
4	5	4	11	8	5	7	5	6	9	8	8	83
10	9	11	7	12	8	6	11	7	6	7	8	84
15	3	17	16	4	10	7	7	12	9	5	10	85
8	16	6	6	15	10	9	12	8	13	7	11	86
12	11	15	20	11	15	14	15	6	9	12	10	87
8	11	9	9	15	4	24	14	16	9	12	12	88
25	29	15	9	25	17	8	12	19	12	8	12	89
15	13	13	15	29	20	15	14	17	18	16	12	90
15	13	14	27	10	10	19	15	10	3	8	13	91
1	1	3	1	3	15	7	4	1	1	1	2	92
3	5	2	1	3	3	8	1	1	2	2	1	93
1	1	1	4	2	1	2	3	3	1	4	3	94
1	2	1	1	1	3	1	1	3	2	1	4	95
1	1	2	1	2	6	3	1	1	1	1	1	96
1	1	1	5	1	3	2	1	2	2	1	3	97
1	1	1	1	1	2	3	4	9	4	1	2	98
4	6	8	6	7	5	4	6	5	3	6	5	99
6	7	9	8	8	7	3	6	9	4	4	2	2000

3-1 طريقة التنقية المكيفة

ان من اول الخطوات التي تتبع لوصف او تحليل سلسلة زمنية هو رسمها بما يعرف بالرسم الزمني لمعرفة الاتجاه العام للسلسلة واستقراريتها ويبين الشكل (3) السلسلة الزمنية



الشكل (3) : السلسلة الزمنية لاعداد المرضى المصابين بسرطان الرئة.

يتبين من الشكل ان السلسلة تتذبذب بشكل قطع مكافئ من الدرجة الثانية مما يدل على عدم استقرار السلسلة. وتم تقدير الاتجاه العام لهذه السلسلة بالاعتماد على معيار متوسط مربع الخطأ اذ تمت ملائمة النماذج وتبين ان نموذج الاتجاه العام التربيعي هو الافضل ويكون النموذج النهائي المقدر للاتجاه العام هو

$$Y_t = 5.87483 + 2.03e^{-2*t} - 7.02e^{-5*t^2}$$

ولتحويل السلسلة الزمنية الى سلسلة مستقرة تم اخذ الجذر التربيعي لبيانات السلسلة وكذلك اخذ الفروق وكانت على التوالي الفرق الاول والفرق الثاني عشر لمعرفة تأثير الموسمية والتي ثبت احصائياً عدم وجودها.

وبتطبيق المعادلات الواردة في الجانب النظري تم التوصل الى ان افضل نموذج هو النموذج $ARMA(0,1)$ وتم تقدير المعلمة θ_{1t}^* وبذلك يكون النموذج هو

$$Y_t = -2.9988a_{t-1} + a_t$$

والجدول (2) يبين قيم التنبؤ التي تم الحصول عليها

الجدول (2) : قيم التنبؤ بطريقة التنقية المكيفة.

3	3	1	5	4	11	7	4	1	6	7	12
9	9	11	3	8	7	6	11	3	1	1	8
7	0	8	14	2	8	7	1	12	8	5	10
6	5	4	0	5	9	9	10	5	12	6	11
9	13	6	12	4	15	9	12	5	8	11	10
7	10	2	4	14	2	10	13	15	8	9	12
24	19	13	4	24	2	5	12	11	12	8	12
4	5	11	15	27	2	5	14	17	17	15	12
13	8	14	25	10	10	16	15	10	1	4	13
1	1	3	2	7	11	6	4	2	27	3	2
23	30	19	25	11	2	1	15	17	10	37	30
8	20	1	4	2	22	2	15	3	3	1	2
10	21	4	15	1	9	16	9	7	2	3	6
1	3	2	16	3	4	2	10	1	3	16	1
1	3	3	5	3	2	8	1	9	2	1	14
1	1	3	22	3	2	2	4	5	0	1	8
4	6	8	16	7	3	3	11	16	2	6	4
11	22	3	20	26	0	2	4	6	3	25	5
7	3	6	4	7	4	4	5	2	1	8	1
1	4	2	5	1	1	1	7	4	1	1	13
	1	1	3	30	4	19	7	6	5	4	1

2-3 التنبؤ بطريقة الشبكات العصبية الاصطناعية

تم تصميم برنامج لغرض التنبؤ بأسلوب الشبكات العصبية حيث صممت شبكة عصبية ذات الانتشار العكسي للخطأ بطبقة مخفية واحدة واربع عقد (عصبونات) للطبقة وتم اختبار الشبكة اعتمادا على معدل التعلم (η) فقد تم اختبار معدل التعلم وضمن المدى المسموح به وهو ($0 < \eta < 0.9$) واختيار اقل متوسط مربع للخطأ، وتم تثبيت عدد التكرارات (100000) تكرار والجدول (3) يبين افضل معدل تعلم لتدريب الشبكة.

الجدول (3) اختبار معدل التعلم لاختيار افضل شبكة.

الادخال	عدد التكرارات	معدل التعلم (η)	متوسط مربعات الخطأ
252	100000	0.1	10.30175
		0.2	10.29172
		0.3	10.5240
		0.4	10.364
		0.5	10.2806
		0.6	10.3508
		0.7	10.9334
		0.8	10.9194
		0.9	10.9413

ومن خلال تدريب الشبكة العصبية تم التوصل الى قيم التنبؤ وحساب المعلمات الاحصائية لغرض المقارنة مع الطريقة السابقة والجدول (4) يبين قيم التنبؤ التي تم الحصول عليها.

الجدول (4): قيم التنبؤ باستخدام شبكة الانتشار العكسي للخطأ.

11	8	9	9	4	4	8	5	4	6	4	5
9	6	11	8	8	6	8	6	6	8	7	7
10	11	9	11	10	8	7	9	7	7	8	8
9	10	11	8	7	9	7	8	10	9	6	9
12	10	9	12	11	10	9	10	9	10	7	10
10	10	11	9	10	11	11	11	7	9	10	10
11	10	10	9	11	7	11	10	11	9	10	10
6	5	11	11	11	11	9	10	11	10	9	10
4	5	7	6	9	11	11	11	11	11	11	10
3	4	4	3	6	10	11	11	10	7	9	10
3	3	3	4	4	11	9	7	5	3	4	6
3	3	3	3	4	7	8	3	3	3	3	3
3	3	3	3	3	3	5	4	4	3	4	4
3	3	3	5	3	4	3	3	4	3	3	5
4	5	3	4	3	6	4	3	3	3	3	3
1	7	7	5	3	5	4	3	3	3	3	4
1	5	9	8	6	4	4	4	8	4	3	4
1	4	7	7	8	5	5	6	7	4	5	5
1	4	5	7	8	7	4	7	8	5	5	4
3	5	5	6	4	6	5	6	4	4	8	7
4	9	6	5	4	4	4	7	4	5	8	6

اعتمدت المعايير الاحصائية الاتية لغرض المقارنة بين طريقتي التنقية المكيفة والشبكات العصبية الاصطناعية
متوسط القيم المطلقة للاخطاء MAE
متوسط مربعات الخطأ MSE
متوسط القيم المطلقة لنسب الخطأ MAPE
ويبين الجدول (5) قيم المقارنة.

الجدول (5) يبين قيم المعايير الاحصائية

الطريقة المستخدمة	متوسط القيم المطلقة لنسب الخطأ	متوسط مربعات الخطأ	متوسط القيم المطلقة للاخطاء
التنقية المكيفة	154.114	47.118	5.328
الشبكات العصبية	48.0378	10.29172	2.5060

4- الاستنتاجات

- 1- ان طريقة الشبكات العصبية لها امكانية معالجة مختلف انواع البيانات الخطية واللاخطية تلقائيا من دون الحاجة الى نموذج مقترح.
- 2- تفوقت الشبكات العصبية على طريقة التنقية المكيفة في التنبؤ ولجميع المعايير الاحصائية المستخدمة.

5- المصادر

- البك، عزة حازم زكي، (2005). "استخدام الشبكات العصبية في التكهّن بالسلسلة الزمنية لاستهلاك الطاقة الكهربائية في محافظة نينوى". رسالة ماجستير غير منشورة، كلية علوم الحاسبات والرياضيات، جامعة الموصل.
- الشيخلي، ايفان علاء ناظم. (2003): "تصميم نظام رياضي ديناميكي لاخطي باستخدام الشبكات العصبية (NARMAX) لاغراض تحليلية وتنبؤية لنشاط المبيعات في شركة كهرباء بغداد"، رسالة ماجستير، كلية الادارة والاقتصاد، جامعة بغداد، العراق.
- محمود، اسيل سمير محمد، (2005). "مقارنة بين طرائق تحليل وتنبؤ السلاسل الزمنية وتطبيقها على مبيعات الشركة العامة لتوزيع كهرباء بغداد، اطروحة دكتوراه، كلية الادارة والاقتصاد، جامعة بغداد.

Al-Nassir, Abdul Majid Hammza, (2005). "Forecasting Performance of Adaptive Filtering and Box-Jenkins Techniques (An empirical investigation).

- Makridakis S. and Wheel Wright (1977). “Adaptive Filtering: An Integrated Autoregressive Moving Average Filter For Time Series Forecasting”, Oper Res. Quart., 28.
- Smith, Leslie., (1997): “An Introduction to Neural Networks”, UC2Press, [www.SC.Stir.ac.uk/~Lss/NNIntro./Invslides, html](http://www.SC.Stir.ac.uk/~Lss/NNIntro./Invslides.html)
- Stergiou, Christos, Siganos, Dimitries. ,(1996): “Neural Networks”, [www.dse.doc.ic.ac.uk/~nd/ Surprise Journal/ Vol4/ csll/report.html](http://www.dse.doc.ic.ac.uk/~nd/SurpriseJournal/Vol4/csll/report.html).
- Gershenson , Carlos. (1998). “Artificial Neural Networks for Beginners”, Sussex Academy, UK.