

## الشبكات العصبية: أنواعها وخوارزميات تدريبها ومجالات تطبيقها وبرمجياتها

Neural Networks: types, training algorithms, applications and Softwares

اسماعيل محمد محمود حساين\*\*

د/ رزق السيد حامد الوزير\*

## ملخص:

تضخمت أحجام البيانات التي تجمعها المنظمات وهي تزاوُل نشاطها اليومي نتيجة لتقدم تكنولوجيا الحاسبات. وازداد تعقد المشاكل المعاصرة بفعل زيادة عدد المتغيرات المؤثرة فيها وإمكانية التفاعل بين هذه المتغيرات. وأصبح من الصعب تصديق أن افتراض شكل دالي معين سوف يستطيع التعبير بكفاءة عن تلك المشاكل المعقدة. وقد ظهرت الشبكات العصبية حديثاً كأسلوب لاعملي لعلاج مثل هذا النوع من المشاكل في ظل اللاخطية العالية التي تربط بين المتغيرات وأحجام البيانات الكبيرة. ويهدف هذا البحث إلى التعريف بأسلوب الشبكات العصبية وأنواعها وخوارزميات تدريبها، كما يهدف إلى استعراض المجالات المختلفة التي استخدمت فيها الشبكات العصبية بنجاح وأشهر برامج تدريب الشبكة والتحقق من مصداقيتها.

وتكون الشبكات العصبية قابلة للتطبيق في المشاكل السببية حين توجد علاقة معقدة بين عدة متغيرات مستقلة (مفسرة/ متبينة/ مدخلات) وواحد أو أكثر من المتغيرات التابعة (مفسر/ متبناً به/ مخرجات)، ويصعب التعبير عن تلك العلاقة بالمدخل التقليدية كالارتباط والانحدار والاختلاف بين المجموعات. وقد طُبِّقَت الشبكات العصبية بنجاح<sup>[5][14][15][20][27]</sup> في مجالات التمويل، والتسويق، وإدارة الموارد البشرية، والتحليل التشغيلي، والطب، والصناعة، والطاقة.

الكلمات الدالة: الشبكات العصبية، خوارزميات التدريب، التطبيقات الحديثة للتنقيب في البيانات

## Summary:

The volumes of data collected by organizations with operations daily are inflated as a result of advances in computer technology. The complexity of contemporary problems by increasing the number of variables affecting it and the possibility of interaction between these variables increased. It became hard to believe that the presumption of a particular functional form will be able to efficiently expression of these complex problems. Neural networks have emerged recently as a nonparametric technique to treat this kind of nonlinear problems under high linking variables and large volumes of data. This research aims to introduce the style and types of neural networks and training algorithms, also aims to review the various areas in which neural networks were used successfully and the most famous training programs for the network and check the credibility.

The neural networks are applicable in the problems of causality when no complex relationship between several independent variables (interpreted / predictors / inputs) and one or more of the dependent variables (explained / response / output), and is difficult to express this relationship by traditional methods such as correlation, regression and differences between groups. Neural networks have been applied successfully<sup>[5][14][15][20][27]</sup> in the areas of finance, marketing, human resources management, operational analysis, medicine, industry, and energy.

**Keywords:** neural networks, training algorithms, modern applications for data mining

\*مدرس الإحصاء التطبيقي بكلية التجارة جامعة المنصورة، وأستاذ مساعد الإحصاء بكلية العلوم الإدارية والمالية جامعة الطائف.

\*\* طالب ماجستير - معهد الدراسات والبحوث الإحصائية - جامعة القاهرة.

## 1. مقدمة


## 1-1 تعريف الشبكة العصبية

تُستخدم الشبكات العصبية (NN) Neural Networks لتحقيق العديد من الأغراض الوصفية والتنبؤية عند التقريب في البيانات<sup>[12]</sup>. وقد نشأت NN في مجال تعليم الآلة Machine Learning في محاولة لتقليد الوظائف العصبية للمخ البشري من خلال توليفة من العناصر الحاسوبية البسيطة (الخلايا العصبية Neurons) في نظام متداخل للغاية. وتتمتع NN بأهمية خاصة<sup>[29]</sup> لأنها تقدم نمذجة عالية الكفاءة للمشاكل المعقدة (التي تحتوي على مئات المتغيرات المستقلة والعديد من التفاعلات ومتغير تابع أو أكثر) بطريقة لامعلمية من قواعد البيانات الكبيرة. كما يمكن استخدامها في حل مشاكل التصنيف ومشاكل الانحدار سواء كانت البيانات مكتملة أو مبتورة.

Censored

## 2-1 مكونات الشبكة العصبية

يوضح شكل (1) أن الشبكة العصبية تتكون من مجموعة من الوحدات الحاسوبية الأولية (تُعرف باسم الخلايا العصبية أو العُقد) متصلة بما يليها من خلال روابط مرجحة. وتمثل كل خلية بدائرة، وتأخذ رقماً طبيعياً (من 1: 10 في هذا المثال). كما تمثل الروابط بأسهم وتأخذ الرمز  $w_{ij}$ ، حيث يشير الدليل  $i$  إلى رقم العقدة التي ينطلق منها السهم ويشير الدليل  $j$  إلى رقم العقدة التي ينتهي عندها. وتُنظم هذه الوحدات في طبقات layers بحيث تتصل كل خلية (في طبقة ما) بجميع خلايا الطبقة السابقة واللاحقة. وتبدأ الشبكة بطبقة المدخلات input layer (من 1: 4 في هذا المثال) التي تناظر كل عقدة فيها أحد المتغيرات المستقلة. وتتصل كل عقدة في طبقة المدخلات بجميع عقد الطبقة الخفية (من 5: 9 في هذا المثال)، وربما تتصل عقد الطبقة الخفية بجميع عقد طبقة خفية أخرى (غير موضح على الرسم). وتنتهي الطبقات بطبقة المخرجات output layer (رقم 10 في هذا المثال) وهي عقدة (أو أكثر) تمثل المتغير التابع (أو المتغيرات التابعة) وهي التقاء للأسهم الخارجة من آخر طبقة خفية.



شكل (1): نموذج لشبكة عصبية بسيطة

يُحسب الوزن  $w_{ij}$  بمجموع حواصل ضرب الأوزان الداخلة على العقدة التي ينطلق منها في قيم العقد التي تنطلق منها تلك الأوزان. وكمثال، فإن قيمة الوزن الرابط بين الطبقة 7 والطبقة 10 هو:

$$w_{7,10} = w_{17} * \text{valueof node1} + w_{27} * \text{valueof node2} + w_{37} * \text{valueof node3} + w_{47} * \text{valueof node4}$$

ويمكن أن يُنظر إلى كل عقدة في هذا المثال على أنها متغير مستقل (العقد من 1: 4)، أو على أنها توليفة (تفاعل) من المتغيرات المستقلة (العقد من 5: 10). فالعقدة 10 هي توليفة غير خطية للقيم في العقد من 1: 4 بسبب وجود دالة التنشيط (القيم المجمعة في عقد الطبقة الخفية). وجدير بالذكر أنه إذا كانت دالة التنشيط خطية ولا توجد طبقة خفية، فإن الشبكة العصبية تُختزل إلى الانحدار الخطي. بينما تُختزل الشبكة العصبية إلى الانحدار اللوجستي في ظل دوال تنشيط غير خطية ذات شكل معين.

## 2. مشكلة البحث

تبلورت نظرية الشبكات العصبية في الثمانينات في مجال تعليم الآلة. ثم أصبحت أحد الفروع الأساسية لعلم التنقيب في البيانات الذي بدأ ظهوره في منتصف التسعينات، وهو الوقت الذي بدأ فيه أيضاً انتهاج أساليب الشبكات العصبية في التطبيقات المختلفة. إلا أن استخدامها في المنطقة العربية -سواء في البحوث أو بواسطة المنشآت- ما زال في أضيق الحدود. وقد يرجع ذلك إلى واحد أو أكثر من العوامل التالية:

- ضعف إلمام معظم الباحثين بمصطلحات وأساليب الشبكات العصبية.
  - اعتقاد البعض بأن الشبكات العصبية عملية شديدة التعقيد، وأن استخدامها في البحث لن يفيد في الخروج باستنتاجات عامة.
  - اعتماد الشبكات العصبية على عملية التنقيب في البيانات (وهما مجالين جديدين)، أدى إلى تفضيل معظم الباحثين للمداخل التقليدية في تحليل المشاكل.
- ويحاول هذا البحث التغلب على هذه الصعاب باستعراض أهم مصطلحات الشبكات العصبية، وأنواعها، وخوارزميات تقديرها، والمجالات المختلفة التي طُبقت فيها الشبكات العصبية بنجاح، وأشهر برامج تدريب الشبكة والتحقق من مصداقيتها.

## 3. هدف البحث

يهدف هذا البحث إلى التعريف بأسلوب الشبكات العصبية وأنواعها وخوارزميات تدريبها، كما يهدف إلى استعراض المجالات المختلفة التي استخدمت فيها الشبكات العصبية بنجاح وأشهر برامج تدريب الشبكة والتحقق من مصداقيتها ومقارنتها ببعض الأساليب التقليدية وأساليب التنقيب في البيانات.

## 4. الدراسات السابقة

يمكن النظر إلى دراسات الشبكات العصبية من ناحيتين:

## من الناحية النظرية:

تاريخياً، ظهرت الشبكة العصبية الأولى<sup>[5]</sup> في عام 1943 على يد عالم الأعصاب Warren McCulloch وعالم المنطق Walter Pitts كعمليات محاكاة أولية باستخدام المنطق الصوري على أساس فهمهما لعلم الأعصاب. وقدمت هذه النماذج عدة افتراضات حول كيفية عمل الخلايا العصبية، واستندت شبكاتها على الخلايا العصبية البسيطة كأجهزة ثنائية مع عتبات ثابتة. وكانت نتائج النموذج عبارة عن وظائف منطق بسيط مثل "a or b" و "a and b"، ولكن التقنية المتاحة في ذلك الوقت لم تسمح بتقديم ما هو أكثر من ذلك. وفي عام 1949 نشر Hebb كتاب The Organization of Behavior الذي قدم فيه قاعدة التعليم المعروفة باسمه. وكانت المساهمة الأكبر في عام 1958 حين قدم Rosenblatt<sup>[10]</sup> شبكات الطبقة الواحدة البسيطة المعروفة الآن باسم الفواهم Perceptrons في مقالة بعنوان "الفاهم: نموذج احتمالي لتخزين وتنظيم المعلومات في المخ". وفي عام 1969 قدم Minsky and Papert كتاباً عما فيه نموذج الطبقة الواحدة إلى أنظمة متعددة الطبقات، وحدث ركود في المجال ككل في فترة السبعينات.

وعادت الشبكات العصبية بقوة في الثمانينات عندما نشر Hopfield سلسلة من البحوث عن شبكات هوبفيلد في عام 1982، وعندما قدم Kohonen في نفس العام خرائط التنظيم الذاتي SOM التي تحمل الآن اسمه. وفي عام 1986 قدم Rumelhart, Hinton and Williams<sup>[25]</sup> طريقة الإكثار الخلفي Backpropagation؛ وهي أشهر الطرق المستخدمة حتى اليوم في تدريب الشبكة العصبية. وفي التسعينات<sup>[1]</sup>، انصب الاهتمام على الشبكات العصبية المبنية على دالة الأساس القطري Radial Basis Function Networks.

وقد تحول الاهتمام في السنوات الأخيرة إلى تحسين عملية التنبؤ بتعميم الشبكات العصبية (بعد تدريبها) على مجموعة البيانات الجديدة. فعلى سبيل المثال، فقد درس Rich Caruana, Steve Lawrence, C.<sup>[22]</sup> Lee Giles مشكلة التوفيق الزائد Over-Fitting في الشبكات العصبية الكبيرة المدربة بطريقة الإكثار الخلفي. كما درس Y. Liu, J. Starzyk, Z. Zhu<sup>[30]</sup> تجنب التوفيق الزائد في الشبكة العصبية بتحديد العدد الأمثل لخلايا طبقة الخفية. وقد استخدمت طريقتهم معيار كمي مبني على تقدير نسبة الإشارة إلى التذبذب Signal-To-Noise-Ratio Figure (SNRF) لاكتشاف التوفيق الزائد أوتوماتيكياً باستخدام خطأ التدريب فقط دون الحاجة لمجموعة التحقق من المصادقية أو مجموعة الاختبار.

## ومن الناحية التطبيقية:

فقد كان مجال المال والأعمال من أكثر المجالات استفادة من الشبكات العصبية، حيث درس I. Bose,<sup>[14]</sup> R. K. Mahapatra التنقيب في بيانات منشآت الأعمال من وجهة نظر تعليم الآلة Machine Learning بغرض تعريف مديري أنظمة المعلومات ومحلي المنشآت بالدور الذي يمكن أن تلعبه أساليب تعليم الآلة في التنقيب في بيانات منشآتهم. وأكدت الدراسة على أن فهم جوانب القوة والضعف لهذه الأساليب في سياق

منشآت الأعمال يفيد في اختيار الطريقة المناسبة لتطبيق بعينه. وأظهر المسح الذي أجرته الدراسة أن أشهر أساليب تعليم الآلة التي لاقت قبولاً تطبيقياً واسع الانتشار في منشآت الأعمال كانت استنتاج القاعدة rule Induction والشبكات العصبية والحالة المبنية على السببية case-Based Reasoning، وكان معظمها في مجالات التمويل. كما ألقى محرري مجلة [9] Decision Support Systems أيضاً الضوء على أهمية استخدام أساليب التنقيب في البيانات (ومن بينها الشبكات العصبية) في صنع القرارات المالية من خلا استعراضهم لعشرة بحوث أخرى في ذات التخصص. كما بحث David Enke, Suraphan [8] Thawornwong القوة التنبؤية للمتغيرات المالية والاقتصادية في التنبؤ بعوائد سوق الأسهم باستخدام الشبكات العصبية.

وفي مجال التسويق، قدمت دراسة [6] Chinho Lin, Chienwen Hong نظام معلومات تسويقي لدعم إدارة المبيعات في منشأة لتصنيع مشروب الشاي تقدم 56 منتجاً. ويمكن لهذا النظام أن يستخدم أساليب التنقيب في البيانات لتحديد المنتجات الترويجية الفعالة استناداً إلى السلوكيات الشرائية للعملاء. كما ناقشت دراسة [7] C. Rygielski, J. Wang, D. C. Yen أساليب وتطبيقات التنقيب في البيانات، وركزت على تطبيق أسلوب الشبكات العصبية و CHAID في مجال إدارة العلاقات بالمستهلك. كما استخدمت دراسة Shin-Yuan Hung et al [26] الشبكات العصبية للتنبؤ بتحول العملاء بين شركات المحمول في تايوان باستخدام الخصائص الديموجرافية للعملاء، ومعلومات الفواتير، والسجلات التفصيلية للمكالمات، وسجل تغيير الخدمة كمتغيرات مفسرة. وتبين من النتائج أن الشبكات العصبية قد قدمت نموذج تنبؤي دقيق لتحول العملاء.


وفي المجال الصناعي، نوهت دراسة [28] Stich et al إلى بعض الدراسات التي استخدمت الشبكات العصبية في الرقابة على العمليات الصناعية. وقارنت بين نموذج الانحدار الخطي المتعدد والشبكات العصبية في بناء نموذج الرقابة. وتبين تواضع نموذج الانحدار في مجابهة الشبكات العصبية بسبب لخطية العلاقة بين المتغير التابع والمتغيرات المستقلة والتفاعل المعقد بين المتغيرات. وتبين أن الشبكات العصبية تحسن جودة الإنتاج وتزيد إحكام السيطرة على العملية الصناعية. وأوصت الدراسة بتطبيق الشبكات العصبية في الرقابة الذاتية على العمليات الصناعية الأخرى.

وفي الطب، بحث [20] Peter Lucas الدور الحالي لطرق التنقيب في البيانات والتحليل البييزي وتحليل الأنماط في مجال الطب الحيوي والعناية بالصحة. وأوضح أن الأساليب الحديثة للتنقيب في البيانات عموماً – وتعليم الآلة خصوصاً – يمكن أن تُستغل في تحسين جودة العناية بالصحة، كما يمكن استخدامها أيضاً كأساس لبناء نظم دعم القرارات المبنية على الحاسب.

## 5. الإمكانية [12] Potential

تعتبر الأوزان في الشبكة العصبية (كما في النموذج البيولوجي) عن معاملات قابلة للتعديل استجابة للإشارات التي تسافر في الشبكة بحسب خوارزمية تعلم مناسبة وقيمة فاصلة Threshold (تُعرف أيضاً باسم

التحيز (Bias) تشبه حد التقاطع في نموذج الانحدار. فالخلية  $j$  تأخذ القيمة الفاصلة  $\theta_j$  وتستلم إشارات داخلية  $x = [x_1, \dots, x_n]$  من الوحدات (الخلايا/العقد) المتصلة بها من الطبقة السابقة. وتفتقر كل إشارة بوزن معين  $w_j = [w_{1j}, \dots, w_{nj}]$ . وتتم دراسة الإشارات الداخلة وأوزانها والقيمة الفاصلة لكل خلية من خلال ما يسمى بدالة التوليف Combination Function. وتنتج دالة التوليف (لكل خلية) قيمة واحدة تسمى الإمكانية (أو الداخل الصافي Net Input). وتقوم دالة التنشيط Activation Function (أو دالة التحويل) بتحويل تلك الإمكانية إلى إشارة خارجة. ويوضح شكل (2) تلك العلاقة باختصار.



شكل (2): تمثيل تنشيط خلية في الشبكة العصبية

وتكون دالة التوليف عادةً خطية، لذلك فإن الإمكانية  $p_j$  تعبر عن مجموع انحرافات قيم الخلايا السابقة  $x_i$  المرجحة بالأوزان الخارجة منها  $w_{ij}$  عن القيمة الفاصلة  $\theta_j$ ، وهو ما يُعبر عنه رمزياً كالتالي:

$$p_j = \sum_{i=1}^n (x_i w_{ij} - \theta_j) = \sum_{i=0}^n x_i w_{ij}$$

حيث  $w_{0j} = -\theta_j$ ،  $x_0 = 1$ . ويمكن الحصول على الإشارة الخارجة للخلية  $j$  (أي  $y_j$ ) بتطبيق دالة التنشيط على الإمكانية  $p_j$  لتعطي:

$$y_j = f(\mathbf{x}, \mathbf{w}_j) = f(p_j) = f\left(\sum_{i=0}^n x_i w_{ij}\right)$$

## 6. أنواع دالة التنشيط [12][13][23][24]

هناك طرق كثيرة لتنشيط الخلايا في الشبكة العصبية. ومن أشهرها: الطريقة الخطية، والطريقة المجزأة piecewise، والطريقة الإسية Sigmoidal، وطريقة أقصى تمهيد Softmax:

6-1 دالة التنشيط الخطية: تُعرّف دالة التنشيط الخطية بالصيغة التالية:

$$f(p_j) = \alpha + \beta p_j$$

حيث تنتمي الإمكانية  $p_j$  لمجموعة الأعداد الحقيقية، و  $\alpha, \beta$  ثابت. وعندما يتطلب النموذج أن يكون مخرج الخلية مساو تماماً لمستوى تنشيطها (الإمكانية)، نضع  $\alpha = 0, \beta = 1$  وتتحول الدالة الخطية إلى ما يسمى بدالة الوحدة. يُلاحظ التشابه القوي بين دالة التنشيط الخطية ونموذج الانحدار الخطي البسيط، إذ يمكن النظر للأخير على أنه نوع بسيط من الشبكات العصبية.

2-6 دالة التنشيط المجزأة: تُعرّف دالة التنشيط الخطية بالصيغة التالية:

$$f(p_j) = \begin{cases} \alpha & p_j \geq \theta_j \\ \beta & p_j < \theta_j \end{cases}$$

ويتضح أن تأخذ قيمتين فقط بحسب تجاوز الإمكانية للقيمة الفاصلة من عدمه. وعندما تكون  $\alpha = 1, \beta = 0, \theta_j = 0$ ، نكون أمام حالة خاصة من التنشيط المجزأ تُعرف باسم دالة تنشيط الإشارة Sign Activation Function التي تأخذ القيمة 1 إذا كانت الإمكانية موجبة والقيمة 0 بخلاف ذلك.

3-6 دالة التنشيط الإسسية: أي التي تأخذ شكل حرف s، وهي الأكثر استخداماً في التطبيقات العملية. وتُنتج هذه الدالة قيمة موجبة فقط في الفترة  $[0, 1]$ . ويرجع شيوع استخدامها إلى أنها غير خطية وإلى قابليتها للفهم وللتفاضل بسهولة. وتُعرّف بالصيغة التالية:

$$f(p_j) = \frac{1}{1 + e^{-\alpha p_j}}$$

حيث تشير  $\alpha$  إلى معلمة موجبة تنظم ميل الدالة.

4-6 دالة أقصى تمهيد: تُستخدم في تطبيع Normalize مخرجات العقد المختلفة التي يوجد بينها علاقة. فإذا كانت الشبكة تحتوي على  $g$  من العقد بمخرجات عددها  $V_j$  (حيث  $j = 1, 2, \dots, g$ )، فإن دالة أقصى تمهيد التي تُطَبِّع  $V_j$  (تجعل مجموعها 1) تكون:

$$\text{soft max}(v_j) = \frac{e^{v_j}}{\sum_{j=1}^g e^{v_n}}$$

وتُستخدم هذه الدالة في حل مشاكل التصنيف المراقب Supervised Classification Problems عندما يأخذ المتغير التابع عدد  $g$  من المستويات.

## 7. طرق التدريب [2][24] Training Methods

يُقصد بالتدريب (بمفاهيم الشبكات العصبية) تعليم الشبكة كيف تنجز مهمة ما، وهو بلغة الإحصائيين الطريقة المستخدمة في تقدير أوزان الشبكة (المعالم المجهولة). ويمكن تدريب أو تعليم الشبكة بعدة طرق من أشهرها وأوسعها انتشاراً؛ طريقة الإكثار الخلفي Backpropagation التي تبحث في تحديث أوزان الشبكة بتصغير دالة الخطأ في فضاء الأوزان باستخدام عدة خوارزميات، من أشهرها:



7-1 خوارزمية الهبوط المتدرج: يأخذ الهبوط المتدرج Gradient Descent الصيغة العامة التالية<sup>[4]</sup>:

$$\Delta w_{ji} = \alpha (t_j - y_j) g'(h_j) x_i,$$

حيث تشير  $\alpha$  إلى ثابت صغير يُعرف باسم معدل التعليم،  $g(x)$  إلى دالة تنشيط الخلية،  $t_j$  إلى القيمة المرغوبة للمخرج،  $h_j$  إلى المجموع المرجح لمدخلات الخلية ( $h_j = \sum x_i w_{ji}$ )،  $y_j$  إلى القيمة الفعلية للمخرج ( $y_j = g(h_j)$ ).

ويكون حل مشكلة التعليم هو توليفة الأوزان التي تُصغّر دالة الخطأ. وتفصيل ذلك كالتالي:

- يُقاس الخطأ لكل فاهم Perceptron (أي كل خلية تتصل بـ  $j$  من المخرجات) بالصيغة:

$$E = \sum_j \frac{1}{2} (t_j - y_j)^2$$

- يتم جمع الأخطاء (لكل الفواهم) للحصول على خطأ الدالة (الخطأ الإجمالي).

- يتم حساب الميل المتدرج بمفاضلة الخطأ الكلي جزئياً بالنسبة لـ  $\ell$  من الأوزان كالتالي:

$$\nabla E = \left( \frac{\partial E}{\partial w_1}, \dots, \frac{\partial E}{\partial w_\ell} \right)$$

- يتم تحديث كل وزن باستخدام مقدار الزيادة Increment التالي:

$$\Delta w_i = -\alpha \frac{\partial E}{\partial w_i}, \quad i = 1, \dots, \ell$$

- نكرر هذه العملية حتى نصل إلى أدنى قيمة لدالة الخطأ، وهي القيمة التي يثبت فيها التغير (أي إلى أن يصبح  $\nabla E = 0$ ). وعندئذٍ، يُقال أن الشبكة قد تم تدريبها (أي تم حل مشكلة التعليم والتوصل للتقديرات النهائية لمعالم الشبكة).

وتُجرى هذه الدورة عدة مرات، ويُطلق على الدورة الواحدة اسم دور Epoch.

7-2 خوارزمية التدرج المقارن<sup>[17][3]</sup>: هي خوارزمية حل عددي لنوع خاص من أنظمة المعادلات الخطية تكون فيه المصفوفة متماثلة ومحددة-موجبة Symmetric and Positive-Definite. وقد استُخدمت الطريقة فيما بعد في الشبكات العصبية لحل مشاكل الأمثلية غير المقيدة.

إذ تتقارب طريقة الإكثار الخلفي (التي تستخدم أسلوب الهبوط المتدرج) ببطء. ويعتمد نجاحها في الشبكات الكبيرة على تحديد معدل التعليم ومعالم قوة الدفع Momentum بواسطة المستخدم. فإذا اختيرت تلك القيم بطريقة غير صحيحة، فإن التقارب قد يكون بطيئاً للغاية أو ربما لا تتقارب الشبكة من أصله. وبالمقارنة بطريقة الهبوط المتدرج، فإن طريقة التدرج المقارن تُجري عملية الأمثلية بسرعة وقوة Robust أكبر. كما أنها لا تتطلب من المستخدم التحديد المسبق لقيم معدل التعليم ومعالم قوة الدفع. لذلك فإن معظم البرامج التي تتضمن الشبكات العصبية تعتمد على هذه الخوارزمية في تدريب الشبكة بطريقة الإكثار الخلفي.



3-7 خوارزميات أخرى: وهناك طرق أخرى لإيجاد النهايات العظمى والصغرى الموضوعية (إجراء عملية الأمثلية) تعتمد على حساب المشتقات الأولى (التدرج Gradient) وتقريب المشتقات الثانية (المصفوفة الهيسية Hessian) دون الحاجة لحسابها. ومنها: خوارزمية [21] Quasi-Newton، وخوارزمية Levenberg-Marquardt<sup>[19]</sup>، والخوارزميات الجينية<sup>[11]</sup> Genetic Algorithms.

### 8. أنواع الشبكات العصبية<sup>[13][24]</sup>

تتحكم 3 معايير في بناء (معمارية/طوبوغرافية) الشبكة، يتقرر بناءً عليها نوع الشبكة. وهذه العوامل هي: عدد الطبقات، واتجاه تدفق المعلومات، والأوزان.

### 8-1 تصنيف الشبكات العصبية بحسب عدد طبقاتها

- شبكة الفواهم ذوي الطبقة الواحدة **Single-Layer Perceptrons**: وفيها تحتوي الشبكة على طبقة مدخلات عددها  $n$  من العقد  $(x_1, \dots, x_n)$  متصلة بطبقة مخرجات عددها  $p$  من العقد  $(y_1, \dots, y_p)$  من خلال الأوزان  $w_{ij}$  التي تربط الخلية رقم  $i$  في طبقة المدخلات بالخلية رقم  $j$  في طبقة المخرجات، حيث  $(i = 1, \dots, n), (j = 1, \dots, p)$ . ومن أمثلة هذا النوع الشبكة التي تستخدم دوال القاعدة القطرية radial basis functions (RBF) كدالة تنشيط في إجراء عملية التقريب.

- شبكة الفواهم متعددة الطبقات **Multi-Layer Perceptrons**: وفيها تحتوي الشبكة على طبقة خفية (أو أكثر) بها  $h$  خلية وتعمل كوسيط بين طبقة المدخلات وطبقة المخرجات. وتعبّر  $w_{ik}$  (حيث  $i = 1, \dots, n; k = 1, \dots, h$ ) عن الأوزان التي تربط بين عقد طبقة المدخلات وعقد الطبقة الخفية، بينما تعبر  $z_{kj}$  (حيث  $k = 1, \dots, h; j = 1, \dots, p$ ) عن الأوزان التي تربط بين عقد طبقة الخفية وعقد طبقة المخرجات. وتستلم خلايا الطبقة الخفية المعلومات من طبقة المدخلات وترجحها بالأوزان  $w_{ik}$  لتنتج مخرجات على الشكل  $h_k = f(x, w_k)$ ، حيث تشير  $f$  إلى دالة تنشيط الوحدات في الطبقة الخفية. كما تستلم خلايا طبقة

المخرجات النواتج من الطبقة الخفية وترجحها بالأوزان  $z_{kj}$  لتنتج المخرجات النهائية على الشكل:

$$y_j = g(\mathbf{h}_j \cdot \mathbf{z}_j) = g\left(\sum_k h_k z_{kj}\right) = g\left[\sum_k z_{kj} f\left(\sum_i x_i w_{ik}\right)\right]$$

وتوضح المعادلة أن قيم مخرجات الشبكة العصبية تُحدد بطريقة مرتدة للخلف.

### 8-2 تصنيف الشبكات العصبية بحسب اتجاه تدفق المعلومات

- شبكات التغذية الأمامية **Feedforward Networks**: وتتحرك فيها المعلومات من طبقة إلى الطبقة التالية للأمام فقط دون السماح لها بالعودة للخلف.
- شبكات التغذية الخلفية **Feedback Networks**: وتتحرك فيها المعلومات من طبقة إلى الطبقة التالية للأمام مع السماح لها بالعودة للخلف إلى الطبقات السابقة.

## 8-3 تصنيف الشبكات العصبية بحسب أوزان روابطها

- الشبكات ذات الأوزان الثابتة **Networks With Fixed Weights**: وهي التي تفترض ثبات الأوزان من طبقة إلى أخرى، لذلك فهي لا تعلمنا شيء عن البيانات ولا تقدم نموذج إحصائي.
- الشبكات المُشرف عليها **Supervised Networks**: وهي التي يوجد فيها متغير تابع يتصرف كمشرف على المشكلة. حيث يمكن استخدام قيمه (المناظرة لقيم المتغيرات المستقلة) لمعرفة أوزان الشبكة. ومن أمثلة هذا النوع شبكة الفواهم متعددة الطبقات **Multi-Layer Perceptrons Network (MPN)**.
- الشبكات غير المُشرف عليها **Unsupervised Networks**: وهي التي لا يوجد فيها متغير تابع، وبالتالي فإن معرفة الأوزان يُبنى كليةً على المتغيرات المفسرة لعدم وجود متغير مشرف. وتُعد الشبكة الكوهينية **Kohonen Networks** - والتي يُطلق عليها أحياناً اسم خرائط التنظيم الذاتية **Self-Organizing Maps (SOMs)** - من أمثلة هذا النوع.

9. متطلبات عملية التدريب<sup>[16][24]</sup>

يجب مراعاة 5 اعتبارات عند تدريب الشبكة العصبية (تقدير أوزانها):

- اختيار عدد الطبقات الخفية: إذ تشير معظم بحوث الشبكات العصبية إلى أن الشبكة التي تحتوي على طبقة خفية واحدة تكفي لتمثيل البيانات، وأن استخدام طبقتين خفيتين نادراً ما يحسن النموذج بل ربما يزيد المشكلة تعقيداً. كما أنه لا يوجد سبب نظري لاستخدام أكثر من طبقتين خفيتين. وتتصح غالبية البحوث باستخدام شبكة من 3 طبقات: طبقة مدخلات، وطبقة خفية، وطبقة مخرجات.
- تحديد عدد خلايا الطبقة الخفية: وهي من أهم خصائص الشبكة العصبية. فإذا كان عدد الخلايا غير مناسب، فإن الشبكة ستصبح غير قادرة على نمذجة البيانات كما ستكون نتائج التوفيق ضعيفة. وتتميز بعض البرامج (مثل DTREG) بتقدير عدد الخلايا الأمثل في الطبقة الخفية بعد تحديد المستخدم للمدى المتوقع لهذا العدد. ويقوم البرنامج بتقدير العديد من النماذج (نموذج لكل عدد) واختبار مصداقيتها لتحديد عدد الخلايا الأمثل. ويُجرى البرنامج هذا البحث عن عدد الخلايا الأمثل ذاتياً بالنسبة للطبقة الخفية الأولى فقط. فإذا قرر الباحث إضافة طبقة خفية ثانية للشبكة، فعليه أن يحدد عدد الخلايا في الطبقة الثانية.
- إيجاد الحل المثالي العام: تحتوي الشبكة العصبية النموذجية على حوالي 100 وزن، يجب تقدير قيمها لتحديد الحل المثالي. فإذا كانت الشبكة خطية، فيكون من السهل التوصل للحل المثالي. ولكن مخرجات الشبكة العصبية (كدالة في المدخلات) غالباً ما تكون غير خطية (بدرجة عالية)، وهذا يجعل عملية الأمثلية أكثر تعقيداً. وتحاول الطرق الحديثة تجنب النهايات الصغرى الموضعية في التوصل إلى الحل العام باختيار قيم مبدئية للأوزان ثم تطبيق خوارزمية التدرج المقارن (وهو النمط المستخدم في برنامج DTREG). ويتم بهذا الأسلوب التوصل للأوزان المثلى بسرعة، غير أن ذلك لا يضمن التوصل إلى

- الحل العام الأمثل. ويمكن التغلب على هذه المشكلة بإجراء عملية الأمثلية عدة مرات في ظل مجموعات مختلفة من القيم العشوائية للأوزان المبدئية (وهو خيار متاح في برنامج DTREG).
- تقارب الحل الأمثل في وقت معقول: بتطبيق الأدوار (الخطوات الخمس) المبينة في خوارزمية الهبوط المتدرج.
  - التحقق من مصداقية الشبكة باختبار التوفيق الفوقي: فمن المعروف في الشبكات العصبية أن البيانات الكلية تُقسّم إلى 3 مجموعات: مجموعة التدريب (وهي البيانات المستخدمة في ضبط أوزان الشبكة)، ومجموعة التحقق من المصداقية (وهي البيانات المستخدمة في تصغير التوفيق الفوقي)، ومجموعة الاختبار (وهي البيانات المستخدمة في اختبار الحل النهائي لتأكيد القوة التنبؤية للشبكة). وفي هذه الخطوة يجب التحقق من أن أي زيادة في الدقة من خلال مجموعة بيانات التدريب سوف تنتج زيادة في الدقة لمجموعة البيانات الجديدة التي لم تستخدمها الشبكة من قبل. فإذا تحسنت الدقة من خلال مجموعة بيانات التدريب دون تحسن الدقة في مجموعة بيانات التحقق من المصداقية (نقصانها أو بقائها على ما هي عليه)، يجب وقف عملية التدريب حتى لا تتعرض الشبكة لمشكلة التوفيق الفوقي.

### 10. تطبيقات الشبكات العصبية

تكون الشبكات العصبية قابلة للتطبيق في المشاكل السببية حين توجد علاقة معقدة بين عدة متغيرات مستقلة (مفسرة/ مَنبئة/ مدخلات) وواحد أو أكثر من المتغيرات التابعة (مُفسر/ متنبأ به/ مخرجات)، ويصعب التعبير عن تلك العلاقة بالمداخل التقليدية كالارتباط والانحدار والاختلاف بين المجموعات. وفيما يلي بعض الأمثلة على المشاكل التي طُبِّقت فيها الشبكات العصبية بنجاح [20][27][15][14][5].

#### 1-10 في التمويل

- التنبؤ بسوق الأسهم: تُعد التقلبات الكبيرة في أسعار الأسهم ومؤشرات السوق مثلاً آخر للمشاكل المعقدة. لذا، فقد استخدم معظم المحللون الفنيون (في السنوات الأخيرة) الشبكات العصبية للتنبؤ بأسعار الأسهم استناداً إلى عدد كبير من العوامل مثل الأداء الماضي لبعض الأسهم (أسعار الافتتاح والإقفال وأقل وأعلى سعر)، والمؤشرات الفنية، ومؤشرات السوق، وأسعار الأدوات الأخرى، والمؤشرات الاقتصادية المختلفة.
- تقييم الائتمان: إذ يجب أن يتوفر للمؤسسات المصرفية معلومات متنوعة عن طالبي القروض (سواء كانوا أفراد أم شركات) تستخدمها كمدخلات للشبكة العصبية (أو أي نموذج آخر) في تقرير منح القرض من عدمه. ومن أمثلة هذه المتغيرات في حالة الأفراد: عمر طالب القرض، ومستوى تعليمه، ومهنته، وحجم القرض. ومن أمثلة هذه المتغيرات في حالة الشركات: القائمة المالية الحالية، والأداء المالي عن الأعوام السابقة. ويتم ذلك بتدريب الشبكة العصبية (توفيق النموذج) من البيانات التاريخية، ثم استخدامها في تمييز الخصائص الهامة وتصنيف طالب القرض الجديد في فئتين: خطر جيد، وخطر سيء.

## المجلد 46 - العدد يونية 2013

• التنبؤ بالإفلاس: بتصنيف الشركات إلى: مُحتمل إفلاسها، وغير مُحتمل إفلاسها. وتحتاج الشبكة لعمل هذا النوع من التحليل للمدخلات التالية: خصائص الشركة، ونسب الأعمال مثل نسبة رأس المال العامل إلى إجمالي الأصول.

• تقييم الممتلكات: تقييم العقارات والسيارات والآلات وغيرها من الأصول. وتحتاج الشبكة لعمل هذا النوع من التحليل للمدخلات التالية: معالم الملكية، والظروف البيئية والديموجرافية والصناعية.

• الكشف عن الغش: كالتهرب الضريبي، ومطالبات التأمين الاحتياطية، والسطو على الحسابات المختلفة.

## 10-2 في التسويق

• التنبؤ بالمبيعات: التنبؤ بالمبيعات المستقبلية استناداً إلى أنشطة التسويق والمبيعات السابقة. ويلزم لتطبيق الشبكات على هذا النوع من التحليل توافر بيانات تاريخية حول ميزانية التسويق، وعدد ووقت الإعلانات، والعروض الخاصة، وغيرها من العوامل التي تؤثر على المبيعات.

• التسويق المستهدف: خفض التكاليف بتوجيه حملة تسويقية خاصة للعملاء ذوي أعلى معدل استجابة. ويحتاج هذا النوع من التحليل لبيانات عن العملاء ومعدل الاستجابة.

• توقع هوامش الربح في البيع بالتجزئة: توقع سلوك الهوامش في المستقبل لتحديد الآثار المترتبة على التغيرات في الأسعار في أحد المستويات على العوائد في المستويات الأخرى. ويتطلب هذا النوع من التحليل بيانات عن: أسعار البيع بالتجزئة، والنفقات عند كل مستوى للبيع بالتجزئة، وتكاليف التسويق، وقيم الهوامش الماضية، وتقلب الأسعار، وخصائص الأسواق الأخرى.

## 10-3 في إدارة الموارد البشرية

• التوظيف: التنبؤ بأن المتقدم للوظيفة سيؤدي وظيفته بأفضل أداء ممكن. وتحديد الموظفين الذين ينوون البقاء في المنظمة لفترة طويلة. ويتطلب هذا النوع من التحليل معلومات عن: المستويات التعليمية، والدورات، والوظائف السابقة، ومستوى الأداء السابق.

• جدولة الموظفين: مثل التنبؤ باحتياجات مراكز الخدمات المختلفة (مطاعم، متاجر، أقسام شرطة، بنوك،..) من الموظفين في أوقات العمل المختلفة بهدف جدولة عدد كاف من الموظفين للتعامل مع عبء العمل. ويتطلب هذا النوع من التحليل توافر بيانات عن: الأجازات، وأوقات الذروة، والطقس، وعوامل أخرى.

• الجوانب الشخصية: اختيار الموظفين المناسبين لإنجاز مهمة معينة أو الذين يُتوقع أن يجتازوا برنامج تدريبي ما بنجاح.

## 10-4 التحليل التشغيلي

• إدارة المخازن: التنبؤ بمستوى المخزون الأمثل الذي يمكن أن يلبي احتياجات العملاء، والتنبؤ بالطلب في ضوء الطلبات السابقة.

- التنبؤ بالتدفقات النقدية: بتعظيم الاستفادة من الموارد عن طريق التوقعات الدقيقة للتدفقات النقدية. ويتطلب هذا النوع من التحليل بيانات عن: الميزانية، والمبيعات، والحسابات المستحقة القابلة للتحويل، والنفقات الرأسمالية، والموسم، وبيانات التشغيل.

### 10-5 في الصناعة

- مراقبة حالة الآلات: إذ أمكن للشبكات العصبية أن تكون مفيدة في خفض التكاليف بإدخال خبرات إضافية على جدولة الصيانة الوقائية للآلات. ويتم ذلك بتدريب الشبكة العصبية للتمييز بين صوت الآلة عندما تعمل بشكل عادي مقابل صوتها عندما تكون على وشك مشكلة (قبل العطل). وبعد تلك الفترة التدريبية، يمكن استخدام خبرة الشبكة لتحذير الفنيين من الأعطال القادمة قبل حدوثها وتسببها في تحمل تكاليف كبيرة.

- إدارة المحركات: استخدمت الشبكة العصبية أيضاً لتحليل إدخال الحساسات Sensors على المحركات الجديدة بهدف تقليل استهلاك الوقود.

### 10-6 في الصحة والسكان:

تحتل الشبكات العصبية الآن مساحة ساخنة في كافة التخصصات الطبية، حيث تعمل البحوث على نمذجة أعضاء الجسم البشري بغرض تشخيص الأمراض. وتعد الشبكات العصبية وسيلة نموذجية للتعرف على الأمراض باستخدام المسوحات المختلفة Scans دون الحاجة لأساليب التشخيص التقليدية، فكل ما تحتاجه هو مجموعة أمثلة (حالات) ممثلة لكافة أشكال المرض. ولما كان ظهور مرض معين يعتمد على مجموعة من المتغيرات الخاضعة للملاحظة (وتفاعلاتها الممكنة) من خلال علاقة غير خطية معقدة جداً، فقد أمكن استخدام الشبكات العصبية للتعرف على الأنماط التنبؤية لهذه الحالات وبالتالي وصف العلاج المناسب لها. ويتم عمل ذلك بناء نموذج للمريض ومقارنته بالقياسات الطبيعية. ويُمكن ذلك الروتين من اكتشاف الحالات المرضية المحتملة مبكراً، وهو ما يجعل عملية مكافحة المرض أسهل بكثير. ويُعد مدخلا الأنوف الالكترونية Electronic Noses والطبيب الفوري Instant Physician أيضاً من أحدث الأمثلة على تطبيقات الشبكات العصبية في الطب، وفي مجال دراسة السكان ونماذج الخصوبة والوفيات والوبائيات والبيئة.

### 10-7 في الطاقة

التنبؤ بالأحمال الكهربائية، والطلب على الطاقة، وأسعار مؤشر الغاز/الفحم، وتشغيل أنظمة التحكم في الطاقة.

### 11. برمجيات الشبكات العصبية

لا تخلو معظم حزم برامج التحليل الإحصائي (مثل SAS, SPSS, MINITAB) وجميع برامج التنقيب في البيانات (مثل Dtree, STATISTICA Data Miner, Oracle, Weka) من الأوامر الخاصة بالتعامل مع الشبكات العصبية. كما ظهرت في الآونة الأخيرة برامج متخصصة في تحليل الشبكات العصبية مثل Mathematica

Neural Networks, NeuroXL, NeuroDimension, NeuroShell, ALYUDA تعطي للباحث مرونة أكبر في التعامل مع الشبكات العصبية أكثر من النوعين الأولين.

## 12. تطبيق عملي:

في هذا الجزء نتناول استخدام الشبكات العصبية ومقارنتها ببعض الأساليب التقليدية وأساليب التنقيب في البيانات لتحليل تابع اسمي (وصفي) وتعتمد الدراسة بصفة أساسية على توفير البيانات المطلوبة حسب الخصائص المختارة من خلال البيانات المتوفرة لمشروع التأهيل المرتكز على المجتمع في محافظتي "أسيوط وقنا"، وذلك لقياس الرضا والأثر عن خدمات التأهيل المرتكز على المجتمع على الأشخاص ذوي الإحتياجات الخاصة بمحافظة "أسيوط"، وقنا" لعدد 400 مفردة توزعت مناصفة حسب النوع، و60% بفترة العمر اقل من 15، ومنهم ذوي اعاقة حركية 44%، ومتعددة 28%، وذوي التعليم الأساسي 39%، وامى واخري 44%.

ولبيان الأهمية النسبية للمتغيرات المستقلة (الأثر) وتمثل أبعاد خدمات التأهيل المرتكز على المجتمع الست وهي (الخدمات العامة، الخدمات الصحية، التعليم، التمكين، المجال الاجتماعي وسبل العيش) على التابع ويمثل الرضا العام (وصفي يأخذ قيمتين نعم-لا)، وتم استخدام أسلوب الشبكات العصبية -التي تسمح بالتعلم من الخبرة والتجارب السابقة لاستنتاج خبرات وتجارب جديدة- كأداة لتحليل البيانات لنفس المجالات التي تتناولها الأساليب الإحصائية التقليدية وتقدم الشبكات العصبية طريقة مناسبة في تمثيل العلاقات بين المتغيرات بشكل مختلف عن الطرق التقليدية وينظر إليها كأداة إحصائية حديثة.

وتعرف الشبكات العصبية بنماذج الشبكات العصبية الذكية صناعياً وهي دوال غير خطية مرنة حيث لا تتطلب توافر الافتراضات المقيدة عن العلاقة بين المتغيرات التابعة والمتغيرات المستقلة وتعالج البيانات اللامعلمية أو صغيرة الحجم ولا تشرط التبعية للتوزيع الطبيعي بقدر عالي من الدقة هذا بالإضافة الى دقتها فيما يتعلق بالبيانات المعلمية .

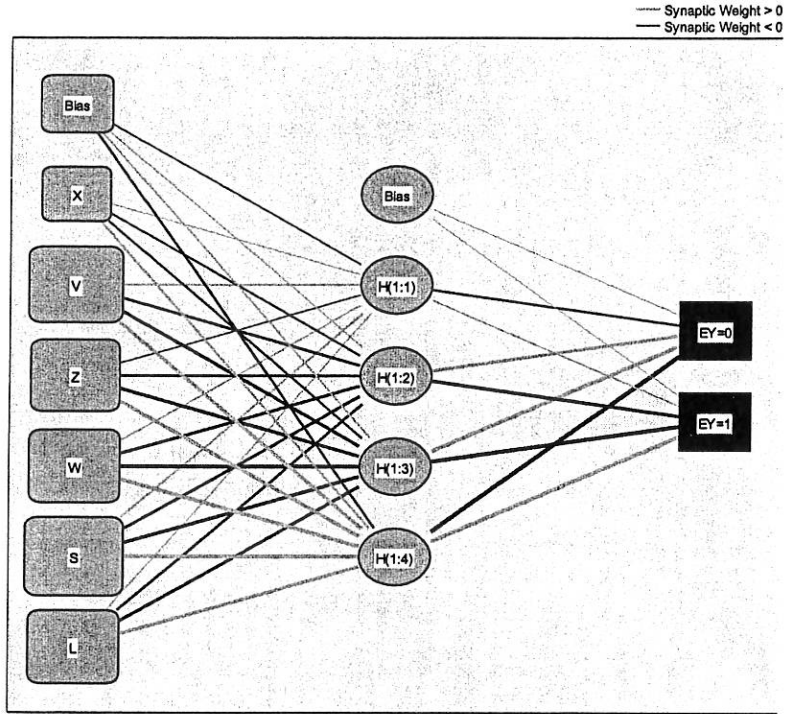
والشبكات العصبية تشبه وتمائل النماذج الإحصائية التقليدية شائعة الاستخدام غير أن هناك اختلافات فيما يتعلق ببعض الاصطلاحات فالمتغيرات المستقلة تسمى مدخلات والمتغيرات التابعة تسمى قيم التدريب أو قيم مستهدفة، والقيم المتنبأ بها تسمى مخرجات والتقدير يسمى تدريب أو تعليم أو التنظيم الذاتي والمعلمات تسمى أوزان وقيمها دائماً موجبة ومجموعها يساوى الواحد، ومن أجل تطبيقها على البيانات:

■ تم معالجة البيانات وقامت الشبكة بالتدريب على هذه البيانات بمعنى أن تقوم الشبكة بالتعلم والتعرف على البيانات والعلاقات بين المتغيرات المختلفة.

■ تم استخدام برنامج لتصميم الشبكة العصبية وتدريبها تبعاً لذلك ووضع معيار لإنهاء التدريب وهو عدم ملاحظة أى تغيير في متوسط الخطأ أما المعايير الإحصائية فهي مجموع مربعات الخطأ MSE ومتوسط الخطأ النسبي MEP.

- تم استخدام الشبكة العصبية للبيانات المتاحة بنسبة (100%) للتدريب Training وبنسبة (0%) للاختبار .Testing
- وتمثلت مدخلات الشبكة في عدد قيم الست متغيرات المستقلة، أما المخرجات فتتمثل في قيمة التابع، وبالتطبيق على البيانات:
- أوضح التحليل الإحصائي معنوية العلاقة بين المخرجات والمدخلات باستخدام اختبار F عند مستوى معنوية 0.000، ودرجة الدقة Accuracy 99.8%، وكفاءة التقسيم Correct Classification 100%.
- بلغت كفاءة التقسيم الصحيح 100%، وهي نسبة مرتفعة تشير للأهمية النسبية للمتغيرات المستقلة بمقارنة المعايير الإحصائية سالفة الذكر يتبين أن الشبكة العصبية قد تدربت بدرجة عالية، ومع استمرار تدريب الشبكة واستقرارها مما يعني أن الشبكة العصبية قامت بالتعلم والتدريب بشكل مناسب.
- توضح الأشكال مخرجات تدريب الشبكة حيث يتضح أن الشبكة قد تدربت من خلال دوال تحفيز الطبقات الخفية Hidden Neurosis Function layer Activation Hidden وتم تقدير عدد 4 عصبون مخفي Hidden Neurosis للنموذج، وأوضحت أن النموذج تمكن من تفسير الظاهرة محل البحث، وتوضح الأشكال سالفة الذكر أن هناك عصبونات كانت أوزانها أقل من الصفر.
- وباستخدام المعايير الإحصائية يستنتج بدون شك أن الشبكة العصبية فعلا تدربت بدرجة ممتازة مع استمرار عملية تدريب الشبكة الانخفاض إلى أن وصل إلى أدنى حد له واستقر مما يعني أن الشبكة العصبية قامت بالفعل بالتعلم والتدريب بشكل سليم وجيد. وتجدر الإشارة إلى أنه لم يطرأ تحسن ملحوظ على أداء الشبكة العصبية عند تغيير بعض المواصفات الداخلية لها، إضافة إلى ذلك فإنه عندما تم تغيير هذه المواصفات وجد أن جميع السيناريوهات قد استغرقت وقتاً أكبر في عملية التدريب. ولم نلاحظ أثر تغيير لهذه المواصفات على أداء الشبكة من خلال المعايير الإحصائية التي سبق ذكرها، وتعرض الأشكال والجداول التالية لمخرجات تدريب الشبكة و أوزانها النسبية.






Hidden layer activation function: Hyperbolic tangent

Output layer activation function: Softmax

شكل (3) مخرجات تدريب الشبكة

جدول (1) الأهمية النسبية لأوزان الأبعاد المستقلة



جدول (2) تقدير معالم النموذج الناتجة من تدريب الشبكة

Predictor	Predicted						
	Hidden Layer 1				Output Layer		
	H(1:1)	H(1:2)	H(1:3)	H(1:4)	[EY=0]	[EY=1]	
Input Layer	(Bias)	-.353-	.206	.479	-.646-		
	الخدمات العامة	.095	-.407-	-.484-	.884		
	الخدمات الصحية	.503	-1.397-	-1.888-	2.865		
	التعليم	-.097-	-1.499-	-2.210-	3.150		
	التمكين	.406	-1.588-	-2.467-	3.606		
	المجال الاجتماعي	.544	-1.585-	-2.332-	3.418		
	سبل العيش	.358	-1.421-	-2.117-	2.981		
Hidden Layer 1	(Bias)				.088	.025	
	H(1:1)				-.504-	.389	
	H(1:2)				2.332	-2.279-	
	H(1:3)				3.655	-3.360-	
	H(1:4)				-5.057-	5.409	


ويتضح من النتائج السابقة أن أهم أبعاد (عوامل) خدمات التأهيل المرتكز على المجتمع الست على التابع الرضا العام على الرضا العام هي المجال الاجتماعي والخدمات الصحية وسبل العيش والتمكين والتعليم والخدمات العامة لذوى الاحتياجات الخاصة بمحافظة أسيوط وقنا والتي تؤكد على زيادة الخدمات التأهيلية بالشراكة مع المؤسسات الداعمة والمجتمع المدني والمؤسسات المقدمة لمثل هذه الخدمات بالمجتمع مع الاهتمام بالمحور الاجتماعي والصحي وسبل العيش والتمكين والتعليم ودمجهم فى المجتمع مما يؤكد على فاعلية برنامج التأهيل المجتمعي القائم على المشاركة المجتمعية.

وحتى تكتمل الصورة يجب مقارنة نتائج أسلوب الشبكات مع بعض الأساليب التقليدية وأساليب تنقيب البيانات الأخرى والمتاحة بنظام SPSS Modeler 14.2 (ويمكن الرجوع لبعض المراجع المتخصصة) والموضحة نتائجها بملحق (1)، ويعرض جدول (3) ملخص النتائج للأساليب (النماذج) السبع، وشكل (4) للمساحة تحت منحنى الروك والتي تقيس حساسية النموذج فى التقسيم للرضا عن الخدمات من عدمه:

جدول (3) كفاءة تقسيم نتائج النماذج الست

نموذج	كفاءة التقسيم الصحيح %	المساحة تحت منحنى الروك
الشبكات البيزية BN	100	1.000
الشبكات العصبية NN	100	1.000
الاحدار اللوجيسى LOG	100	1.000
تحليل التمايز DIS	88	0.967
أقرب جار KNN	99	0.994
متجه دعم الآلة SVM	99	0.988
شجرة التقسيم CT	86	0.939

شكل (4) المساحة تحت منحنى الروك لحساسية النموذج في التقسيم للرضا عن الخدمات من عدمه



مما سبق يتضح:

- أن الشبكات العصبية الاصطناعية أكثر دقة وكفاءة في التصنيف عن الأساليب الإحصائية التقليدية حيث وصلت الشبكات لمعدل مرتفع وعالي من الدقة مع بقاء أفضليتها وسرعتها ودقتها.
- إن استخدام نموذج الشبكات العصبية في التصنيف، ورسم الخطط سواء الطويلة الأجل والقصيرة الأجل لما يتميز به هذا النموذج من سرعة ودقة في البيانات أكثر منه في الأساليب الإحصائية التقليدية.
- من خلال التطبيق لكل من النماذج الإحصائية التقليدية والشبكات العصبية يتبين لنا أن الشبكات العصبية قد تميزت عن الأساليب الإحصائية التقليدية بأن لديها منهجية في عدم الاعتماد على الخطية في البيانات.
- وجد أن الشبكات العصبية تتفوق على النماذج التقليدية بدرجة ملحوظة، وبمعنى آخر ونظراً لمنهجية الشبكات العصبية في اعتمادها على غير الخطية فإن أداءها أفضل مقارنة بالنماذج التقليدية لتحليل التابع الوصفي الأسمى.

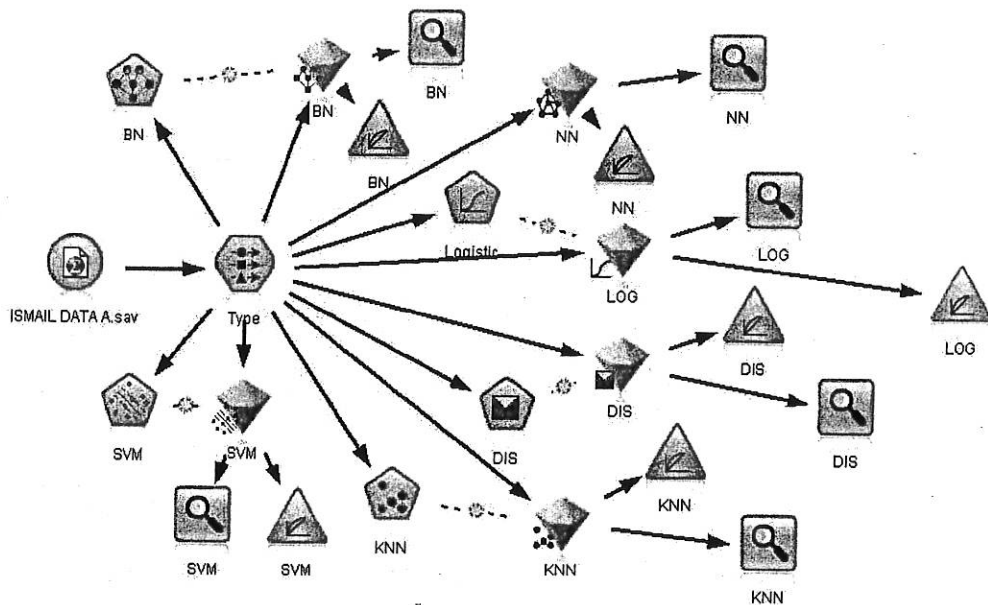
## References

- العباسي، عبد الحميد محمد (2004)، "المقارنة بين استخدام الشبكات العصبية وساريمما للتنبؤ بأعداد الوفيات الشهرية الناتجة عن حوادث المرور بالكويت"، المجلة العربية للعلوم الإدارية، الكويت، مجلد (3) العدد (11)، ص (333 – 359).
- العباسي، عبد الحميد محمد (2009)، التحليل المتعدد المتغيرات باستخدام SPSS، معهد الدراسات والبحوث الإحصائية – جامعة القاهرة – مصر، 2009.
- العباسي، عبد الحميد محمد (2010)، التحليل الإحصائي المتقدم باستخدام SPSS، معهد الدراسات والبحوث الإحصائية – جامعة القاهرة – مصر، 2010.
- الوزير، رزق و سمرى، حاتم (2012)، أساليب التقيب في البيانات: الطرق المعلمية واللامعلمية، المجلة المصرية للسكان وتنظيم الأسرة، معهد الدراسات والبحوث الإحصائية – مصر، مجلد (45) العدد (2)، ديسمبر 2012 ص (1 – 23).
- 1] A Radial Basis Function Approach to a Color Image Classification  
<http://scholar.lib.vt.edu/theses/available/etd-6197-223641/unrestricted/Ch3.pdf>
- 2] Backpropagation  
<http://en.wikipedia.org/wiki/Backpropagation>
- 3] Conjugate gradient method  
[http://en.wikipedia.org/wiki/Conjugate\\_gradient\\_method](http://en.wikipedia.org/wiki/Conjugate_gradient_method)
- 4] Delta rule (gradient descent)  
[http://en.wikipedia.org/wiki/Delta\\_rule](http://en.wikipedia.org/wiki/Delta_rule)
- 5] Christos Stergiou and Dimitrios Siganos. Neural Network  
[http://www.doc.ic.ac.uk/~nd/surprise\\_96/journal/vol4/cs11/report.html#Neural Networks in Practice](http://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html#Neural_Networks_in_Practice)
- 6] C. Lin, C. Hong (2009). "Development of a marketing information system for supporting sales in a Tea-beverage market," *Expert Systems with Applications*, 36, pp. 5393–5401.  
[www.elsevier.com/locate/eswa](http://www.elsevier.com/locate/eswa)
- 7] C. Rygielski, J. Wang, D. C. Yen (2002). "Data mining techniques for customer relationship management," *Technology in Society*, 24, pp. 483–502.
- 8] D. Enke, S. Thawornwong (2005). "The use of data mining and neural networks for forecasting stock market returns," *Expert Systems with Applications*, 29, pp. 927–940.  
[www.elsevier.com/locate/eswa](http://www.elsevier.com/locate/eswa)
- 9] Editorial of Decision Support Systems (2004). "Data mining for financial decision making," *Decision Support Systems*, 37, pp. 457–460.  
[www.elsevier.com/locate/dsw](http://www.elsevier.com/locate/dsw)
- 10] F. Rosenblatt (1958). "The perceptron: A probabilistic model for information storage and organization in the brain," *Psychological Review*, Vol 65(6), Nov, pp.386–408.  
doi: 10.1037/h0042519
- 11] Genetic algorithm  
[http://en.wikipedia.org/wiki/Genetic\\_algorithm](http://en.wikipedia.org/wiki/Genetic_algorithm)
- 12] Giudici, P. (2003), Applied Data Mining: Statistical Methods for Business and Industry, John Wiley & Sons Ltd.
- 13] Hastie, Trevor, Tibshirani, Robert, Friedman, Jerome (2009). The Elements of Statistical Learning: Data Mining, Inference, and Prediction, Second Edition.  
*Springer Series in Statistics*.
- 14] I. Bose, R. K. Mahapatra (2001). "Business data mining: a machine learning perspective," *Information & Management*, 39, pp. 211–225.  
[www.elsevier.com/locate/dsw](http://www.elsevier.com/locate/dsw)
- 15] John A. Bullinaria (2004). Introduction to Neural Networks  
<http://www.cs.bham.ac.uk/~jxb/NN/I1.pdf>


## المجلد 46 – العدد يونية 2013

- 16] Mathematical optimization  
[http://en.wikipedia.org/wiki/Mathematical\\_optimization](http://en.wikipedia.org/wiki/Mathematical_optimization)
- 17] Multilayer Perceptron Neural Networks  
<http://www.dtrek.com/mlfn.htm>
- 18] Neural Network Software *For researchers, data mining experts and predictive analysts*  
<http://www.alyuda.com/products/neurointelligence/neural-network-applications.htm>
- 19] Neural Network Toolbox, Levenberg–Marquardt (trainlm)  
[http://www.google.com.sa/search?hl=ar&rlz=1T4ACAW\\_enEG337&q=Neural+Network+Toolbox%2C+Levenberg-Marquardt+%oq=Neural+Network+Toolbox%2C+Levenberg-Marquardt+%gs\\_l=serp.3...102611.102611.0.103864.1.1.0.0.0.334.334.3-1.1.0...0.0...1c.UTmEEemtzcS4](http://www.google.com.sa/search?hl=ar&rlz=1T4ACAW_enEG337&q=Neural+Network+Toolbox%2C+Levenberg-Marquardt+%oq=Neural+Network+Toolbox%2C+Levenberg-Marquardt+%gs_l=serp.3...102611.102611.0.103864.1.1.0.0.0.334.334.3-1.1.0...0.0...1c.UTmEEemtzcS4)
- 20] P. Lucas (2004). "Bayesian Analysis, Pattern Analysis and Data Mining in Health Care," *Current Opinion in Critical Care*, 10, pp. 399–403.
- 21] Quasi–Newton method  
[http://en.wikipedia.org/wiki/Quasi-Newton\\_method](http://en.wikipedia.org/wiki/Quasi-Newton_method)
- 22] R. Caruana , S. Lawrence , C. L. Giles (2011). "Overfitting in Neural Nets: Backpropagation, Conjugate Gradient, and Early Stopping," *Proc. Neural Information Processing Systems Conference*.  
<http://wenku.baidu.com/view/0c0a327fa26925c52cc5bfbfd.html?from=related>
- 23] Reil, T. (2005), Artificial Neural Network  
<http://www.google.com.sa/url>
- 24] Rojas, R. (1996). Neural Networks, *The backpropagation algorithm*, Springer–Verlag, Berlin.  
<http://page.mi.fu-berlin.de/rojas/neural/chapter/K7.pdf>
- 25] Rumelhart, Hinton, Williams (1986). "Learning representations by back-propagating errors," *Nature*, 323 (6088), pp. 533–536.  
doi:10.1038/323533a0
- 26] S. Hung, D. C. Yen, H. Wang (2006). "Applying data mining to telecom churn management," *Expert Systems with Applications*, 31, pp. 515–524.  
[www.elsevier.com/locate/eswa](http://www.elsevier.com/locate/eswa)
- 27] StatSoft, *STATISTICA Automated Neural Network (SANN)*  
<http://www.statsoft.com/textbook/neural-networks/>
- 28] T. J. Stich, J. K. Spoerre, Tom s Velasco (2000). "The Application of Artificial Neural Networks to Monitoring and Control of an Induction Hardening Process," *Journal of Industrial Technology*, 16(1), pp. 1–11.  
<http://atmae.org/jit/Articles/stic0114.pdf>
- 29] Two Crows. Introduction to Data Mining and Knowledge Discovery, 3<sup>rd</sup> ed.  
<http://www.twocrows.com/intro-dm.pdf>
- 30] Y. Liu, J. A. Starzyk, Z. Zhu (2007). "Optimizing number of hidden neurons in neural networks,"  
[http://www.ohio.edu/people/starzykj/network/Research/Papers/Recent%20conferences../Hidden%20Neurons%20AIAA2007\\_549-204.pdf](http://www.ohio.edu/people/starzykj/network/Research/Papers/Recent%20conferences../Hidden%20Neurons%20AIAA2007_549-204.pdf)
- 31] SPSS (2012). SPSS Modeler 14.2 User's Guide. Chicago, IL: SPSS Inc.

ملحق (1)




Bayesian Network

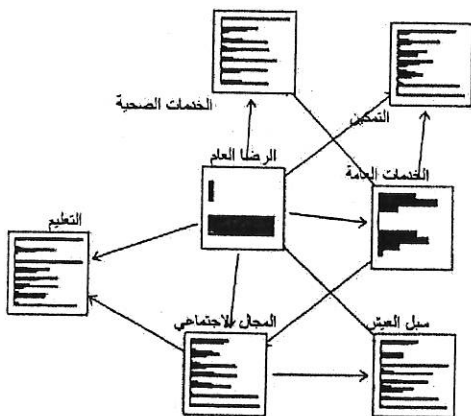


Predictor Importance

الرضا العام



Bayesian Network




Conditional Probabilities of الخدمات العامة

Parents	Probability				
الرضا العام	< -0.65	0.65 - 0.959	0.959 - 1.268	1.268 - 1.577	> 1.577
D	0.04	0.18	0.44	0.34	0.00
I	0.00	0.00	0.16	0.52	0.32

Model Summary

Target	الرضا العام
Model	Multilayer Perceptron
Stopping Rule Used	Minimum accuracy exceeded
Hidden Layer 1 Neurons	3



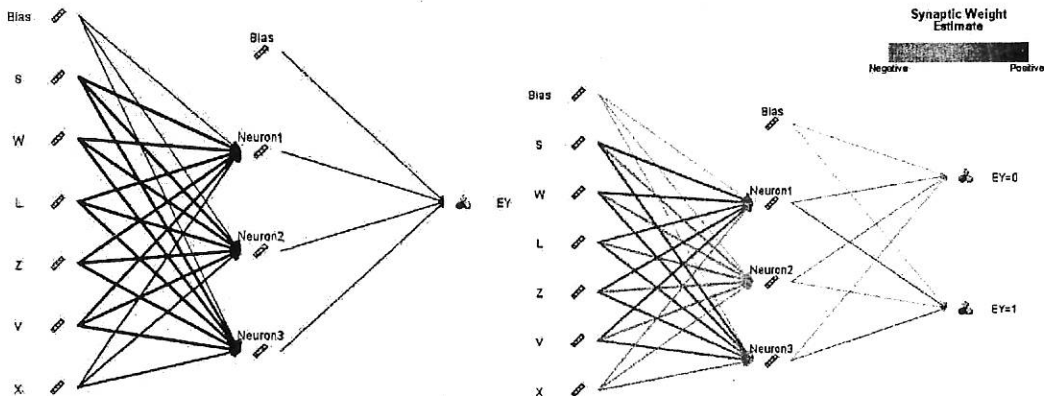
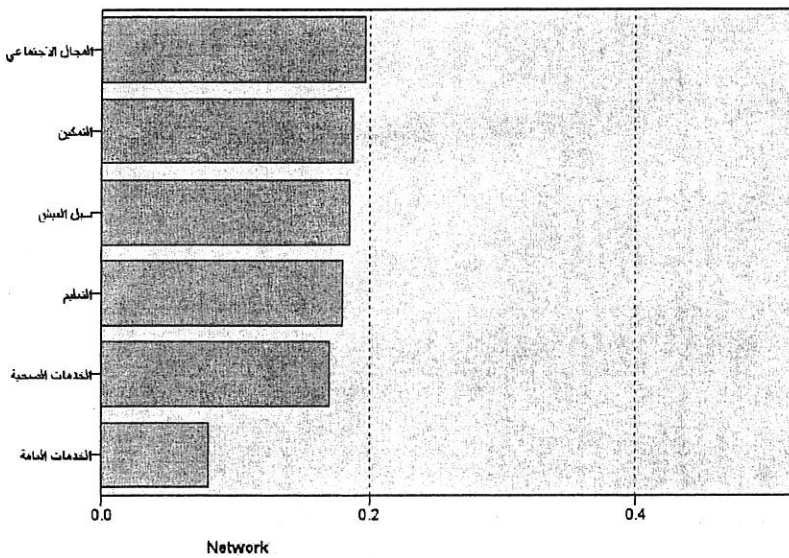
Classification for الرضا العام

Overall Percent Correct = 99.8%

Observed \ Predicted	Predicted		Row Percent
	0	1	
0	99.6%	0.4%	100.00
1	0.0%	100.0%	100.00

Predictor Importance

Target: الرضا العام





Model Fitting Information

Model	Model Fitting Criteria	Likelihood Ratio Tests		
	-2 Log Likelihood	Chi-Square	df	Sig.
Intercept Only	541.487			
Final	.000	541.487	6	.000


Pseudo R-Square


Cox and Snell	.742
Nagelkerke	1.000
McFadden	1.000

Parameter Estimates

EY(a)		B	Std. Error	Wald	df	Sig.	Exp(B)	95% Confidence Interval for Exp(B)	
								Lower Bound	Upper Bound
YES	Intercept	-1810.830	15418.124	.014	1	.907			
	X	167.314	4442.918	.001	1	.970	4.607E+072	.000	(.b)
	V	228.564	1923.795	.014	1	.905	1.837E+099	.000	(.b)
	Z	214.829	2080.199	.011	1	.918	1.991E+093	.000	(.b)
	W	219.774	1958.008	.013	1	.911	2.797E+095	.000	(.b)
	S	236.294	2053.349	.013	1	.908	4.182E+102	.000	(.b)
	L	222.132	1825.250	.015	1	.903	2.956E+096	.000	(.b)

Predictor Importance  
Target: EY



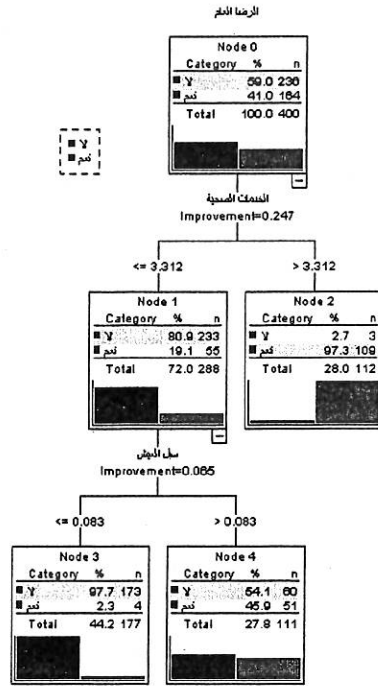


Growing Method: CRT  
Dependent Variable: العام للرضا

Surrogates

Parent Node	Independent Variable	Improvement	Association	
0	Primary	.247		
	الصحة الاجتماعية	.235	.795	
	الخدمات الصحية	.169	.705	
	التعليم	.158	.625	
	Surrogate	الخدمات العامة	.159	.563
	التمكين	.111	.402	
1	Primary	.065	.402	
	سبل العيش	.049	.775	
	التعليم	.050	.505	
	Surrogate	الاجتماعي المجال	.036	.414
	الصحة العامة	.021	.189	
	الخدمات	.023	.090	

Growing Method: CRT  
Dependent Variable: العام للرضا



Eigenvalues

Function	Eigenvalue	% of Variance	Cumulative %	Canonical Correlation
1	1.678(a)	100.0	100.0	.792

a. First 1 canonical discriminant functions were used in the analysis.

Wilks' Lambda

Test of Function(s)	Wilks' Lambda	Chi-square	df	Sig.
1	.373	389.040	6	.000

Standardized Canonical Discriminant Function Coefficients

	Function
	1
الخدمات العامة	-.503
الخدمات الصحية	.726
التعليم	.017
التمكين	.196
المجال الاجتماعي	.480
سبل العيش	.139

Structure Matrix


	Function	
	1	
الخدمات الصحية		866
المجال الاجتماعي		866
التعليم		763
التأمين		678
سبل العيش		625
الخدمات العامة		582

Pooled within-groups correlations between discriminating variables and standardized canonical discriminant functions. Variables ordered by absolute size of correlation within function.

Functions at Group Centroids

الرضا العام	Function	
	1	
NO		-1.077
YES		1.550

Unstandardized canonical discriminant functions evaluated at group means



This chart is a lower-dimensional projection of the predictor space, which contains a total of 6 predictors.

k Selection Error log

