

تحسين فرصة الحصول على عطاء مشروع هندسي لأبنية مدرسية باستخدام الشبكات العصبية الصناعية

الدكتور جمال عمران *

الدكتور هاني نجا **

مي صوفان ***

(قبل للنشر في 2004/9/16)

□ الملخص □

اهتم العديد من الباحثين بتطوير نماذج رياضية وإحصائية لتساعد المقاولين في تحديد نسبة الضم أو التنزيل التي تزيد من فرصة الفوز بالعطاء عند تقدمهم لمشروع ما، ولسوء الحظ فإن كثيراً من هذه النماذج لم تطبق وذلك إما بسبب النقص في المعلومات المطلوبة لتطبيق النموذج، وإما بسبب درجة التعقيد الكبيرة في تطبيق بعض تلك النماذج في الحياة العملية.

ويقدم هذا البحث نموذج شبكة عصبية Neural Network تساعد المقاول في تحديد نسبة الضم أو التنزيل التي تزيد من فرصة فوزه بالعطاءات الخاصة بمشروعات تنفيذ المدارس. وقد تم تصميم وتدريب واختبار الشبكة بالاعتماد على 118 عينة من المشروعات المنفذة في قرى ومدن الساحل السوري، أما تحديد العوامل التي تؤثر على نسبة التنزيل أو الضم والتي تعتبر كمدخل للشبكة فقد تم تحديدها بالاعتماد على استبيان تم توزيعه على عدد كبير من المقاولين العاملين في هذا النوع من المشروعات. وقد تم تدريب واختبار الشبكة على العينات المذكورة سابقاً من أجل معماريات مختلفة للشبكة وذلك لاختبار المعمارية التي توافق الخطأ الأصغري، وتبين أن الشبكة العصبية المكونة من طبقتين خفيتين تحوي كل منهما عشر عصبونات وباستخدام تابع التنشيط سيغمويد ومعدل تعلم 0.8 أعطت أفضل النتائج.

*محاضر في قسم الإدارة الهندسية والإنشاء، كلية الهندسة المدنية، جامعة تشرين، اللاذقية، سوريا.
** محاضر في قسم الإدارة الهندسية والإنشاء، كلية الهندسة المدنية، جامعة تشرين، اللاذقية، سوريا.
*** دبلوم في كلية الهندسة المدنية، جامعة تشرين، اللاذقية، سوريا.

Improving the Opportunity of Winning a Project Tender of Schools Using Artificial Neural Network

Dr. Jamal Omron*
Dr. Hani S. Naja**
May M. Soufan***

(Accepted 16/9/2004)

□ ABSTRACT □

A lot of researchers have developed many mathematical and statistical models to help the contractor to determine the mark up that increases the opportunity of winning a project bid.

Unfortunately, most of these models were not applied in construction project bids, either because of the lack of required information or the complexity of applying some of these models in the practical life.

This paper presents neural network model which can help the contractor determine the bid price that increases the opportunity of winning the bid of school construction project. The proposed neural network has been designed, trained and tested using 118 samples of school projects distributed in the villages and the cities of the Syrian coast.

The factors affecting the bid price which are considered to be the network input, have been determined by the use of questionnaire distributed among many experienced constructors involved in this kind of projects.

The network was trained and tasted for different architectures in order to choose the network architecture that leads to the minimum percentage of errors, and it came out that the network that consists of two hidden layers with ten neuroses in each hidden layer with sigmoid function and learning rate of 0.8 gave the best results.

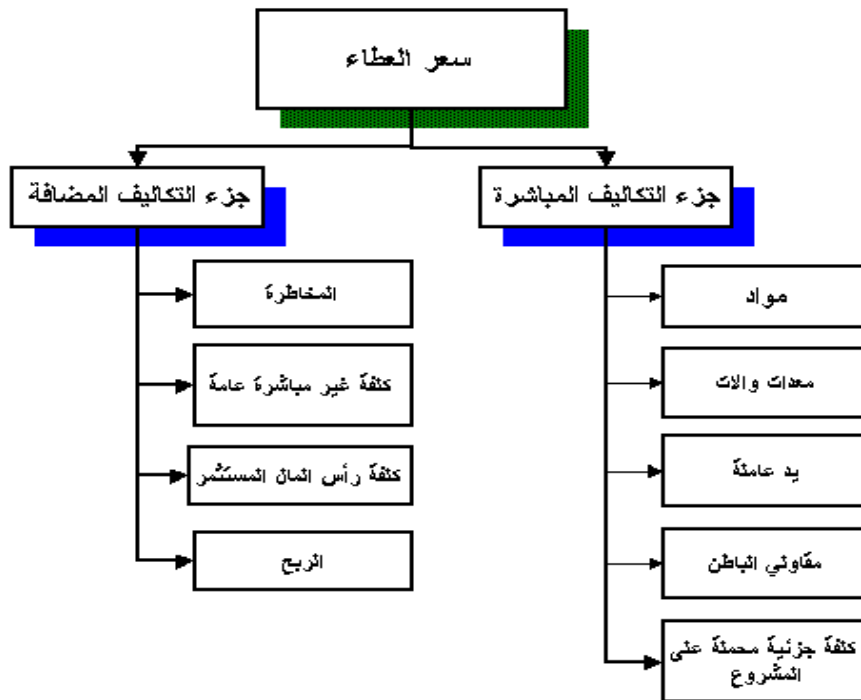
*Lecturer, Construction Engineering And Management Department, Faculty Of Civil Engineering, Tishreen University, Lattakia ,Syria.

** Lecturer, Construction Engineering And Management Department, Faculty Of Civil Engineering, Tishreen University, Lattakia, Syria.

***Diploma, Construction Engineering And Management Department, Faculty Of Civil Engineering, Tishreen University, Lattakia, Syria.

مقدمة:

إن سعر العطاء الذي يضعه المقاول عند التقدم للمنافسة على مناقصة ما يتم تقديره بالأخذ بعين الاعتبار نوعين من التكاليف هما: 1 - تكاليف مباشرة Direct Cost: كتكاليف اليد العاملة والمواد والمعدات إضافة إلى التكاليف غير المباشرة المحملة على المشروع نفسه Indirect cost، 2 - جزء التكاليف غير المباشرة (الإضافات): Add on وتشمل التكاليف غير المباشرة العامة، كتكلفة رأس المال المستثمر، المخاطرة، إضافة إلى الربح. ويمكن توضيح أنواع التكاليف التي تحدد سعر العطاء بالشكل (1).



الشكل (1) أنواع التكاليف التي تحدد سعر العطاء.

إن الخلاف الأساسي بين أسعار المتنافسين على العطاء غالباً ما ينتج عن الاختلاف في تقديرهم لقيمة إضافات التكلفة Add on وذلك لأن الكلفة المباشرة غالباً ما يتم تقديرها بشكل مشابه أو باختلافات بسيطة بين مختلف المتعهدين المتقدمين للعطاء لأنها معتمدة أساساً على جدول الكميات المطروح من قبل مالك المشروع Bill Of Quantity (BOQ)، أما الكلفة المضافة Add On والتي تتضمن الربح فهي تختلف من مقاول لآخر وتأخذ بعين الاعتبار مجموعة من العوامل الخاصة بالمشروع كدرجة تعقيد المشروع، حجم المشروع، مقدار المخاطرة، المشاكل القانونية التي قد يتعرض لها المشروع. وكل تلك العوامل تصعب مهمة المقاول في تحديد نسبة التنزيل أو الضم المثلّي التي تضمن له الفوز بالعطاء.

استراتيجيات التقدم للطاءات التنافسية:

إن عملية تحديد نسبة الضم أو التنزيل التي سينتقد بها المقاول لمناقصة ما والتي يأمل أن يربح بها العطاء هي عملية صعبة وتتطلب تحليلاً دقيقاً وجهداً من جانبه، فإذا كانت نسبة التنزيل منخفضة جداً فغالباً ما يفشل المقاول في الحصول على العطاء إضافة لخسارة الوقت والجهد والمال الذي أنفق بالتحضير للمناقصة. ومن جهة أخرى فإذا كانت هذه النسبة مرتفعة جداً فالمقاول ربما يربح المناقصة ولكن نسبة ربحه سوف تقل أو لن يربح مطلقاً، لذلك من الضروري إيجاد طريقة لتحديد هذه النسبة بحيث تضمن للمقاول الفوز بالمناقصة مع ضمان أعلى نسبة ربح ممكنة من المشروع وبالتالي بقائه ضمن دائرة المنافسة.

تتمثل المشكلة في صعوبة تحديد العلاقات الرياضية التي تربط المتغيرات الكثيرة والتي تميز المشروع ونسبة التنزيل أو الضم المثلى التي تزيد فرصة الفوز بالعطاء، وهذا ما دفع الكثير من الباحثين للسعي لاقتراح طرق تساعد على تحديد هذه النسبة، ومعظم هذه النماذج اعتمدت على إيجاد تابع التوزيع الاحتمالي للنسبة "S" الذي يمثل نسبة سعر العطاء إلى الكلفة التقديرية، إن نوع التابع المستخدم شكل نقطة الخلاف الرئيسية بين الباحثين، فالنموذج المقترح من قبل [Friedman 1956] قد استخدم التوزيع Gamma أما النماذج المقترحة من قبل [Benjamin and Meador 1979] وكذلك [McCaffer 1976] و [Gates 1967] فقد افترضت تابع التوزيع الطبيعي Normal، في حين افترض [Klein 1976] أن توزيع Lognormal يلائم المناقصات بشكل أكبر. وفي عام 1990 اقترح [Seydel. J and Olson. D] نموذج احتمالي لتحديد تلك النسبة بالاعتماد على ثلاث عوامل فقط هي كلفة المشروع، المخاطرة المتوقعة، حجم العمل الحالي للشركة أو "درجة تواصل العمل". أما النموذج المقترح لحل المشكلة من قبل [Dozzi, Abou Risk and Schroeder 1996] فقد اعتمد على نظرية المنفعة، وعلى الرغم من أن النموذج قد أخذ بالاعتبار الكثير من العوامل المؤثرة إلا أنه لم يطبق عملياً وذلك لصعوبته ولكثرة الثوابت العددية المتغيرة مع كل مشروع والتي يصعب الحصول عليها خلال فترة التحضير للمناقصة. نموذج وأخذ [Fayek Aminah 1998] بعين الاعتبار حوالي تسعين عاملاً وذلك بالاعتماد على نظرية المجموعة الضبابية Fuzzy Set Theory.

هدف البحث:

على الرغم من كثرة الأبحاث التي عالجت استراتيجيات التعاقد التنافسية إلا أن أكثرها لم يطبق عملياً، وذلك لصعوبة معالجة العوامل المؤثرة على نسبة الضم أو التنزيل بسبب كثرتها وتعقيدها وإهمال بعض النماذج للكثير من العوامل التي تؤثر على تلك النسبة ومن بينها العوامل النوعية التي لا يمكن التعبير عنها بأرقام كظروف الطقس ودرجة تعقيد المشروع وطبيعة التربة. والسبب الآخر لصعوبة تحديد نسبة الضم أو التنزيل كون تلك النسبة تعتمد على بيانات المقاولين المنافسين والتي تعتبر معلومات سرية يصعب الحصول عليها، وحتى في حال معرفة هذه البيانات فإن بعض المنافسين يلجؤون لتغيير استراتيجيتهم تبعاً لظروفهم الخاصة ولتغيرات السوق، كما أن جميع النماذج تستخدم القواعد الهندسية والرياضية التي قد تكون صعبة الفهم على المقاول كنظرية المنفعة والنظرية الضبابية والنظرية الاحتمالية.


لهذا بقيت الحاجة لنموذج جديد يلائم الناحية العملية للمقاولين ويساعدهم على تحديد نسبة الضم أو التزويل بسهولة دون وجود أية علاقة رياضية عند التطبيق، ويستطيع أن يأخذ بالاعتبار جميع العوامل النوعية وغير النوعية المؤثرة على تحديد تلك النسبة ودون الحاجة لمعرفة أي معلومات عن المنافسين كما يمكن هذا النموذج المقاول من اتخاذ قراره بشكل سريع خصوصاً في الحالات التي تكون فيها فترة التحضير للمناقصة قصيرة.

يقدم هذا البحث محاولة لدراسة إمكانية استخدام إحدى تطبيقات الذكاء الصناعي المتمثلة بالشبكات العصبية الصناعية وذلك في حل إحدى المشاكل التي تواجه المقاولين الساعين إلى دخول سوق المنافسة على عطاءات المشروعات المدرسية من خلال تحديد النسبة التي تحسن فرصة المقاول بالفوز بالعطاء وبأقل فارق ممكن عن أقرب منافسيه، والنموذج المطور للشبكة العصبية الصناعية سوف يمكن المقاول العادي الذي لا تتوفر لديه معلومات عن النظريات الرياضية والاحتمالية من استخدامه بكل سهولة ويسر.

نموذج الشبكة العصبية الصناعية المقترح:

إن الميزة الأساسية للشبكات العصبية تكمن في قدرتها على معالجة كمية كبيرة من المعلومات وتكوين نماذج لحل العديد من المسائل التي تكون فيها العلاقة بين متحولات الدخل والخرج تتصف بصعوبة صياغتها رياضياً. وتتألف الشبكة العصبية المقترحة من نظام التغذية الأمامية Feed Forward ومن مجموعة من الطبقات Multi Layers وكل طبقة تتألف من مجموعة من الوحدات أو العقد Nodes، Units، حيث يختلف عدد الطبقات الأمثل ضمن الشبكة وعدد الوحدات داخل كل طبقة باختلاف المشكلة المطروحة.

و يوضح الشكل (2) بنية الشبكة العصبية الصناعية والمكونة من [Garrett. J. H, Gunaratnam. D. J. and Ivezic. N 1997]



الشكل (2) بنية الشبكة العصبية الصناعية .

. **طبقة الدخل Input layer**: حيث تعمل عقد المعالجة Nodes على توزيع القيم المدخلة إليها من الوسط الخارجي إلى كل وحدة من وحدات الطبقة الخفية التي تليها عبر الارتباطات أو الأوزان الموجودة بينهما فهي بذلك لا تقوم بأية عملية حسابية.

. **الطبقات الخفية Hidden Layers**: وهي مجموعة الطبقات التي تقع بين طبقتي الدخل والخرج، وعناصر هذه الطبقات هي التي تقوم بالعمليات الحسابية حيث تتلقى الإشارات من وحدات الدخل بعد أن تكون قد عدلت من خلال أوزان الارتباطات بين هاتين الطبقتين "الدخل والخفية" لتعالجها وتطبق تابع التنشيط على تلك الإشارات ثم تحولها إما إلى الطبقة الخفية التالية أو إلى طبقة الخرج. إن تابع التنشيط المطبق يمكن أن يأخذ أشكالاً متعددة تتعلق بطبيعة التطبيق ومن أهمها تابع التنشيط الخطي، وتابع سيغمويد ثنائي القطبية وتابع سيغمويد الذي تم اعتماده في هذا البحث.

. **طبقة الخرج Output Layer**: بعد أن يطبق تابع التنشيط المستخدم على قيم الدخل الصافي المتجهة إلى وحدات الطبقة الخفية تقوم هذه الوحدات بتحويل القيم الناتجة إلى كل وحدة من وحدات طبقة الخرج حيث تقوم عناصر المعالجة فيها بإجراء العمليات الحسابية بشكل مشابه تماماً للطبقات الخفية لتعطي بعد ذلك النتيجة النهائية للمشكلة [Freeman. J. A and Skapura. D. M 1991].

وقد تم تطوير الشبكة العصبية المقترحة من خلال أربع مراحل أساسية هي:
[California Scientific Software 1994]

1. تصميم الشبكة.
2. تدريب الشبكة.
3. اختبار الشبكة.
4. مرحلة تطبيق الشبكة.

ويقصد بعملية تصميم الشبكة إيجاد الشبكة العصبية المثلى والتي تقابل الخطأ الأصغري وذلك عن طريق تحديد العوامل المؤثرة على المشكلة وتحديد عدد الطبقات الخفية وعدد العقد في كل طبقة ومعدل التعلم المقابل للحل الأمثل.

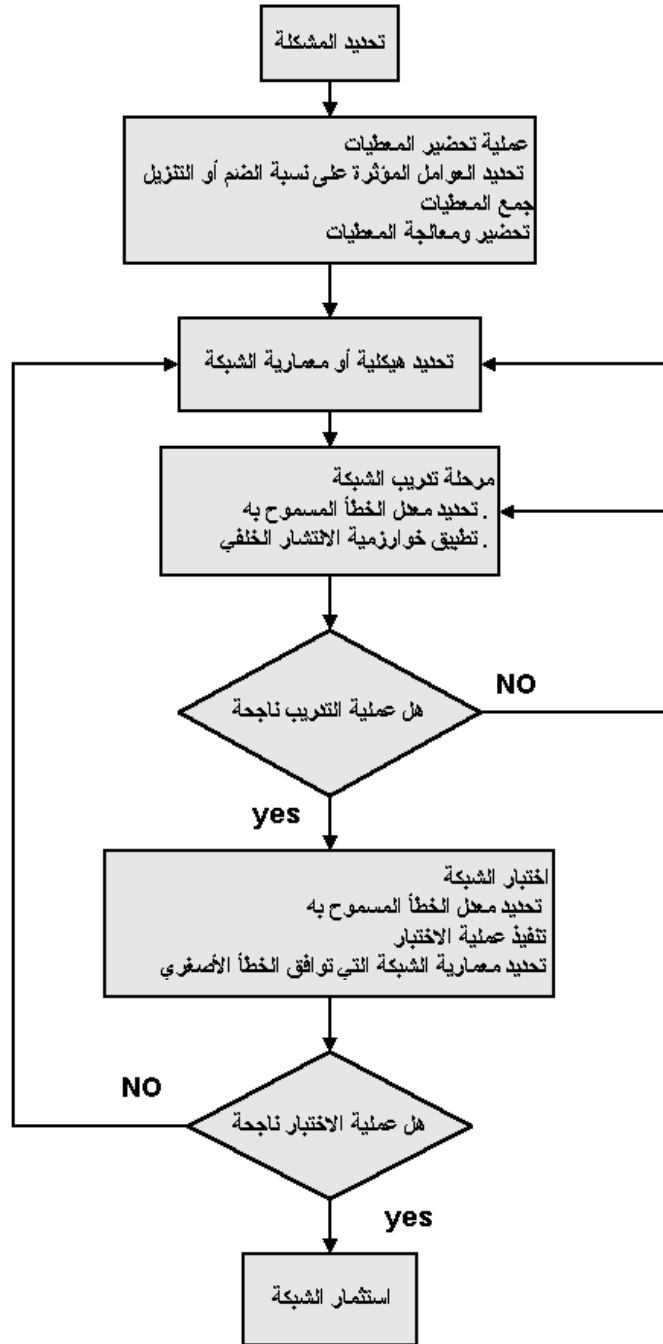
أما عملية التدريب فتتمثل بحساب أوزان الارتباطات بين وحدات الطبقات المختلفة وحساب الخطأ الناتج بين الخرج الحقيقي والخرج الناتج عن عملية التدريب، ومن ثم إعادة توزيعه بعملية معاكسة وذلك بتطبيق تقنية الانتشار الخلفي Back Propagation وذلك للحصول على الخطأ الأصغري المرغوب به والمحدد قبل البدء بعملية التدريب. ونظراً لأن عملية التدريب تحتاج إلى توفر قيم الدخل وقيم الخرج المقابلة لها لعدد كبير من العينات بهدف تدريب الشبكة لهذا تم اختيار مشاريع المدارس المنفذة في مدن وقرى الساحل السوري وذلك بسبب كثرة تنفيذ هذا النوع من المشاريع إضافة إلى المنافسة الشديدة من قبل المقاولين عليها بسبب بساطتها وسهولة تنفيذها، وهذا ما شجع استخدام الشبكات العصبية الصناعية في تحديد نسبة التزليل المثلى التي تزيد فرصة المقاول بالفوز بالعطاء وأقل فارق عن أقرب منافسيه.

مرحلة الاختبار تشبه في أليتها عملية التدريب وهي المرحلة التي تصبح فيها الشبكة قادرة على تمييز العينات وإعطاء استجابات صحيحة لعينات لم تتدرب عليها سابقاً وعادة تكون نسبة نماذج الاختبار حوالي 10 % من عدد العينات الإجمالي.

وإذا كانت قيمة الخطأ الناتج عن عملية الاختبار تقع ضمن المجال المسموح والمحدد قبل عملية الاختبار فعندها يمكن اعتبار أن الشبكة قد تدرت واختبرت بشكل جيد ويمكن بالتالي وضعها قيد الاستثمار. أما إذا كان الخطأ لا يتوافق مع الخطأ المسموح به، فيجب عندئذ اللجوء إما إلى تغيير هيكلية الشبكة وتصميمها وإما إلى تغيير أحد بارامترات التدريب. ويوضح الشكل (3) مراحل تطوير الشبكة العصبية الصناعية المقترحة والفقرات التالية تشرح هذه المراحل بشكل مفصل [California Scientific Software 1994].

تحديد العوامل المؤثرة على نسبة الربح

تؤثر العديد من العوامل على عملية تحديد نسبة الضم أو التنزيل، واعتمد معظم الباحثين الذين وضعوا نماذج رياضية لتحديد هذه النسبة على نفس العوامل، وإن كان كل منهم قد أعطى أهمية لبعضها دون غيرها. ولتحديد العوامل المؤثرة على نسبة الضم أو التنزيل والتي سيتم اعتبارها في طبقة الدخل للشبكة المقترحة، تم توزيع استبيان على عدد كبير من المقاولين المهتمين بتنفيذ هذا النوع من المشاريع " مشاريع تنفيذ مدارس ". وبعد الدراسة الإحصائية لنتائج الاستبيان المذكور تم تحديد أكثر العوامل أهمية وقد حصرت بأربعة عشر عاملاً كل منها له تأثير كبير على المشكلة المطروحة. ويظهر الجدول (1) العوامل التي تم اعتبارها في هذا البحث مع وصف كل عامل والقيم العددية التي تعبر عنه من أجل كل حالة له.



الشكل (3) مراحل تطوير الشبكة العصبية المقترح.

الجدول (1) العوامل المؤثرة على نسبة الضم أو التنزيل.

رقم العامل	العامل	وصف العامل	وزن العامل
1	حجم المشروع	كلفة المشروع التقديرية.	مقدرة بألوف الليرات السورية
2	درجة تعقيد المشروع	يتعلق هذا المعيار بنوع المدرسة، عدد الطوابق، عدد الشعب، مدة التنفيذ.	0 = مشروع بسيط 1 = مشروع متوسط التعقيد 2 = مشروع معقد
3	مدة التنفيذ	مدة العمل في المشروع	مقدرة بالأيام
4	نوع التربة.	ما هي نوعية تربة الموقع ؟ وما مقدار صعوبة معالجة هذه التربة ؟	0 = تربة ذات نوعية جيدة . 1 = تربة ذات نوعية متوسطة . 2 = تربة ذات نوعية سيئة . 3 = تربة ذات نوعية سيئة جدا .
5	موقع المدرسة.	المشروع ضمن المدينة أم خارجها ؟ .	0 = ضمن المدينة . 1 = خارج المدينة .
6	توفر الخدمات.	موقع المشروع مخدم (توفر ماء وكهرباء) أم غير مخدم ؟	0 = موقع مخدم . 1 = موقع غير مخدم .
7	تنفيذ طريق .	هل سيتم تنفيذ طريق بطول L يصل المشروع بالطريق العام أم لا ؟	0 = لا ضرورة لتنفيذ طريق . 1 = عندما $0 < L < 100$ متر 2 = عندما $100 < L < 200$ متر 3 = طول الطريق أكثر من 200 م
8	وجود مشاكل قانونية	هل المشروع يحتوي على مشاكل قانونية ؟ .	0 = لا يوجد مشاكل . 1 = يوجد مشاكل .
9	المخاطرة والظروف الخاصة	هل هناك ظروف خاصة قد تؤثر على أحد بنود المشروع ؟	0 = لا يوجد مخاطرة . 1 = مخاطرة متوسطة . 2 = مخاطرة عالية .
10	القرب من موردي المواد الأولية للبناء .	المسافة " D " بعد أماكن توفر المواد الأولية للبناء .	0 عندما $D > 25$ كم . 1 عندما $25 < D < 50$ 2 عندما $50 < D < 75$ 3 عندما $D > 75$
11	عدد المتقدمين للعرض أو درجة التنافسية	عدد المتنافسين المتقدمين لهذا المشروع .	عدد الأشخاص.
12	عدد المشاريع السابقة للمتعهّد	لتحديد الخبرة بالنسبة للمقاول وبالنسبة لطاقم العمل عنده	عدد المشاريع المنفذة.
13	دقة التقدير.	درجة دقة الجهة الدارسة (حساب كميات، تصاميم .. الخ)	نسبة مئوية %
14	ظروف الطقس .	في أي فترة من السنة سيتم تنفيذ المشروع؟	3 = الشتاء . 2 = الخريف أو الربيع. 1 = الصيف

جمع المعطيات

تعد مرحلة جمع المعطيات من أهم مراحل تصميم الشبكة العصبية الصناعية لان الشبكة العصبية تحتاج إلى عدد كبير من أزواج التدريب (دخل، خرج) وذلك لإجراء عملية التدريب والاختبار، وبدون هذه العينات فالشبكة لن تتمكن من التدريب والاختبار وحل المشكلة المطروحة. إن كل عينة من العينات مرتبطة بالعوامل الأربعة عشر المحددة سابقاً والتي لا تحمل طبيعة متشابهة، فبعض العوامل نعبر عنه بالأرقام ككلفة المشروع وعدد المتقدمين للمناقصة، والأخر بشكل رمزي كدرجة التعقيد ودرجة المخاطرة. ويقدر ما تكون هذه العينات دقيقة وممثلة للواقع فان القيم الناتجة عند استثمار الشبكة سوف تكون دقيقة أكثر.

لقد شملت العينة التي تم تدريب واختبار الشبكة عليها على بيانات مئة وثمانية عشر / 118 / مشروعاً لمدارس منفذة خلال السنوات الأربعة الماضية حيث جمعت بياناتها من دائرة الخدمات الفنية باللاذقية ومن المواقع الحقيقية لبعضها، وقد كانت العينة المأخوذة شاملة قدر الإمكان لجميع الحالات والظروف للحصول على أعلى دقة ممكنة للشبكة النهائية التي سنحصل عليها والتي ستوضع قيد الاستثمار.

معالجة المعطيات :

يقصد بعملية معالجة المعطيات تحويل المعطيات الرمزية إلى قيم عددية حسب درجة تأثير كل منها على نسبة التنزيل الموافقة وذلك ليسهل التعامل معها، ومن ثم تحويل المعطيات العددية والرمزية معا إلى قيم محددة ضمن مجال حدود تابع التنشيط المستخدم في الشبكات العصبية، ثم إيجاد القيم المقابلة لكل عامل من العوامل المؤثرة على نسبة الضم أو التنزيل وذلك بالاعتماد على العمود الرابع من الجدول (1) وحالة كل عينة من المشاريع المستخدمة في عملية التدريب والاختبار [California Scientific Software 1994].

تصميم الشبكة / تحديد معمارية الشبكة /

يقصد بعملية تصميم معمارية الشبكة تحديد الكثير من المتغيرات التي تميز الشبكة العصبية الصناعية كعدد الطبقات الخفية، عدد الوحدات بكل طبقة خفية، معدل التعلم، معدل الخطأ... الخ. إن معدل التعلم يلعب دوراً في تقارب الشبكة للحصول على الخطأ الأصغر، أما عدد الطبقات الخفية وعدد الوحدات أو العقد في كل طبقة فهي تحدد عدد الارتباطات بين تلك الوحدات، فإذا كانت الارتباطات قليلة فالشبكة لن تكون قادرة على التعلم والارتباطات الكثيرة تجعل الشبكة تأخذ وقتاً أطول للتعلم، وإن طبقة مخفية واحدة تكفي لحل 85 % من التطبيقات كما يمكننا استخدام أكثر من طبقة خفية عند عدم الحصول على نتائج مقبولة مع طبقة واحدة [علام زكي عيسى 2000]. أما تتابع التنشيط فيتم اختياره بحيث يحقق العديد من الخصائص الهامة كأن يكون تابع مستمر، قابل للاشتقاق، انسيابي غير متناقص، مشتقه سهل الحساب، ولهذا فقد تم تطبيق تابع التنشيط سيغمويد Sigmoid لامتلاكه تلك المزايا.

وقد حللت المعايير المحددة لكل مدرسة على حده لأن هذه العينة ستستخدم في عملية تدريب واختبار الشبكة لاحقاً، وإن مجالات التحويل لكل معيار مع القيمة العددية المقابلة له موضحة بالجدول السابق (1). تحتاج الشبكات العصبية الصناعية إلى الكثير من العينات لتتعلم وتصبح قادرة على إعطاء نتائج دقيقة ولهذا فقد تم تطبيق تقنية Cross Validation التي تقوم بتوليد عينات جديدة اعتباراً من العينات المتوفرة.

وقد تم توليد خمس مجموعات جزئية مشتقة من العينة الأصلية هي على التوالي G1, G2, G3, G4, G5 فمن اجل المجموعة الجزئية G1 تم تكوينها باستبعاد المشاريع {1, 5, 10,100} وتم إجراء التدريب على 80 مشروعاً فقط، أما بالنسبة للمجموعة G2 فقد تم استبعاد المشاريع {2, 6, 11,111} من العينة الأصلية وتمت عملية التدريب على المشاريع المتبقية، وهكذا بالنسبة للمجموعات G3, G4, G5 وهكذا فقد تضاعفت العينة الإجمالية حوالي خمس مرات [Twomey. J M and Smith. A E 1997].

تطوير الشبكة العصبية الصناعية المقترحة

تم تصميم نموذج الشبكة العصبية الصناعية المقترحة باستخدام أداة لنمذجة الشبكات العصبية المطورة من قبل جامعة كاليفورنيا والتي تحمل الاسم التجاري Brain Maker حيث تم تصميم الشبكة وتدريبها واختبارها باستخدام هذه الأداة. وقد درست كل مجموعة من المجموعات الخمس على حده، حيث تم أخذ جميع الاحتمالات الممكنة لمعمارية الشبكة وذلك بتغيير أحد العوامل في كل مرة كعدد الطبقات المخفية، أو عدد الوحدات ضمن الطبقة المخفية، ومن أجل كل معمارية تم تجريب معدلات تعلم مختلفة وذلك لاختيار المعمارية الأفضل للشبكة، ومن ثم تم اختيار التصميم الموافق لأقل نسبة خطأ في كل حالة من حالات التصميم المختلفة.

وقد اعتمدت مرحلة تدريب الشبكة على تقنية التدريب بطريقة الانتشار الخلفي Back propagation، حيث تم تمرير أزواج التدريب للشبكة (دخل، خرج) الواحدة تلو الأخرى ومن أجل كل عينة يتم حساب قيمة خرج الشبكة المقدر والذي يقارن مع الخرج الحقيقي (الفعلي) المقدم للشبكة ليتم بعد ذلك حساب قيمة الخطأ بينهما وتوزيعه باتجاه معاكس (أي تعديل أوزان الارتباط بين وحدات الطبقات المخفية) بهدف الحصول على كمية خطأ مقبول ضمن الخطأ المسموح للشبكة والذي تم اعتباره 0.1 % ومن ثم الحصول على مصفوفة الأوزان المثلى التي سيتم استخدامها في مرحلة الاستثمار. ويظهر الجدول (2) نتائج اختبار الشبكة باعتبار معمارية معينة وهي شبكة مؤلفة من طبقة خفية واحدة تتألف من ثماني وحدات وذلك من أجل معدلات تعلم مختلفة تتراوح بين 0.1 إلى 1 .

الجدول (2) قيم الأخطاء الناتجة عن اختبار الشبكة المكونة من طبقة خفية واحدة بثمانى وحدات ومن أجل معدلات تعلم مختلفة.

Average Error	مجموعات التدريب					معدل التعلم	رقم التصميم
	G5	G4	G3	G2	G1		
RMSE							
*0.0563	0.0733	0.0333	0.0339	0.0638	0.0772	0.1	1
**0.06718	0.0855	0.0413	0.0416	0.0744	0.0931		
0.08176	0.0769	0.0897	0.0765	0.0815	0.0842	0.2	2
0.09928	0.0997	0.1041	0.0844	0.1039	0.1043		
0.07868	0.0687	0.0952	0.0959	0.0966	0.037	0.3	3
0.09888	0.0979	0.1362	0.1078	0.1062	0.0463		
0.06048	0.0698	0.0528	0.0454	0.0571	0.0773	0.4	4
0.07626	0.0854	0.0605	0.058	0.0814	0.096		
0.07563	0.0673	0.0934	0.0775	0.0654	0.0745	0.5	5
0.0962	0.086	0.1233	0.0927	0.0765	0.1025		

Average Error	مجموعات التدريب					معدل التعلم	رقم التصميم
	G5	G4	G3	G2	G1		
0.07958 0.0935	0.0678 0.0755	0.1045 0.1256	0.0971 0.1129	0.0678 0.0853	0.0607 0.0682	0.6	6
0.0709 0.0853	0.0688 0.0897	0.0921 0.1105	0.051 0.061	0.0908 0.1054	0.0518 0.0599	0.7	7
0.08198 0.10342	0.0881 0.1162	0.0724 0.0814	0.0904 0.1123	0.0816 0.1153	0.0774 0.0919	0.8	8
0.08624 0.1077	0.0887 0.112	0.0913 0.1083	0.1019 0.1173	0.0688 0.0914	0.0805 0.1096	0.9	9
0.08024 0.09808	0.0802 0.0914	0.1005 0.1407	0.0696 0.0735	0.0846 0.1049	0.0663 0.0799	1	10

حيث يدل الرقم العلوي في كل خلية من الجدول إلى متوسط مقدار الخطأ أي Average Error. والذي يعطى بالعلاقة :

$$\text{Error \%} = \frac{|X_a - X_d|}{X_d} \cdot 100$$

حيث إن:

X_a : الخرج المحسوب من تطبيق حسابات الشبكة العصبية.

X_d : الخرج الحقيقي والمقدم للشبكة من العينات (دخل، خرج) .

أما الرقم السفلي فيدل على قيمة الانحراف المعياري للخطأ والذي يعطى بالعلاقة :

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n \sum_{j=1}^m (X_{di} - X_{aj})^2}{n}}$$

أما قيم العمود الأخير فهي عبارة عن المتوسط الحسابي لقيم مجموعات التدريب الخمس لكل معمارية. وبالطريقة نفسها درست كافة الحالات المختلفة لمعمارية الشبكة أولاً من أجل طبقة خفية واحدة حيث تم تغيير عدد الوحدات ضمن الطبقة الخفية ابتداء بـ 8 وحدات ولغاية 20 وحدة. وكذلك قيم معدل التعلم Learning Rate وذلك من أجل كل مجموعة من مجموعات التدريب الخمس، ومن ثم تم اختيار الحل الأمثل بالنسبة لتلك المتغيرات.

ويوضح الجدول (3) الخطأ المتوسط وقيمة الانحراف المعياري للخطأ، لكافة الحالات المدروسة لمعمارية الشبكة المكونة من طبقة خفية واحدة وذلك من أجل عدد وحدات مختلفة للطبقة، وباعتبار معدلات تعلم مختلفة بين 0.1 و 1 حيث أن كل خلية في الجدول تعرض المتوسط الحسابي للخطأ المتوسط والانحراف المعياري للخطأ

للمجموعات الخمسة والمدرية بطريقة مشابهة للحالة المدروسة الموضحة بالجدول (2)، كما يظهر السطر الأول للمعماريات المختلفة للشبكة أي عدد الوحدات في كل من طبقة الدخل، الطبقة الخفية وطبقة الخرج. الجدول (3) قيم الخطأ الناتج عن اختبار مختلف الحالات المدروسة لمعمارية الشبكة المكونة من طبقة خفية واحدة ومعدلات تعلم مختلفة.

معماريات الشبكة المختلفة							معدل التعلم	رقم التصميم
14,20,1	14,18,1	14,16,1	14,14,1	14,12,1	14,10,1	14,8,1		
0.0759 0.0928	0.0644 0.0845	0.075 0.0915	0.0636 0.0774	0.068 0.0813	0.0716 0.087	0.0563 0.0672	0.1	1
0.0824 0.0966	0.067 0.0791	0.0749 0.0887	0.0680 2 0.0810	0.0672 0.0802	0.0697 0.0822	0.0818 0.0993	0.2	2
0.09 0.1048	0.0841 0.0987	0.0887 0.1005	0.0885 0.1046	0.0791 0.097	0.0813 0.0945	0.0788 0.0989	0.3	3
0.0897 0.1084	0.0917 0.1128	0.0708 0.089	0.0834 0.0974	0.0785 0.0977	0.0787 0.0951	0.0605 0.0763	0.4	4
0.0758 0.0883	0.0785 0.1017	0.0865 0.1049	0.0804 2 0.0958	0.0829 0.1023	0.0762 0.0922	0.0756 0.0962	0.5	5
0.0986 0.1183	0.0849 0.1029	0.0807 0.1015	0.0716 0.0872	0.0862 0.1016	0.0914 0.1037	0.0796 0.0935	0.6	6
0.0836 0.1012	0.0753 0.0971	0.0815 0.0986	0.0826 0.1063	0.07 0.0837	0.0603 0.0748	0.0709 0.0853	0.7	7
0.0868 0.1062	0.0854 0.1013	0.0795 0.0889	0.0873 0.1072	0.089 0.1023	0.0765 0.0957	0.082 0.1034	0.8	8
0.0777 0.0938	0.0814 0.0991	0.0876 0.1014	0.0967 0.1135	0.0817 0.101	0.0877 0.1043	0.0862 0.1077	0.9	9
0.0844 0.1076	0.0736 0.089	0.0799 0.0928	0.0901 0.1123	0.0761 0.0932	0.075 0.0978	0.0802 0.0981	1	10
0.0758 0.0883	0.0644 0.0845	0.0708 0.0890	0.0636 0.0774	0.0672 0.0802	0.0603 0.0748	0.0563 0.0672		MIN

وقد تمت زيادة عدد الطبقات الخفية إلى طبقتين خفيتين وعولجت المجموعات الخمسة بنفس الخطوات السابقة من حيث تغيير عدد الوحدات ضمن كل من الطبقات الخفية ابتداء من 8 وحدات إلى 20 وحدة ومعدل التعلم ابتداء من القيمة 0.1 ولغاية 1 وورثت القيم الناتجة في الجدول (4).

الجدول (4) قيم الأخطاء الناتجة عن اختبار مختلف الحالات المدروسة لمعمارية الشبكة المكونة من طبقتين خفيتين.

معماريات الشبكة المختلفة							معدل التعلم	رقم التصميم
MIN	14,20,20,1	14,18,18,1	14,16,16,1	14,14,14,1	14,12,12,1	14,10,10,1		

0.0611 0.0741	0.0735 0.092	0.0756 0.0875	0.0632 0.0744	0.0814 0.0971	0.0699 0.0848	0.0702 0.0849	0.0611 0.0741	0.1	1
0.0654 0.0773	0.0763 0.0914	0.0807 0.0987	0.0702 0.0908	0.0747 0.0891	0.0685 0.0898	0.0654 0.0773	0.0663 0.0815	0.2	2
0.0636 0.0845	0.0806 0.0948	0.0636 0.0845	0.0741 0.0882	0.0749 0.0923	0.0697 0.0858	0.0753 0.0901	0.078 0.091	0.3	3
0.0629 0.0769	0.064 0.0757	0.0711 0.0873	0.0738 0.0942	0.0828 0.0976	0.0772 0.0905	0.0629 0.0769	0.0678 0.0921	0.4	4
0.0581 0.0735	0.0742 0.0887	0.0581 0.0735	0.067 0.0815	0.0636 0.0788	0.0786 0.0907	0.0699 0.0869	0.0815 0.0987	0.5	5
0.055 0.0635	0.055 0.0635	0.0688 0.0863	0.0746 0.0977	0.0622 0.0808	0.0649 0.082	0.0708 0.0869	0.0730 0.0929	0.6	6
0.0584 0.073	0.0584 0.073	0.0625 0.0791	0.0594 0.0782	0.0669 0.082	0.0664 0.0851	0.0624 0.0758	0.0599 0.0723	0.7	7
0.0525 0.0659	0.0618 0.0778	0.0695 0.0835	0.0709 0.0872	0.0588 0.0744	0.0602 0.0794	0.0525 0.0659	0.0657 0.0816	0.8	8
0.0539 0.0661	0.05786 0.0731	0.0603 0.0736	0.0539 0.0661	0.0607 0.0723	0.0619 0.0782	0.0726 0.0911	0.0608 0.0767	0.9	9
0.0578 0.0704	0.0578 0.0704	0.0623 0.0749	0.0603 0.0751	0.0595 0.0746	0.0642 0.0849	0.0641 0.0823	0.0653 0.0874	1	10
0.0525 0.0659	0.055 0.0635	0.0581 0.0735	0.0539 0.0661	0.0588 0.0744	0.0602 0.0794	0.0525 0.0659	0.0599 0.0723		MIN

ومن خلال نتائج التدريب الموضحة في الجدول (3) و(4) لوحظ أن الشبكة العصبية تعطي خطأ اصغرياً من أجل المعمارية التالية:

- عدد وحدات طبقة الدخل أربع عشرة وحدة.
- عدد وحدات طبقة الخرج هي وحدة فقط تعبر عن نسبة التنزيل المثلى.
- عدد الطبقات الخفية هما طبقتان فقط.
- عدد الوحدات أو العصبونات في كل طبقة خفية هو عشر وحدات.
- معدل التعلم 0.8 .
- تابع التنشيط المستخدم هو تابع سيجمويد Sigmoid .

وبعد اختيار الشبكة العصبية المثلى السابقة، أعيدت عملية تدريب الهيكلية المقترحة على العينة الكلية المكونة من /100/ مشروعا وتم استبعاد /18/ ثمانية عشر مشروع بشكل عشوائي لإجراء عملية الاختبار، فكانت الشبكة المثلى توافق الدورة أو رقم Run 10320 بخطأ متوسط Average Error يساوي % 1.61 وانحراف معياري RMSE يساوي % 2.17.

التحقق من النموذج المقترح:

تم اختبار الشبكة النهائية المثلى والموافقة للدورة رقم 10320 على العينات الثمانية عشرة والتي استبعدت من أجل الاختبار وذلك لمعرفة مدى تطابق القيم الحقيقية والنتائج المحسوبة من الشبكة وكانت النتائج موضحة بالجدول التالي.

الجدول (5) نسب التنزيل الحقيقية ونسب التنزيل الناتجة عن استثمار الشبكة

رقم المشروع	اسم المدرسة	نسبة التنزيل الحقيقية	نسبة التنزيل الناتجة عن الشبكة	رقم المشروع	اسم المدرسة	نسبة التنزيل الحقيقية	نسبة التنزيل الناتجة عن الشبكة
1	مشروع عاشر 1	20.5	20.323	10	عين العروس	16.3	16.098
2	الكوم	15.9	15.16	11	ظاهرية	20.8	20.115
3	زراعة 2	16.51	16.571	12	زينو	3	3.0412
4	برج إسلام	19.1	18.239	13	استرية	18.3	18.571
5	بقليون	20	20.34	14	جورة الماء	27.6	27.52
6	دير حنا	16.69	16.24	15	برنة	23.1	23.195
7	طويشرة	14.78	14.737	16	الحارة	23.6	23.486
8	خشخاشة 2	21.2	21.095	17	طارقية	22.5	22.182
9	العافقي	23.6	23.278	18	القاقعية	23.6	22.871

وقد تم حساب معامل الارتباط r بين نسب التنزيل الحقيقية ونسب التنزيل الناتجة عن الشبكة وذلك لمعرفة قوة العلاقة بينهما، إن قيمة r تأخذ القيم ضمن المجال $[0, 1]$ وكلما اقتربت العلاقة من الواحد كانت العلاقة قوية، وتعطى علاقة الارتباط بالشكل:

$$r = \frac{n\sum XY - \sum X \sum Y}{\sqrt{(n\sum X^2 - (\sum X)^2)(n\sum Y^2 - (\sum Y)^2)}}$$

حيث X تعبر عن نسبة التنزيل الحقيقية.

Y تعبر عن نسبة التنزيل الناتج عن الشبكة.


وبعد التعويض بالعلاقة السابقة وجد أن معامل الارتباط $r = 0.99780$ وبالتالي $r^2 = 0.9956$

ونلاحظ أن قيمة معامل الارتباط قريبة جداً من الواحد وهذا يعبر عن قوة العلاقة بين القيم الحقيقية

والناتجة.

كما يوضح الشكل (4) مقارنة بين نسب التنزيل الحقيقية ونسب التنزيل الناتجة عن الشبكة ويمكن بسهولة

ملاحظة مدى تطابق كلا المنحنيين.



الشكل (4) نسب التنزيل الحقيقية ونسب التنزيل الناتجة عن الشبكة.

حيث تعبر السلسلة 1 عن نسب التنزيل الحقيقية، أما السلسلة 2 فتعبر عن نسب التنزيل الناتجة عن الشبكة

استثمار النموذج لحل المشكلة:

بعد أن تم تدريب الشبكة واختبارها أصبح بالإمكان وضع هذه الشبكة ذات الأوزان الموافقة لأقل كمية خطأ

قيد الاستثمار وذلك بعدة طرق منها :

1. استثمار الشبكة من قبل المقاولين وذلك من أجل تحديد نسبة الضم أو التنزيل التي تزيد من فرصة حصولهم على العطاء مع ضمان هامش جيد للربح، وذلك بإدخال بيانات العوامل التي تحيط بالمشروع الجديد، وفي هذه الحالة تعمل الشبكة باتجاه واحد لينتج عنها مباشرة النسبة المثلى للضم أو التنزيل والتي يجب أن يتقدم بها المقاول للعطاء.
2. يمكن الاستفادة من الشبكة الناتجة عن تحليل الحساسية لمعرفة تأثير تغير قيمة عامل ما من الإدخالات على الخرج النهائي وذلك بتغيير قيمة هذا العامل فقط ومراقبة الخرج الناتج. إن معرفة العوامل التي تؤثر بشكل كبير على نسبة الخرج تدعو للاهتمام بها ومعالجة المشاكل التي تتعلق بها وذلك لتحسين نسبة التنزيل أو الضم هذه.

الاقتراحات والتوصيات:

تقدم هذه الورقة البحثية محاولة للاستفادة من تقنية الشبكات العصبية في حل مشكلة من مشاكل اتخاذ القرار الهندسي حيث تم تطبيق نموذج شبكة عصبية تساعد المقاولين في تحسين فرصة الفوز بالعطاءات وذلك من خلال تحديد نسبة التنزيل أو الضم التي يجب أن يتقدم بها للعطاء والتي تزيد فرصة حصوله على المناقصة مع ضمان أفضل هامش جيد للربح، وقد اختيرت العطاءات الخاصة بمشاريع تنفيذ المدارس وذلك لانتشار هذا النوع من المشاريع في الجمهورية العربية السورية. ولقد وضعت الشبكة المدربة والمختبرة قيد الاستثمار وأعطت نتائج دقيقة يمكن زيادتها من خلال معالجة مختلف العوامل المؤثرة على نسبة الضم أو التنزيل كزيادة دقة المخمن عن طرق تأهيل كادر يستخدم الحاسب في وضع الدراسة وكذلك عدم البدء بأي مشروع مالم تتم دراسته من الناحية القانونية... الخ. كما ينصح باستخدام نموذج الشبكات العصبية الصناعية في مختلف مجالات الهندسة المدنية التي تتطلب مقدارا كبيرا من الدقة وليتم ذلك يجب إجراء عملية توثيق لجميع المشاريع الهندسية المنجزة في القطر بغية الاستفادة من تلك البيانات في تطوير الاستخدام المستقبلي للشبكات العصبية.

المراجع:

1. BENJAMINE, N. B. H. R C 1972 - competitive bidding the Probability of wining. Journal of the Construction division, ASCE, 1998. pp.313-330.

2. BENJAMINE, N. B. H. and MEADOR, R C 1979 - comparison of Friedman's and Gates's competitive bidding models. Journal of the Construction division, ASCE, 105(CO1). pp.25-40.
3. CALIFORNIA SCIENTIFIC SOFTWARE, 1994- Getting Started With Brainmaker. Nevada city, CA.
4. DOZZI, A. R. and SCHROEDER, 1995 – Utility Theory model for bid markup decisions. Journal of Construction Engineering and Management, ASCE, VOL.122, NO.2. pp119-124.
5. FAYEK, A. 1998 - competitive bidding strategy model and software system for bid preparation. Journal of the Construction Management, ASCE, VOL.124, NO.1, pp. 1-9.
6. FREEMAN, J. A. and. SKAPURA, D. M, 1992– Neural networks, Algorithms, Applications, and Programming Techniques "
7. FRIEDMAN, L. 1956 - competitive bidding strategy. Operation Research 1(4), pp 104-112.
8. GARRETT, J. H, GUNARATNAM, D. J, AND IVENZIE, N. 1997 -Introduction To Neural Networks. Published In the ASCE Second Monograph on Application of Artificial Neural Networks In Civil Engineers.
9. GATES, M. 1967 - Bidding strategy and probabilities. Journal of the Construction division, ASCE, 93 (CO1), pp 75-107.
10. McCAFFER, R and Pettitt, A. N, 1976 - Distribution of bids for buildings and road contracts. Operational Research Quarterly 27(4I), pp 835-843.
11. Seydel, J. and Olson, D. L. 1990 - Bids Considering Multiple Criteria. Journal of the Construction Engineering and Management, ASCE, 116, NO.4, pp 609-623.
12. Twomey. J. M, and Smith. A. E. 1997 “ Validation and Verification “Artificial Neural Networks For Civil Engineering: Fundamentals and Applications, ASCE.
13. عيسى، علام زكي. 2000 - الشبكات العصبية الصناعية، البنية الهندسية، الخوارزميات، التطبيقات، دار شعاع.