

استخدام الشبكات العصبية الاصطناعية في تخمين انتاجية تغليف واجهات المباني بالحجر

د فائق محمد سرحان الزويني
كلية الهندسة- قسم الهندسة المدنية
جامعة النهريين

الخلاصة

ان الهدف الرئيسي من هذا البحث هو استخدام اسلوب جديد يعرف بالشبكات العصبية الاصطناعية لتخمين انتاجية فقرة تغليف واجهات المباني بالحجر. ان الاساليب والتقنيات الحالية المستخدمة في تخمين الانتاجية في العراق تعتبر ضعيفة وغير كفوة اضافه الى ذلك هناك حاجة الى اعتماد تقنيات متطورة وجديده لتخمين الانتاجية تتسم بالسرعه والدقه والمرونة بالاستخدام. ان تطبيق الشبكات العصبية الاصطناعية كتقنيه جديده في قطع التشييد في العراق ظروري جدا لضمان نجاح ادارة المشروع. نموذج واحد بني للتنبؤ بالانتاجية الكلية لمشاريع المباني, في هذا العمل تم استخدام الشبكات متعددة الطبقات بتقنية الانتشار الرجعي للخطأ لنمذجة عملية تخمين الانتاجية وقد تم دراسة العديد من الحالات التي لها علاقه ببناء الشبكات العصبية الاصطناعية منها معمارية الشبكة والعوامل الداخلية لها ومدى تأثيرها على اداء نماذج الشبكات العصبية الاصطناعية ومن معلومات الشبكات تم استنباط معلومات حول الاهمية النسبية للعوامل المؤثرة على الانتاجية الانشائية ووضعت معادلات لحساب تلك الانتاجية. لقد وجد بان هذه الشبكات لها القابليه على التنبؤ بالانتاجية الكلية لتغليف واجهات المباني بالحجر الطرق بدرجة جيدة جدامن الدقة (94.6%) و بلغت معاملات الحسابات (R) (93.2%). واطهر هذا النموذج بانه غير حساس نسبيا لعدد العقد في الطبقة المخفيه والحد الكمي ومعدل التعلم وحجم الخطوة

مفاتيح الكلمات: تخمين الانتاجية، الشبكات العصبية الاصطناعية، مشاريع المباني

The Use of Artificial Neural Networks for Productivity Estimation of finishing Stone works for Building Projects

Abstract

The main objective of this research is to introduce a new and alternative approach of using a neural network for productivity estimation of the finishing works for building project. The application of Artificial Neural Networks, as a modern technique, in Iraqi construction industry is necessary to ensure successful management, and many of the construction companies feel the need of such system in project management. Multi-layer perceptron trainings using the back-propagation algorithm were used. In this work, the feasibility of ANNs technique for modeling these productivity parameters was investigated. A number of issues in relation to ANNs construction such as the effect of

ANNs geometry and internal parameters on the performance of ANNs models were investigated. Information on the relative importance of the factors affecting the above productivity parameters predictions were presented and practical equations for the predictions of the above cost were developed.

One model was built for the prediction the total productivity of building project. It was found that ANNs have the ability to predict the Total productivity for finishing works for building project with a good degree of accuracy of the coefficient of correlation (R) was 93.2%, and average accuracy percentage of 96.4%.The ANNs model developed to study the impact of the internal network parameters on model performance indicated that ANNs performance was relatively insensitive to the number of hidden layer nodes, momentum term, and learning rate.

Keyword: productivity estimate, building project, artificial neural network

المقدمة

تنتشر في جسم الإنسان ملايين الخلايا العصبية والتي تتفرع بدورها إلى الملايين من الزوائد العصبية، حيث تنقل هذه الخلايا العصبية الإحساس و ردّات الفعل من و إلى العقل البشري بواسطة الحبل الشوكي. ومن خلال هذه الخلايا العصبية يتم تخزين المعرفة عن العالم الخارجي في العقل البشري، وذلك عن طريق ضبط الأوزان داخل هذه الخلايا. ففكر العلماء في طريقة يستطيعون من خلالها محاكاة هذه العملية التي تحدث في العقل البشري، وتوصلوا إلى علم الشبكات العصبية Neural Network والذي يندرج تحت علوم الذكاء الاصطناعي، بحيث يجعلون من أجهزة الحاسوب أجهزة ذكية، بإمكانها أن تكتسب المعرفة بنفس الطريقة التي يكتسب بها الإنسان المعرفة، وهي طريقة ضبط الأوزان أثناء التعلم. في هذا البحث، جرى استخدام الشبكات العصبية الاصطناعية في محاولة لإيجاد نموذج لحساب انتاجية فقرة التغليف بالحجر لواجهات المباني .

هدف البحث

تحتل القوى العاملة أهمية كبيرة في جميع مجالات العمل لأنها تعد الاداة الكفوة لاي عملية تطويرية اذا احسن استخدامها وتوفر لها المناخ العملي المناسب. وفي قطاع التشييد تبرز هذه الاهمية اكثر لان العامل البشري يطغى على باقي العوامل المؤثرة في العملية الانتاجية لكون الكثير من فقرات العمل في هذا القطاع تعتمد على العنصر البشري ويبقى دور المكنات والمعدات محدوداً نوعاً ما.

يهدف هذا البحث الى ابراز اهمية استخدام التقنيات الحديثة ومن اهمها الشبكات العصبية الاصطناعية الذكية في تخمين انتاجية فريق عمل تغليف جدران المباني الخارجية (الواجهات) بالحجر وذلك من خلال:

- (1) تحديد العوامل المؤثرة على انتاجية فقرة تغليف الجدران المباني .
- (2) بناء نموذج حاسوبي للتنبأ او لتخمين انتاجية فقرة تغليف جدران المباني بالحجر .
- (3) توثيق معدلات الانتاجية المختلفة والعوامل المؤثرة على فقرة تغليف جدران المباني بالحجر للمشاريع المنفذة سابقاً من خلال خزن واستعادة البيانات وتحديثها دورياً من خلال النموذج المطور في الفقرة (2)
- (4) ايجاد معادلة رياضية لحساب الانتاجية القياسية لفقرة التغليف بالحجر .

مبررات البحث

يمكن إيجاز مبررات البحث بما يأتي:

- (1) ان تطبيق الشبكات العصبية الاصطناعية كتقنية حديثة في قطاع التشييد في العراق اصبح ضرورة ملحة لضمان نجاح العملية الادارية للمشاريع الانشائية اضافة الى مواكبة التطور التكنولوجي العالمي والذي تحتاجه معظم الشركات الانشائية في العراق.
- (2) قلة الدراسات المحلية والعالمية حول موضوع تخمين انتاجية فقرات اعمال الانهاءات في المشاريع الانشائية باستخدام الشبكات العصبية الاصطناعية .
- (3) هناك ضعف واضح في تخمين انتاجية فقرات الاعمال الانشائية في قطاع التشييد في العراق عموماً، بسبب استعمال وسائل قديمة تعاني من ضعف في الدقة والسرعه وعدم الموثوقيه.
- (4) غياب التوثيق لمعدلات الانتاجية الحقيقية للمشاريع الانشائية المنجزة سابقاً.

فرضيات البحث

استنادا الى المبررات المذكورة انفا أمكن صياغة فرضية البحث الآتية:

(الشركات الانشائية في العراق بحاجة الى استخدام وسائل وتقنيات حديثة متطورة لغرض تخمين الانتاجية في المشاريع الانشائية بالاعتماد على معادلات رياضية ذات درجة دقة عالية وتمتاز بسهولة الاستخدام).

الدراسات السابقة

ان الدراسات والبحوث المتعلقة بموضوع انتاجية الايدي العاملة في قطاع التشييد في العراق تعتبر قليلة نوعاً ما وخاصة في حساب انتاجية اعمال الانهاءات وقد تيسر للباحث الاطلاع على عدد من هذه البحوث [(الطويل و حداد،1989) (سعيد،1990) (طاهر،1995) (عيدان،1996)]. ويرى الباحث بان الغالبية العظمى من هذه البحوث كانت تتباين في حساب الانتاجية المخمّنة وذلك لكون عامل التخمين يعتمد على الخبرة الشخصية او من المشاريع السابقة كما ان المهندس الذي يقوم بالتخمين لا يعتمد على معادلة رياضية ذات دقة عالية في حساب الانتاجية . ولم تتطرق الدراسات والبحوث المحلية الى موضوع حساب الانتاجية لفقرات الانهاءات باستخدام الشبكات العصبية الاصطناعية الذكية على حد علم الباحث. فيما عدا محاولتان من قبل الباحثين (AL-Zwainy,2008) و (Baker,2011) والذي كان موضوع بحثيهما عن تخمين كلف الطرق وتخمين انتاجية فقرة البناء بالطابوق على التوالي.

اما بالنسبة للدراسات والبحوث العربية والاجنبية، فقد اطلع الباحث على عدد منها وخاصة تلك البحوث التي تستند في حساب الانتاجية الانشائية لفقرات العمل المختلفة بالاعتماد على تقنية الشبكات العصبية الاصطناعية الذكية (Ezeldin and Sharara,2006) (Ming at el ,2000) (Tam at el,2002) (Jason and Simaan,1997) (Li and Miroslaw,1994) ولكن اياً من هذه البحوث لم يتطرق الى موضوع تخمين انتاجية فقرة تغليف الجدران بالحجر وانما كانت تقتصر في حساب انتاجية الهياكل الخرسانية والخرسانة الجاهزة وحساب انتاجية المعدات الانشائية، ولهذا يعتبر هذا البحث محاولة من قبل الباحث للولوج في هكذا نوع من البحوث لحساب الانتاجية الانشائية بالاعتماد على الشبكات العصبية الاصطناعية .

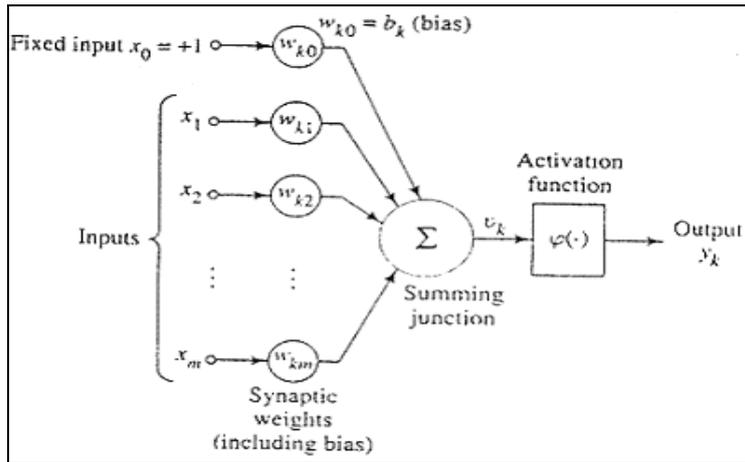
الشبكات العصبية الاصطناعية (Artificial Neural Networks(ANN)

هي تقنيات حسابية مصممة لمحاكاة الطريقة التي يؤدي بها الدماغ البشري مهمة معينة، وذلك عن طريق معالجة ضخمة موزعة على التوازي، ومكونة من وحدات معالجة بسيطة، هذه الوحدات ما هي إلا عناصر حسابية تسمى عصبونات أو عقد (Nodes , Neurons) والتي لها خاصية عصبية، من حيث أنها تقوم بتخزين المعرفة العملية والمعلومات التجريبية لتجعلها متاحة للمستخدم وذلك عن طريق ضبط الأوزان (Al-Zwainy,2008)

إذاً الشبكات العصبية الاصطناعية (ANN) تتشابه مع الدماغ البشري في أنها تكتسب المعرفة بالتدريب وتخزن هذه المعرفة باستخدام قوى وصل داخل العصبونات تسمى الأوزان التشابكية. وهناك أيضا تشابه عصبي حيوي مما يعطي الفرصة لعلماء البيولوجيا في الاعتماد على ANN لفهم تطور الظواهر الحيوية.

وصف عام لآلية عمل العصبون الاصطناعي

بشكل عام يمكن القول أن كل شبكة عصبونية ترتب بشكل طبقات من العصبونات الاصطناعية بالطبقة الاولى تسمى طبقة ادخال و الطبقة الاخيرة تسمى طبقة اخراج و طبقات مخفية تتواجد بين طبقتي الادخال و طبقة الاخراج .



الشكل (1) نموذج لعصبون اصطناعي. (Haykin, 1990)

الشكل (1) يبين كل عصبون في احدى هذه الطبقات يتصل بكافة العصبونات الموجودة في الطبقة التي تليه و كافة العصبونات في الطبقة التي تسبقه , حيث ترده الإشارات أو القيم من عصبونات الطبقة السابقة ليقوم بمعالجتها و إعطاء قيمة خرج وحيدة تنتقل إلى كافة عصبونات الطبقة التي تلي طبقته . كل عصبون اذا يتلقى عدة قيم دخل Input و يعطي قيمة خرج وحيدة Output . ترتبط العصبونات أحيانا بدخل ثابت يدخل في كل عملية معالجة و لا علاقة له بمدخلات الشبكة يدعى الانحياز bias (Haykin,1990)

طريقة معالجة المعلومات

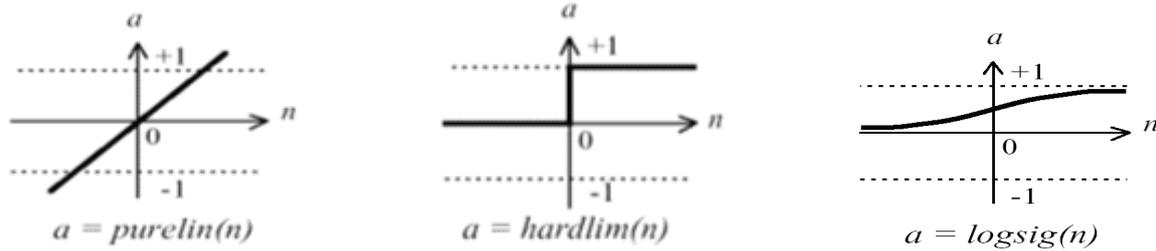
كل اتصال بين عصبون و آخر يتميز بارتباطه بقيمة تدعى الوزن، وهي تشكل مدى أهمية الارتباط بين هذين العصبونين , يقوم العصبون بضرب كل قيمة ادخال وارده من عصبونات الطبقة السابقة بأوزان الاتصالات مع هذه العصبونات , من ثم جمع نواتج الضرب جميعا , ثم إخضاع النتيجة لتابع تحويل transfer function او تابع تفعيل activation function ويختلف حسب نوع العصبون , ناتج تابع التحويل يعتبر خرج العصبون الذي ينقل إلى عصبونات الموجودة الطبقة اللاحقة. (Fausett, 1994)

دالة (توابع) التحويل

توجد عدة انواع من توابع التفعيل او توابع التحويل، من اهمها (Shahin, 2003) :

- (1) تابع العتبة أو تابع الخطوة: يحد هذا التابع من خرج العصبون بحيث يصبح الخرج مساويا للواحد إذا كان الدخل أكبر أو مساويا للواحد ويصبح الخرج مساويا للصفر إذا كان الدخل أصغر من الصفر. وكما مبين في الشكل (2-أ).
- (2) التابع الخطوي الخطي أو تابع التتابع (Tanh): يستخدم هذا التابع في العصبونات المستخدمة في المرشحات التلاؤمية الخطية . وكما مبين في الشكل (2-ب).
- (3) التابع الأسّي (Sigmoid): الشكل (2-ج) يبين التابع الاسي اذ يأخذ هذا التابع قيم الدخل المحصورة بين $-\infty$ و ∞ + ويجعل الخرج محصورا بين 0 و 1 ... وهو أكثر التوابع استخداما بسبب سهولة اشتقاقه وكثرة أنواعه .

ويرى الباحث بحكم تخصصه بهذا المجال ان أبسط توابع التحويل هو تابع قيمة العتبة الذي يعمل العصبون على أساسه ، معطيا قيمة 1 إذا كان المجموع الموزون لقيم الداخلي أكبر من قيمة معينة تدعى العتبة و 0 إذا كان المجموع الموزون اقل من العتبة . لكن أهمها هو تابع السيجمويد (التابع الأسّي) , لأنه يؤمن اللاخطية في حسابات الشبكة العصبونية عن طريق تحويل قيمة تفعيل النيورون ضمن المجال $[0,1]$. إضافة لذلك فهو يؤمن ميزة اضافية تتلخص في بساطة تابعه المشتق المطلوب في خوارزمية الانتشار الخلفي back-propagation للأخطاء و هي احدى خوارزميات التعليم المراقب المستخدمة في الشبكات أمامية التغذية .



الشكل (2) انواع توابع التحويل (Shahin, 2003)

أنواع الشبكات العصبونية

للشبكات العصبونية عدة أنواع من أهمها البيرسيترون و شبكات كوهونين ذاتية التنظيم و شبكات عصبونية أمامية التغذية (Zurada, 1996). Feed-forward Neural networks في هذا البحث تم استخدام شبكات عصبونية أمامية التغذية خلفية النقل (Back-propagation Feed-forward Neural networks). وذلك لأنها من أهم أنواع الشبكات العصبونية وهي مجموعة عقد عصبونية مرتبة بشكل طبقات. ترتبط هذه العصبونات مع بعضها عادة بحيث يرتبط كل عصبون في طبقة ما بجميع العصبونات في الطبقة التالية (ولا ترتبط عصبونات نفس الطبقة مع بعضها البعض الآخر). وان الشكل النموذجي لهذه الشبكات هو ثلاث طبقات عصبونية على الأقل تدعى (طبقة ادخال input layer, وطبقة مخفية hidden layer, وطبقة اخراج output layer). فطبقة الدخل لا تقوم بأي عملية معالجة فهي ببساطة مكان تغذية الشبكة بشعاع البيانات, تقوم طبقة الدخل بعد ذلك بتغذية (نقل المعلومات) الطبقة المخفية و من ثم تقوم الطبقة المخفية بتغذية طبقة الخرج. المعالجة الفعلية للبيانات Data تتم في الطبقة المخفية و طبقة الخرج أساسا. وعندما يكون هناك عدد كاف من العصبونات في كل طبقة, تكون الشبكة قادرة على التدريب training للقيام بأشياء مفيدة بالاستعانة بخوارزميات التدريب algorithm training, تعتبر الشبكات أمامية التغذية مهمة جدا خاصة في استخدامات التصنيف الذكي و التمييز الذكي لبيانات غير مألوفة مسبقا

طرق تعليم الشبكة العصبونية

ان الشبكات العصبونية لا تبرمج بل إنها تقوم بالتعلم. اذ تتعلم الشبكة عن طريق إعطائها مجموعة من الأمثلة، التي يجب أن تكون مختارة بعناية، لأن ذلك سيساهم في سرعة تعلم الشبكة. ومجموعة الأمثلة هذه تسمى فئة التدريب. وتنقسم طرق تعليم شبكة عصبونية إلى قسمين حسب فئة التدريب التي تعرض على الشبكة وهما (Master, 1993):

1) التعليم المراقب (بواسطة معلم) Supervised Learning of ANN's

تقوم كل طرق التعليم أو التدريب بواسطة معلم للشبكات العصبونية الاصطناعية على فكرة عرض البيانات التدريبية أمام الشبكة على هيئة زوج من الأشكال وهما الشكل المدخل input والشكل المستهدف target وهذا ما تم اتباعه في هذا البحث.

2) التعليم غير المراقب (بدون معلم) Unsupervised learning

في هذه الطريقة تكون فئة التدريب عبارة عن متجه المدخلات فقط دون عرض الهدف على الشبكة، وتسمى هذه الطريقة التعليم الذاتي حيث تبني الشبكات العصبونية الاصطناعية أساليب التعليم على أساس قدرتها على اكتشاف الصفات المميزة لما يعرض عليها من أشكال وأنساق وقدرتها على تطوير تمثيل داخلي لهذه الأشكال وذلك دون معرفة مسبقة وبدون عرض أمثلة لما يجب عليها أن تنتجه وذلك على عكس المبدأ المتبع في أسلوب التعليم بواسطة معلم.

الدراسة العملية

تضمن الجانب العملي من هذا البحث، ثلاث مراحل مهمة هي:

- 1) المرحلة الاولى:- تحديد العوامل المؤثرة في حساب انتاجية اعمال تغليف جدران المباني بالحجر
- 2) المرحلة الثانية:- بناء نموذج شبكة عصبونية اصطناعية لتخمين انتاجية اعمال تغليف جدران المباني بالحجر
- 3) المرحلة الثالثة:- اشتقاق معادلة رياضية لتخمين انتاجية اعمال تغليف جدران المباني بالحجر.

تحديد العوامل المؤثرة في حساب انتاجية اعمال تغليف جدران المباني بالحجر

ان تطبيق الشبكات العصبية الاصطناعية في تخمين انتاجية فقرة تغليف جدران المباني بالحجر يتطلب تحديد وبيان العوامل (المتغيرات) المؤثرة على الانتاجية الانشائية. ان هذا البحث يوضح بناء نموذج الشبكات العصبية للتنبؤ بالانتاجية الانشائية للمشاريع المستقبلية بالاعتماد على بيانات ومعلومات لمشاريع منفذه سابقاً في العراق. ان الطريقة المستخدمة في هذا البحث، لغرض جمع البيانات التاريخية للمشاريع المنفذه سابقاً، هي طريقة مباشرة تعتمد على المصادر والمراجع المتعلقة بموضوع الانتاجية الانشائية (عيان، 1996)، وتم الاستفاده من الملحق الموجود في تلك الدراسة كقاعدة بيانات للنموذج الذي تم تطويره في هذا البحث. وتضمنت قاعدة البيانات معلومات تاريخية لـ(132) مشروع انشائي منفذ سابقاً في مناطق مختلفة من العراق كمحافظة بغداد وصلاح الدين وبابل والانبار والبصرة.

في هذا البحث تم تقسيم العوامل (المتغيرات) المؤثرة على الانتاجية الانشائية الى صنفين رئيسيين هما:

- (1) العوامل (المتغيرات) المستقلة Independent Variables
- (2) العوامل (المتغيرات) غير المستقلة (المعتمدة) Dependent Variables

تم في هذا البحث اعتماد الانتاجية الانشائية كمتغير غير مستقل، ويتم حساب قيمته بالاعتماد على المتغيرات المستقلة الاخرى وهي (الخبرة و العمر و عدد العمال و منسوب العمل و الطقس و درجة تعقيد الموقع)، ان طبيعة البيانات التي تتكون منها المتغيرات المستقلة والبالغ عددها ستة متغيرات، يمكن تصنيفها الى صنفين مهمين هما

- (1) المتغيرات الكمية
- (2) المتغيرات النوعية

ان المتغيرات الكمية تتكون من اربع متغيرات هي:

- (1) الخبرة: ويقصد بها عدد سنوات الخبرة لرئيس فريق العمل (الخلفة) لفقرة التغليف بالحجر، وتقاس الخبرة بالعدد (سنة)، وتم الرمز لها في هذا البحث بالرمز (V1).
- (2) العمر: ويقصد به العمر الحقيقي لرئيس فريق العمل (الخلفة) لفقرة التغليف بالحجر، ويقاس العمر بوحدة العدد (سنة)، وتم الرمز له بالرمز (V2).
- (3) عدد العمال: ويقصد به عدد العمال المساعدين لرئيس فريق العمل، ويقاس بوحدة العدد وتم الرمز له بالرمز (V3).
- (4) منسوب العمل: ويقصد به ارتفاع موقع فقرة التغليف بالحجر عن مستوى الارض الطبيعية للمشروع، ويقاس بوحدة (المتر) وتم الرمز له بالرمز (V4).

اما المتغيرات النوعية فقد تكونت من متغيرين فقط هما:

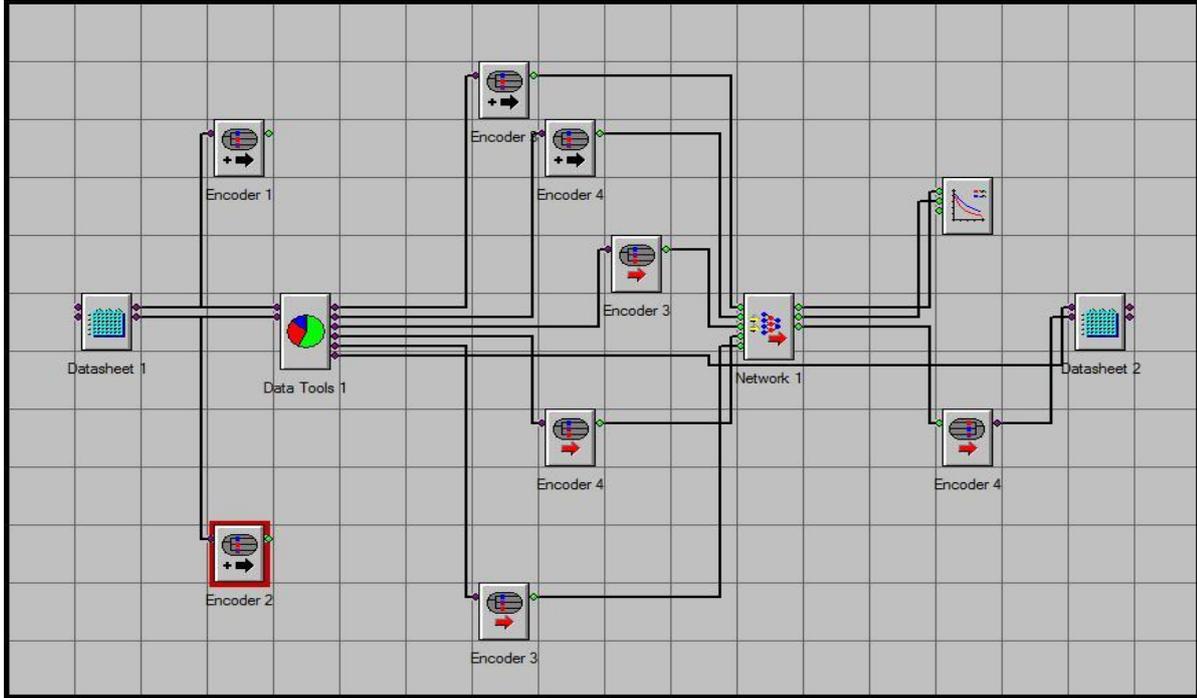
- (1) الطقس: ويقصد به الظروف الجوية المحيطة بموقع العمل، وتم تصنيفها الى صنفين هما (0 و 1) فالصنف (0) يشير الى ان الطقس المعتدل، اما الصنف (1) فيشير الى ان الطقس غائم او غائم ممطر او مترب.
- (2) درجة تعقيد الموقع: ويقصد بها تفاصيل العمل مع وصف لمعوقات العمل والظروف التي تؤثر على كمية الانتاجية، وتم تصنيفها الى صنفين هما (0 و 1) فالصنف (0) يشير الى ان موقع العمل غير معقد اما الصنف (1) فيشير الى ان موقع العمل معقد.

بناء نموذج شبكة عصبية اصطناعية لتخمين انتاجية اعمال تغليف جدران المباني بالحجر

ان المنهجية المستخدمة في بناء نموذج الشبكة العصبية الاصطناعية المطور في هذا البحث تتضمن تطوير مجموعه من النماذج الفرعية، مثل نموذج الادخال (Input Model) ونموذج الاخراج (Output Model) ونموذج تقسيم البيانات

(Data Division Model) ونموذج اختيار معمارية الشبكة العصبية (Network Model) ونموذج ضبط الاوزان (Weight Model), ونموذج معدل التعلم (Learning Rate Model) ونموذج حجم الخطوة (Momentum Term Model) ونموذج التحقق (Validation Model).

تم استخدام برنامج نيوفريم (Neuframe-v.4) وهو عبارة عن برنامج تجاري مكتوب بلغة (C++) ويعتبر هذا البرنامج من تقنيات الذكاء الاصطناعي وسهل الاستعمال في بناء مختلف الشبكات العصبية الاصطناعية. ولقد تم استخدام هذا البرنامج لتوضيح كيفية بناء النماذج الفرعية ابتداءً من نموذج الادخال وانتهاءً بنموذج الاخراج وكما موضح في الشكل (3) ادناه باستثناء نموذج التحقق فقد تم بنائه باستخدام برنامج الحزم الاحصائية للعلوم الاجتماعية (SPSS).



الشكل (3) نموذج الشبكة العصبونية الأمامية التغذية خلفية النقل ،
والتي تم بنائها باستخدام برنامج (Neuframe-v.4)

نموذجي الادخال الاخراج Model Inputs and Outputs

ان عملية اختيار المتغيرات في نموذجي الادخال والخراج تكتسب اهمية كبيرة تساهم في تحسين اداء الشبكة العصبية، اذ ان زيادة عدد متغيرات الادخال والخراج يؤثر تأثيرا كبيرا في زيادة حجم الشبكة العصبونية وبالتالي يؤدي الى انخفاض في سرعة عملية تعلم وبالتالي التأثير في كفاءة الشبكة العصبونية.

توجد عدة طرق لاختيار عدد المتغيرات في نموذجي الادخال والخراج و تم اختيار طريقة المعرفة المسبقة (Method of Prior Knowledge) في هذا البحث، اذ ان هذه الطريقة تستخدم بكثرة في قطاع التشييد ومعتمدة في كثير من الابحاث والدراسات، ويمكن استخدام هذه الطريقة عندما لا تكون هناك معرفة مسبقة عن المتغيرات الادخال وتأثيرها على متغيرات الاخراج، وبالتالي فقد تضمن نموذج الادخال المتغيرات المستقلة بنوعها الكمية والنوعية وهي (الخبرة والعمر ومنسوب العمل والطقس ودرجة تعقيد الموقع)، اما نموذج الاخراج فقد شمل على المتغير غير المستقل وهو (الانتاجية) . ويعتبر هذان النموذجان وسيلة لخرن وتوثيق البيانات للمشاريع السابقة، ويمكن تحديثهما باستمرار.

نموذج تقسيم البيانات Data Division Model

بيانات الإدخال أو الإخراج في الشبكة العصبونية هي اما تكون متغيرات مستمرة أو متغيرات منفصلة، ويتم تقسيم هذه البيانات الى ثلاث مجاميع رئيسية:

- (1) مجموعة التدريب لبناء نموذج الشبكة العصبونية (Training Set).
 - (2) مجموعة اختبار او فحص نموذج الشبكة العصبونية (Testing set).
 - (3) مجموعة تحقيق مستقلة لتخمين اداء النموذج في البيئة المعمول فيها (Validation Set).
- فمجموعة التدريب تستخدم لضبط الأوزان المتصلة في الشبكة العصبونية. وتستخدم مجموعة الفحص للتأكد من أداء للشبكة في مختلف مراحل التعليم، ويتم إيقاف التدريب عندما يزداد الخطأ لمجموعة الفحص. وتستخدم مجموعة التحقق لتقييم اداء النموذج بمجرد اكمال تدريب الشبكة العصبونية بنجاح. لذلك يعتبر تقسيم البيانات الى المجموعات الثلاثة اعلاه، خطوة حاسمة ومهمة في نمذجة الشبكة العصبونية.

في هذا البحث تم استخدام طريقة الثبات الاحصائي (Statistically Consistent Method) لغرض تقسيم البيانات الى المجاميع الثلاث (مجموعة التدريب ومجموعة الفحص ومجموعة التحقيق) وهذه الطريقة تضمن تناسب احصائي للبيانات لكل مجموعة وبالتالي ضمان عدم وجود تحيز في تقسيم البيانات في كل مجموعة باستخدام فحص تي (T-test) من خلال استخدام المعايير الاحصائية وهي الوسط الحسابي والانحراف المعياري والمدى. ومن ايجابيات هذه الطريقة انها تعتمد اسلوب المحاولة والخطأ (trial and error) للوصول الى افضل تقسيم للبيانات .

من خلال الجدول (1) نلاحظ نسبة تقسيم البيانات لمجموعات التدريب والفحص والتحقيق باستخدام اسلوب المحاولة والخطأ، فقد استخدم الباحث نسب مختلفه من البيانات لهذه المجموعات في محاول للحصول على افضل اداء للشبكة العصبونية متمثلاً بالوصول الى اعلى معامل ارتباط (Coefficient correlation) لبيان قوة العلاقة بين مخرجات الشبكة العصبونية (الانتاجية المتنبأ بها) و الانتاجية المقاسة (الحقيقة) وبالتزامن مع اقل نسبة خطأ للفحص (Testing error) ، فهذان المعياران هما المعتمدان في هذا البحث لاختيار افضل تقسيم للبيانات . ومن خلال الجدول (1) يمكن ملاحظة ان افضل تقسيم للبيانات هو 72% لمجموعة التدريب ، 14% لمجموعة الفحص و 14% لمجموعة الفحص بالاعتماد على اقل نسبة خطأ للفحص (4.8%) واكبر معامل ارتباط (91.3%) ولم يتم اختيار التقسيم الاول للبيانات (15%، 5%، 80%) كافضل تقسيم للبيانات على الرغم من ان معامل الارتباط له اكبر ويبلغ (91%) ، الا ان هذا الفرق بين قيمة معاملي الارتباط تعتبر قليلة جدا او غير محسوسة بينما نسبة خطأ الفحص للتقسيم الاول للبيانات تبلغ (9.8%) تعتبر اكبر مقارنة مع التقسيم المختار كافضل تقسيم للبيانات . وهكذا نجد ان افضل اداء للشبكة العصبونية يكون عند تقسيم البيانات الى 72% لمجموعة التدريب و 14% لمجموعة الفحص و 14% لمجموعة التحقيق.

جدول (1): تأثير تقسيم البيانات على اداء نموذج الشبكات العصبية

معامل الارتباط Coefficient correlation(r)%	نسبة خطأ الفحص Testing error%	نسبة خطأ التدريب Training error%	تقسيم البيانات % Data Division		
			مجموعة التحقيق %Querying	مجموعة الفحص %Testing	مجموعة التدريب %Training
91.6	9.8	7.4	15	5	80
91.3	6.4	7.3	15	10	75
91.3	4.8	7.6	14	14	72
89.6	6.4	7.2	17	15	68
93.4	7.4	7.5	14	22	64
88	7.3	7.1	17	23	61
82.4	9.1	6.4	20	20	61
89.5	7.2	7.6	20	11	68
84	7	7.5	11	20	68
88.9	7	7	17	11	72
86.5	7.7	6.8	11	17	72
80	7.1	6.6	9	15	76

ولغرض توزيع البيانات الكلية للمتغيرات والبالغ عددها (132) مشاهدة، على المجاميع الثلاث وهي مجموعة التدريب ومجموعة الفحص ومجموعة التحقيق فان برنامج (Neuframe) المستخدم يوفر طريقة كفوءة لتوزيع البيانات بثلاث اساليب وهي:

- (1) الاسلوب العشوائي random: ففي هذا الاسلوب يقوم البرنامج بتوزيع بيانات المتغيرات بصورة عشوائية على المجاميع الثلاثة وبحسب النسب التي تم الحصول عليها في الجدول (1).
 - (2) الاسلوب الشريطي random: وفي هذا الاسلوب يقوم البرنامج بتقسيم البيانات الكلية الى مجموعات غير محددة من الحزم، وكل حزمة تضم بيانات لكل من مجموعة التدريب ومجموعة الفحص ومجموعة التحقيق، وبعد ذلك يتم جمع بيانات كل مجموعة من كل حزمة وصولاً للنسب التي تم الحصول عليها في الجدول (1).
 - (3) الاسلوب الحزمة المتكاملة blocked: في هذا الاسلوب يتم التعامل مع البيانات الكلية كحزمة واحدة وتقسيم على الترتيب للمجاميع الثلاث، اي ان الـ(73%) الاولى من البيانات تكون لمجموعة التدريب والـ(14%) الثانية تكون لمجموعة الفحص والـ(14%) الثالثة والاخيرة من البيانات تكون لمجموعة التحقيق.
- ومن اجل دراسة تأثير استخدام الخيارات المختلفة للتقسيم (random, blocked, random) تم التحقق منها كما مبين في الجدول (2)، ويمكن ملاحظة ان افضل اداء للشبكة العصبونية هو عند استخدام طريقة التقسيم الشريطي (striped) حيث ان لها اقل خطأ بالنسبة للفحص (4.8%).

جدول(2): تأثير طريقة التقسيم على اداء الشبكة العصبية

معامل الارتباط Coefficient correlation(r)%	نسبة خطأ الفحص Testing error%	نسبة خطأ التدريب Training error%	اسلوب التقسيم Choices of division	تقسيم البيانات % Data Division		
				مجموعة التحقيق Querying %	مجموعة الفحص %Testing	مجموعة التدريب %Training
91.3	4.8	7.6	striped	14	14	72
74.5	6.5	6.1	blocked	14	14	72
92.6	6.3	7	random	14	14	72

نموذج معمارية الشبكة العصبية (Neural Network Model)

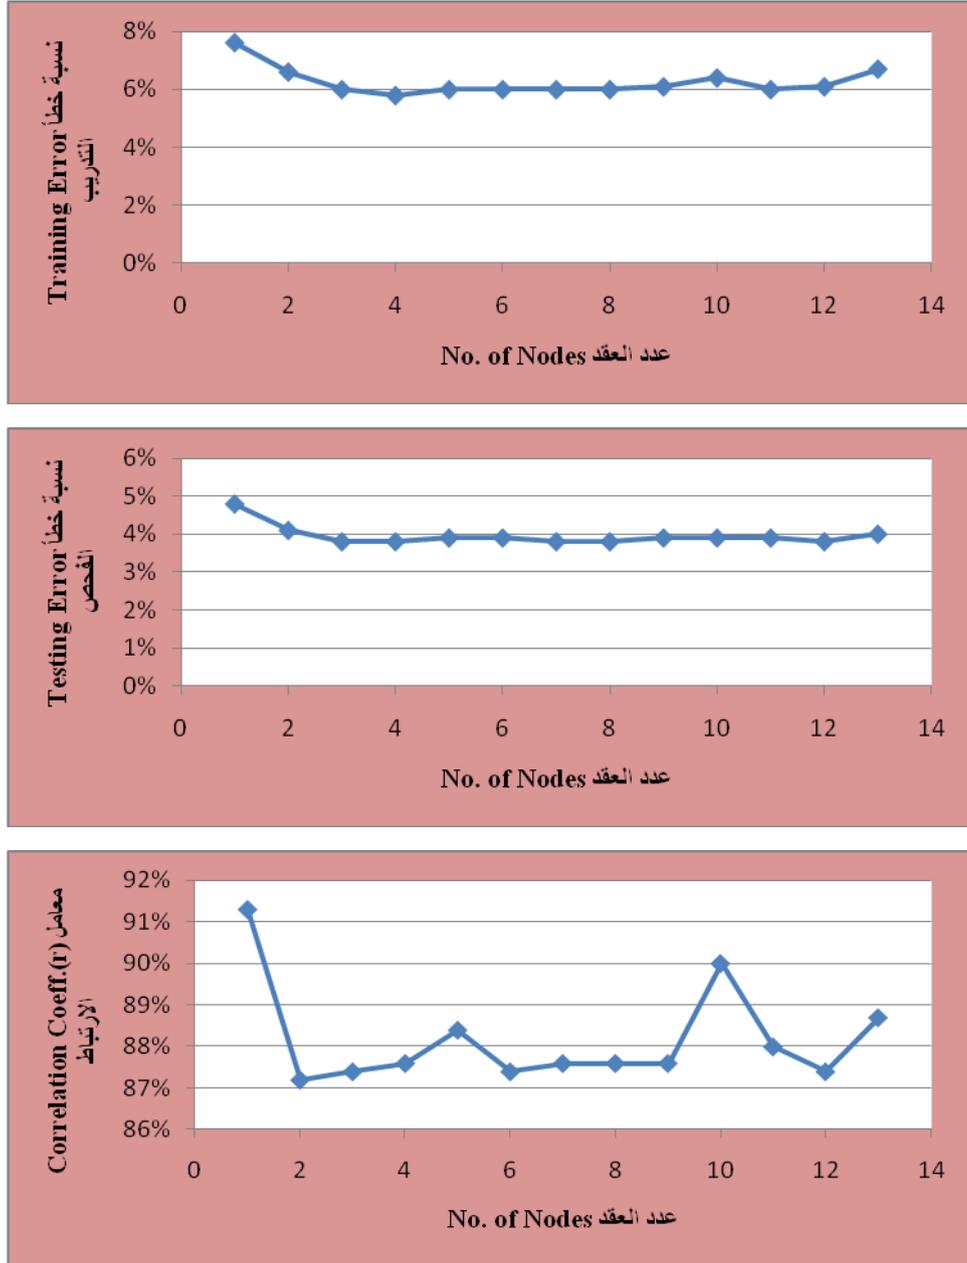
معمارية الشبكة العصبية الاصطناعية هي الطريقة التي ترتبط بها العصبونات مع بعضها البعض لتشكيل الشبكة . وان تحديد العدد المناسب من العقد العصبونية في الطبقة الوسطية من الشبكة العصبونية يعتبر عامل مهم لنجاح الشبكة العصبية مع العلم بان عدد العقد في طبقة الادخال (Input Layer) يكون مساويا لعدد العوامل المؤثرة في حساب الانتاجية وتبلغ ستة عوامل هي العمر والخبرة ومنسوب العمل والطقس ودرجة تعقيد الموقع، اما طبقة الاخراج (Output Layer) فهي تحتوي على عقده عصبونية واحده وهي الانتاجية المقاسة .

هناك العديد من الطرق التي يمكن ان تستخدم لايجاد العدد الامثل للعقد العصبونية في الشبكات العصبية (AI- (Zwainy,2008) ، وان افضل طريقة هي استخدام المعادلة (1) وتتضمن البدء باختيار عقد واحده في الطبقة الوسطية ومن ثم البدء بزيادة تدريجية في عدد العقد لحين تحقيق افضل اداء للشبكة وان اقصى عدد للعقد يساوي (1+I2)، وهذه الطريقة هي التي اعتمدها الباحث في بحثه.

$$\text{Max.No.of Node} = 1 + 2 * I \dots \dots \dots (1)$$

وباستخدام المحددات الافتراضية للبرنامج المستخدم في هذا البحث وهي معدل التعلم (Learning Rate) وتبلغ قيمته (0.2) و حجم الخطوة (Momentum Term) وتبلغ قيمته (0.8)، اما دالة التحويل (Transfer Function) لعقد طبقة الاخراج والطبقة الوسطى المخفية فهي من نوع (Sigmoid).

من الشكل (3) ادناه يتبين بأن هناك اختلاف بسيط في نسبة الخطأ لمجموعة الفحص وان افضل اداء للشبكة عندما عدد العقد يكون مساو الى عقدة واحدة. وذلك لحصولها على اعلى معامل ارتباط (91.3%) و نسبة خطأ للفحص (4.3%). وبالتالي يكون الشكل النموذجي لهذه الشبكة المطورة في هذا البحث عبارة عن ثلاث طبقات عصبونية (طبقة دخل input layer و طبقة مخفية hidden layer و طبقة خرج output layer) طبقة الدخل لا تقوم بأي عملية معالجة فهي ببساطة مكان تغذية الشبكة بقاعدة البيانات و تقوم طبقة الدخل بعد ذلك بتغذية (نقل المعلومات) الى الطبقة المخفية و من ثم تقوم الطبقة المخفية بتغذية طبقة الخرج . المعالجة الفعلية للبيانات Data تتم في الطبقة المخفية و طبقة الخرج أساسا .



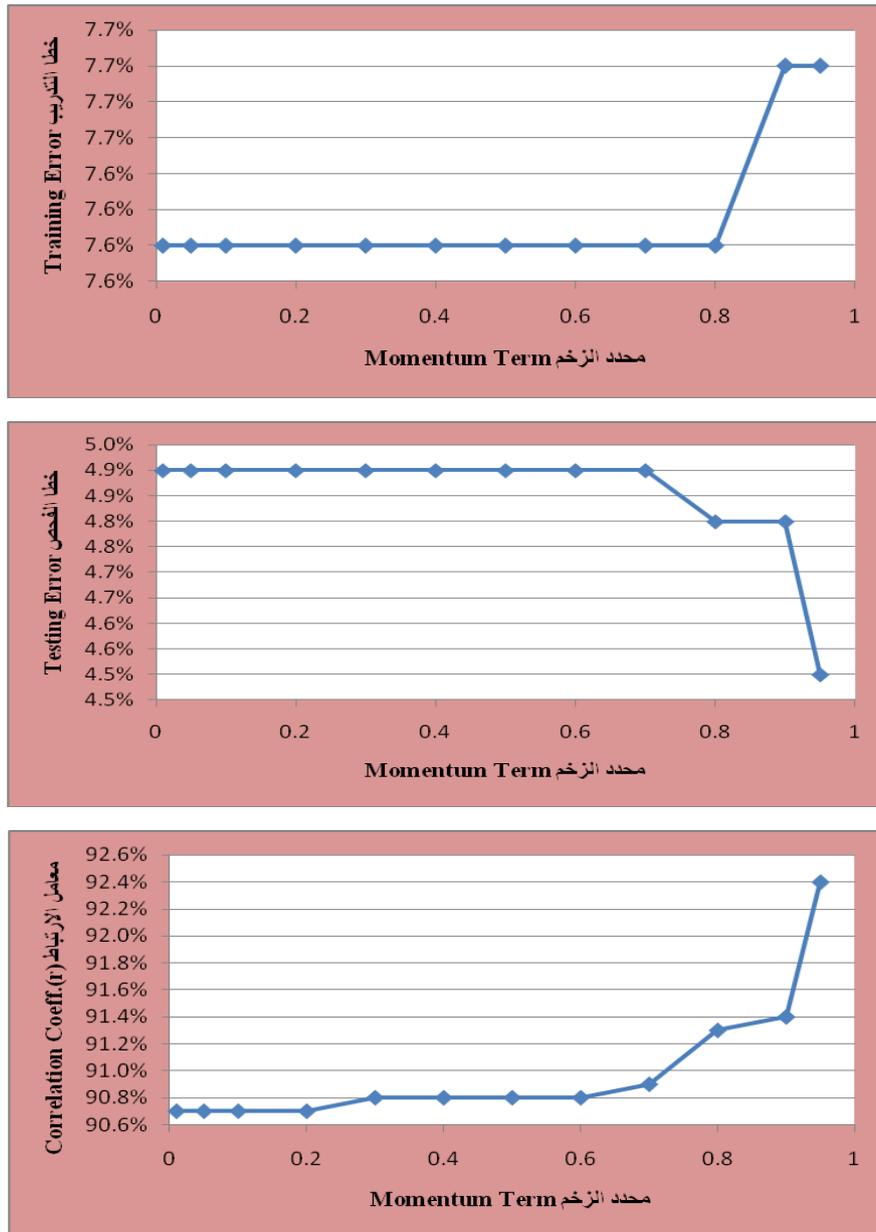
شكل(3): اداء نموذج الشبكة العصبية مع العدد المختلف لعدد العقد

نموذج حجم الخطوة (Momentum Term Model) ونموذج معدل التعلم (Learning Rate Model)

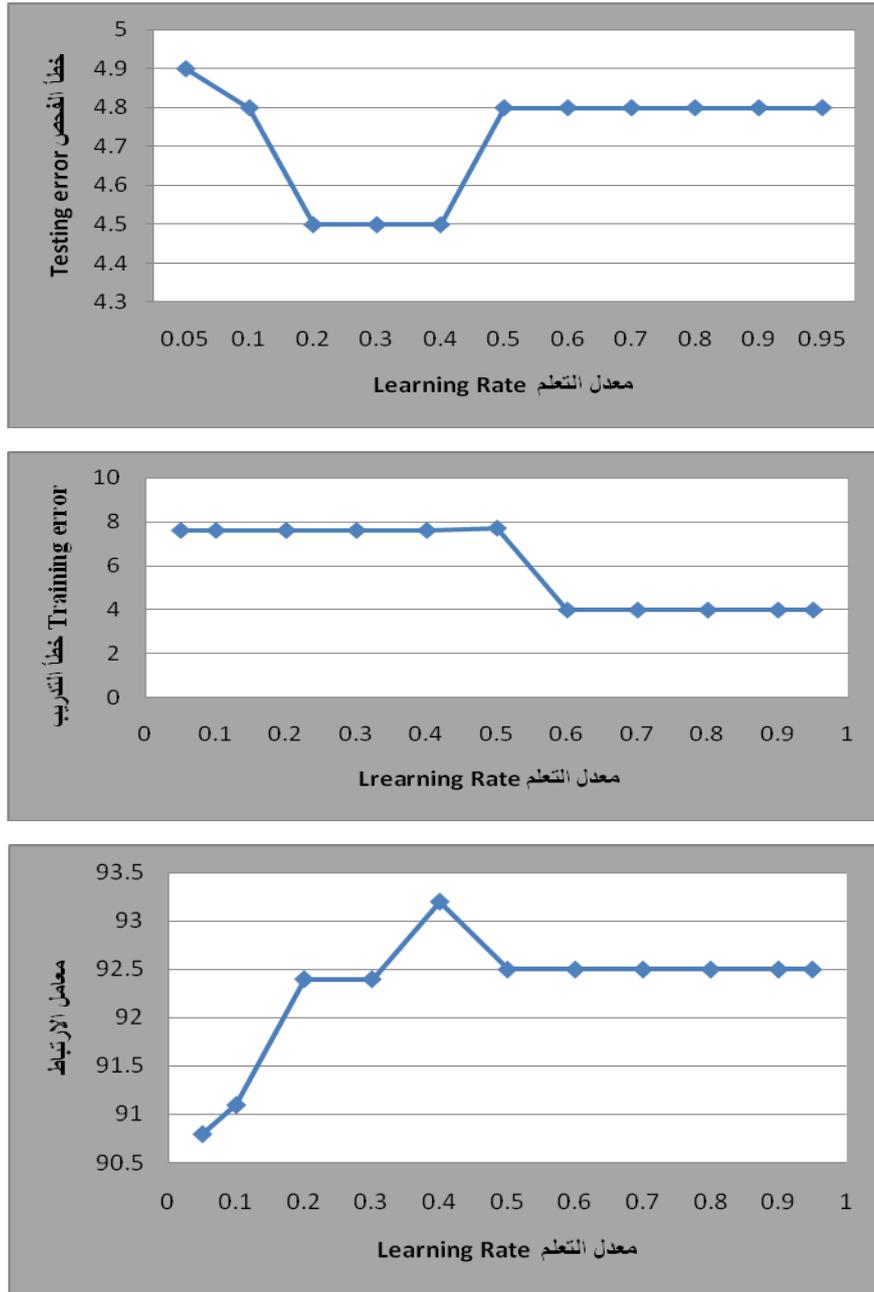
يعتبر هذا النموذجان من النماذج المهمة في تحسين اداء الشبكة العصبونية، وانهما يعملان معا بشكل مترابط من خلال معمارية الشبكة العصبية وكلاهما يؤثران في بعضهما البعض الاخر. ومن اجل بيان تاثير معامل حجم الخطوة او ما يسمى محدد الزخم (Momentum Term) على اداء الشبكة، قام الباحث باجراء مجموعة من الاختبارات على الشبكة العصبية وذلك من خلال تغيير معدل الزخم لقيم تتراوح بين الحد الادنى لهذا المعامل وهو (0) والحد الاعلى له وهو (1.0).

من الشكل (4) يتوضح بأن الشبكة غير حساسة لتنوع محدد الزخم من المدى (0.01) الى (0.8) ثم بدأت بالنقصان تدريجياً لفحص الخطأ . وان افضل اداء للشبكة عندما يكون محدد الزخم مساوياً الى (0.95) حيث ان لها اقل نسبة خطأ لمجموعة الفحص (4.5%) واكبر معامل ارتباط (r) (92.4%)، اذ نلاحظ ان هناك تحسن في اداء الشبكة كلما اقترب محدد الزخم من الحد الاقصى له وهو (1).

بالاضافة الى ذلك , نلاحظ ان تأثير معدل التعلم (Learning Rate) على اداء النموذج. يعمل معدل التعلم على تحديد سرعة تغير الميل والانحيات , و تم تحقيقه تأثير معدل التعلم عندما تثبت القيمة المثلى لمحدد الزخم (Momentum Term) (0.95) , وكما مبين في الشكل (5), اذ نلاحظ ان امثل قيمة لمعدل التعلم تبلغ (0.4) اذ ان لها اقل خطأ لمجموعة الفحص (4.5%)، واكبر معامل ارتباط (r) (93.2%)، اذ نلاحظ ان هناك تحسن في اداء الشبكة كلما اقترب معدل التعلم من الحد الادنى له وهو (0.0).



شكل(4): تأثير تنوع محدد الزخم على اداء نموذج الشبكة العصبية (معدل التعلم=0.2)



شكل (5): تأثير تنوع معدل التعلم على اداء نموذج الشبكة العصبية (محدد الزخم = 0.95)

ولدراسة تأثير دالة التحويل تم اجراء اربعة اختبارات وكما مبين في الجدول (3) ادناه ، ويمكن ملاحظة بأن اداء الشبكة العصبية تقريبا غير حساس لنوع الدالة الوظيفية اذ كان معامل الارتباط بحدود 93% ونسبة خطأ الفحص يتراوح بين 4.5% و 6.3%، ومن خلال ذلك نستنتج بان افضل اداء لنموذج الشبكة تم الحصول عليها عند استخدام الدالة الوظيفية (sigmoid) لكلا الطبقتين الوسيطة (المخفية) وطبقة المخرجات، وذلك بسبب الحصول على اعلى معامل ارتباط (93.2%) واقل نسبة خطأ للفحص (4.3%). وهكذا وجد الباحث ان تابع السيغمويد هو الأكثر شيوعا كتابع تحويل للعصبونات لأنه يؤمن اللاخطية في حسابات الشبكة العصبونية عن طريق تحويل قيمة تفعيل النيورون ضمن المجال [0,1]. إضافة لذلك فهو يؤمن ميزة اضافية تتلخص في بساطة تابعه المشتق المطلوب في خوارزمية الانتشار الخلفي

back-propagation للأخطاء و هي احدى خوارزميات التعليم المراقب المستخدمة في الشبكات أمامية التغذية في هذا البحث.

جدول (3) : تأثير الدالة التحويل على اداء نموذج الشبكة العصبية

معامل الارتباط Coefficient correlation (r)%	نسبة خطأ الفحص Testing error%	نسبة خطأ التدريب Training error%	دالة التحويل transfer function	
			طبقة الاخراج Output Layer	الطبقة الوسطية Hidden (المخفية) Layer
93.2	4.5	7.6	الاسي sigmoid	الاسي sigmoid
93	6.3	7.8	التانج tanh	الاسي sigmoid
93	6.3	7.8	الاسي sigmoid	التانج tanh
93	6.3	7.8	التانج tanh	التانج tanh

نموذج ضبط الاوزان (Weight Model)

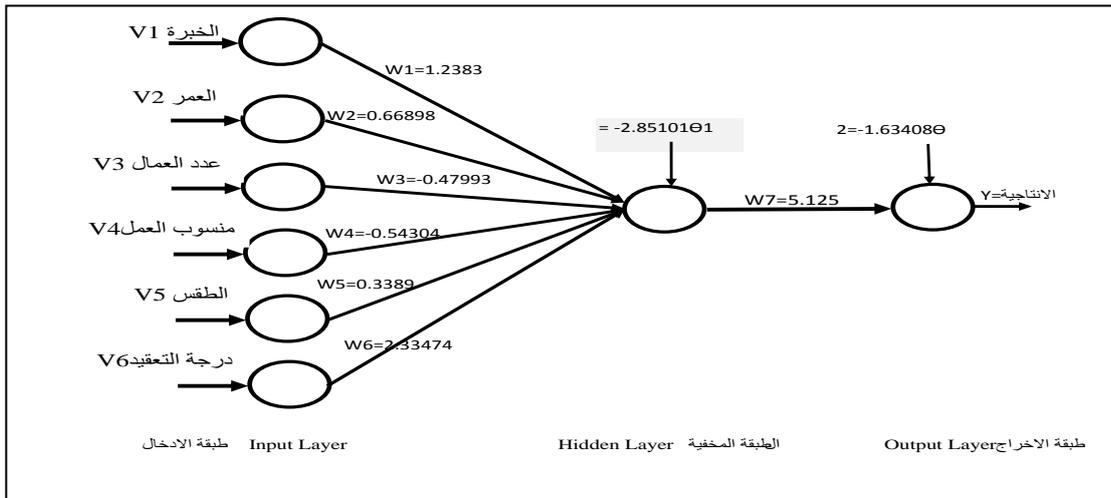
كل اتصال بين عصبون و آخر يتميز بارتباطه بقيمة تدعى الوزن و هي تشكل مدى أهمية الارتباط بين هذين العنصرين , يقوم العصبون بضرب كل قيمة دخل واردة من عصبونات الطبقة السابقة بأوزان الاتصالات مع هذه العصبونات , من ثم جمع نواتج الضرب جميعا , ثم إخضاع النتيجة لتابع تحويل يختلف حسب نوع العصبون , ناتج تابع التحويل يعتبر خرج العصبون الذي ينقل إلى عصبونات الطبقة اللاحقة .

وبعد تدريب الشبكة تم الحصول على قيم الاوزان للعقد الواصلة بين طبقة الاولى (الادخال) والطبقة الثانية (الوسطى او المخفية) وكذلك الاوزان بين الطبقة الثانية والطبقة الثالثة (الاخراج) وكما مبين في الجدول (4) ادناه

جدول(4) ضبط الاوزان بين طبقات الشبكة العصبية

حد العتبة في الطبقة المخفية Hidden layer threshold θ_j	W_{ji} (الوزن من العقدة (i) في طبقة الادخال الى العقدة (j) في الطبقة المخفية)						عقد الطبقة المخفية Hidden layer nodes
	i=6	i=5	i=4	i=3	i=2	i=1	
-2.85101	2.33474	0.3389	-0.543.4	-0.47993	0.66898	1.2383	j=6
حد العتبة في طبقة الاخراج Output layer threshold θ_j	W_{ji} (الوزن من العقدة (i) في الطبقة المخفية الى العقدة (j) في طبقة الاخراج)						عقد طبقة الاخراج Output layer nodes
	-	-	-	-	-	i=7	
-1.63408	-	-	-	-	-	5.1256	j=7

واخيراً يتم الحصول على الشكل النهائي للشبكة العصبية الاصطناعية ذات الطبقات الثلاثة وكما مبين في الشكل (6).



الشكل (6) الشبكة العصبية الاصطناعية المطورة في هذا البحث (البحث)

يمكن التنبؤ بالانتاجية لفقرة التغليف بالحجر لواجهات المباني من خلال المعادلة التالية:

$$y = 1/(1 + e^{-(\theta 2 - w7 * \tanh(X))}) \dots \dots \dots (2)$$

وباستخدام الاوزان (Wi) وحدي العتبة ($\theta 1$) و ($\theta 2$) المبينة في الجدول (1)، تكون المعادلة كالآتي:

$$y = 1/(1 + e^{-(+1.63408 - 5.125 * \tanh(X))}) \dots \dots \dots (3)$$

حيث ان:

Y = الانتاجية.

اما المتغير (X) فيمكن ايجاده من خلال المعادلة الآتية:

$$X = (\theta 1 + (W1 * V1) + (W2 * V2) + (W3 * V3) + (W4 * V4) + (W5 * V5) + (W6 * V6)) \dots \dots \dots (4)$$

ومما يجدر الاشارة له هنا، ان جميع المدخلات (المتغيرات) (V1, V2, V3, V4, V5, V6)، قد تم تحويل قيمها الحقيقية الى قيم قياسية تتراوح بين (0 و 1) وذلك حسب ما يتطلبه البرنامج (Neuframe-v4) اثناء فترة التدريب، وعليه فان ايجاد الانتاجية المقاسة من خلال المعادلة (3) ستكون القيم بين (0 و 1). ومن اجل الحصول على قيم الانتاجية الحقيقية لابد من تعديل الاوزان باستخدام المعادلة (5) ادناه، لارجاع القيم الى قيمتها الحقيقية.

$$Scaled Value = ((X - Xmin)/(Xmax - Xmin)) \dots \dots \dots (5)$$

واخيرا يكون الشكل النهائي لمعادلة الانتاجية كالآتي:

$$y = (5.51)/(1 + e^{-(+1.63408 - 5.125 * \tanh(X))}) + 1.56 \dots \dots \dots (6)$$

حيث ان:

$$X = \{-14.1491 + (1.2383 \cdot V1) + (0.669 \cdot V2) + (-12.478 \cdot V3) + (-13.033 \cdot V4) + (0.339 \cdot V5) + (0.50633 \cdot V6)\} \dots \dots \dots (7)$$

وبالتطبيق العملي للمعادلة النهائية للانتاجية باستخدام احدى بيانات المشاريع المبينة في الملحق (1) ، عندما كان عمرة الخلفة يبلغ 31 عاما وخبرته 12 عاما وعدد العمال المساعدين (1) ومنسوي العمل (م0) والطقس (1) ودرجة التعقيد (1)، فإن الانتاجية المقاسة حسب المعادلة (6) و(7) تساوي = 6.907م2ايوم بينما الانتاجية الحقيقية تبلغ 6.94م2ايوم

نموذج التحقق (Validation Model).

في هذا البحث ، تم استخدام المعايير الاحصائية ادناه لاثبات كفاءة المعادلة المشتقة من نموذج الشبكة العصبية الاصطناعية المطورة في هذا البحث .

(1) المعدل المطلق لنسبة الخطأ، Mean Absolute Percentage Error (MAPE)

$$MAPE = \left(\frac{\sum (|A - E|)}{A} \cdot 100\% \right) / n \dots \dots \dots (8)$$

(2) درجة الدقة ، Average Accuracy Percentage (AA%)

$$AA\% = 100\% - MAPE \dots \dots \dots (9)$$

(3) معامل التحديد ، The Coefficient of Determination (R²)

(4) معامل الارتباط ، The Coefficient of Correlation (R)

حيث ان:

A: قيم الانتاجية الحقيقية

E: قيم الانتاجية المخمنة من خلال المعادلة

n: عدد المشاريع

والجدول (4) ادناه يمثل نتائج المعايير الاحصائية الاربعة اعلاه، ولعدد من المشاريع (19 مشروعاً) وهي تمثل نسبة الـ(14%) من البيانات الكلية التي تم تغذيتها في البرنامج المستخدم والتي تم تصنيفها لمجموعة التحقيق بعد اكمال بناء نموذج الشبكة العصبية الاصطناعية .

النتائج تبين ان للمعادلة المستخدمة لتخمين الانتاجية في نموذج الشبكة العصبية درجة دقة عالية جدا تبلغ (94.6%) وهي نتيجة تعتبر ممتازة لكفاءة النموذج المطور في هذا البحث .

جدول (4) نتائج تحقيق نموذج الشبكة العصبية

القيم الاحصائية لنموذج الشبكة العصبية	المعايير الاحصائية
%93.2	معامل الارتباط R
%86.86	معامل التحديد R ²
%5.4	المعدل المطلق لنسبة الخطأ MAPE
%94.6	درجة الدقة AA%

الاستنتاجات

ان الهدف الرئيسي من هذا البحث هو استخدام اسلوب جديد يعرف بالشبكات العصبية الاصطناعية لتخمين انتاجية فقرة التغليف بالحجر لمشاريع المباني . ان تطبيق الشبكات العصبية الاصطناعية كتقنيه جديده في قطاع التشييد في العراق ضروري جدا لضمان نجاح ادارة المشروع. نموذج واحد بني للتنبؤ بالانتاجية الكلية لعمال التغليف بالحجر في مشاريع المباني , في هذا العمل تم استخدام الشبكات متعددة الطبقات بتقنية الانتشار الرجعي للخطأ. لقد وجد بان هذه الشبكات لها القابليه على التنبؤ بالانتاجية الكلية بدرجة ممتازة من الدقة 96.4% و بلغت معاملات الارتباط (R) 93.2%. واطهر هذا النموذج بانه غير حساس نسبيا لعدد العقد المخفيه والحد الكمي ومعدل التعلم

References

المصادر

- [1]Al-Zwainy, Faiq, M. S. (2008), “**The Use of Artificial Neural Network for Estimating Total Cost of Highway Construction Projects**”, a thesis submitted to the Civil Engineering Department, College of Engineering, Baghdad University, Ph.D.
- [2]Baker, Sahar I.(2011), “**Forecasting of Factors Affecting Brickwork Productivity Estimation by Using Artificial Neural Network**” , a thesis submitted to the Civil Engineering Department, College of Engineering, Baghdad University, M.Sc
- [3]Fausett, L. 1994, “**Fundamantals of Neural Networks**”, Prentice Hall.
- [4]Haykin, S., (1999), “**Neural Network a Comprehensive Foundation**”, 2nd ed. Prentic-Hall International Inc.
- [5]Jason Portas and Simaan AbouRizk , (1997),“**Neural Network Model for Estimating Construction Productivity**”, JOURNAL OF CONSTRUCTION ENGINEERING AND MANAGEMENT © ASCE / DECEMBER, Vol. 123.
- [6]Li-Chung Chao, and Miroslaw J. Skibniewski,(1994) " **Estimating Construction Productivity: Neural-Network-Based Approach**", Journal of Computing in Civil Engineering / April, Vol. 8.
- [7]Master, T. (1993), “**Practical Neural Networks Recipes in C++.**”, Academic Press, London.
- [8]Ming Lu, S. M. AbouRizk, and Ulrich H. Hermann,(2000), "**Estimating Labor Productivity Using Probability Inference Neural Network**", JOURNAL OF COMPUTING IN CIVIL ENGINEERING / OCTOBER, Vol. 14.
- [9]Samer Ezeldin and Lokman M. Sharara,(2006), "**Neural Networks for Estimating the Productivity of Concreting Activities**" Journal of construction engineering and management ASCE/June, Vol.132

- [10]Shahin, M.A., (2003), “Use of Artificial Neural Networks for Predicting Settlement of Shallow Foundations on Cohesionless Soils”, Ph.D. Thesis, Department of Civil and Environmental Eng., University of Adelaide.
- [11]Tam .C.M., Thomas K.L. Tong & Sharon L. Tse,(2002) "Artificial Neural Networks Model for Predicting Excavator Productivity" Department of Building and Construction, City University of Hong Kong, 83, Tat Chee Avenue, Kowloon, Hong Kong, China. Engineering, Construction and Architectural Management © ASCE.
- [12]Zurada, J., (1996), “Introduction to Artificial Neural System”, Jaiur Publishing House.
- [13] الطويل، نبيل جميل و حداد، طارق، 1989. "انتاجية اليد العاملة لفكرة البناء بالطابوق في قطاع التشييد لمنطقة بغداد"، مجلة الهندسة والتكنولوجيا، ص 79.
- [14] سعيد، محمد أراز محمد علي، 1990. "دراسة تأثير المناخ وساعات العمل الطويلة على تباين الاداء في المشاريع الانشائية"، رسالة ماجستير، قسم البناء والانشاءات، الجامعة التكنولوجية.
- [15] عيدان، ابراهيم عبد الله، 1996، "دراسة تأثير عدد من العوامل على مستوى الانتاجية وانظمة الاجور والحوافز في المشاريع الانشائية في العراق"، رسالة ماجستير، قسم البناء والانشاءات، الجامعة التكنولوجية.