

Developing a Model to Estimate Plastering Labor Productivity using Artificial Intelligence

Dr. Fayez Jrad *
Dr. Samah Makkieh **
Abdullah Ghbeish ***

(Received 3 / 10 / 2022. Accepted 15 / 5 / 2023)

□ ABSTRACT □

Underestimating productivity carefully causes the project to be delayed and the cost to be increased; therefore, estimating productivity is of great importance in all aspects of construction. The human factor generally outweighs other factors that affect productivity since a large percentage of jobs depend on it. Plastering is one of the most important internal and external cladding works for all types of projects. There is hardly any building or facility in Syria devoid of plastering works. Therefore, this research aims to develop an Artificial Neural Network (ANN), which does not depend on personal experience and connects the factors that affect labor productivity in plastering with each other. The factors that affect productivity are determined through the previous studies and by collecting opinions of project managers, site managers, contractors, and through the data acquired. Eight influential factors are used to predict labor productivity in plastering: location of plastering, method of plastering, number of plastering patches, number of work teams, age, work team experience, weather, and floor height. The network is trained on several architectural designs, and the design with the least mistakes and the highest correlation coefficient is chosen as the best architectural design. The optimal network is composed of eight inputs to the network, a hidden layer with 10 nodes, and the output layer is related to labor productivity. The optimal trained network is tested on new samples. The test results show the preciseness of the suggested model in prediction with a correlation coefficient of $R=98.12\%$. Finally, a software interface is developed that provides labor productivity in plastering using the abovementioned network.

Keywords: Artificial Neural Networks, Productivity, Plastering.

Copyright



:Tishreen University journal-Syria, The authors retain the copyright under a CC BY-NC-SA 04

* Associate Professor, Construction Engineering and Management Department, Faculty of Civil Engineering, Tishreen University, Latakia, Syria. Favezalijrad@gmail.com

** Assistant Professor, Construction Engineering and Management Department, Faculty of Civil Engineering, Tishreen University, Latakia, Syria. S.makkieh@tishreen.edu.sy

*** Postgraduate Student (Ph.D.), Construction Engineering and Management Department, Faculty of Civil Engineering, Tishreen University, Latakia, Syria. Abdullah.ghbeish.94@tishreen.edu.sy

تطوير نموذج لتقدير إنتاجية اليد العاملة لأعمال الطينة باستخدام الذكاء الصناعي

د. فايز جراد *

د. سماح مكية **

عبدالله غبيش ***

(تاريخ الإيداع 3 / 10 / 2022. قُبِلَ للنشر في 15 / 5 / 2023)

□ ملخص □

إن عدم تقدير الإنتاجية بشكل دقيق يؤدي إلى التأخر بزمان المشروع وزيادة في كلفته، لذلك تعد عملية تقدير الإنتاجية ذات أهمية كبيرة في جميع مجالات التشييد. غالباً ما يطغى العامل البشري على باقي العوامل المؤثرة في العملية الإنتاجية لكون نسبة كبيرة جداً من الأعمال تعتمد على العنصر البشري. تعتبر الطينة من أهم أعمال الإكساء الداخلية والخارجية لكافة أنواع المشاريع، ولا يكاد يخلو أي بناء أو منشأة في الواقع السوري من أعمال الطينة. لذلك يهدف هذا البحث إلى تطوير نموذج شبكة عصبية [ANN] غير معتمد على الخبرة الشخصية يربط العوامل المؤثرة على إنتاجية اليد العاملة لأعمال الطينة مع بعضها البعض. تم تحديد العوامل المؤثرة على الإنتاجية من خلال الدراسات السابقة ومن خلال إجراء عملية رصد لآراء مدراء المشاريع ومهندسي الموقع والمقاولون ومن خلال البيانات التي تم الحصول عليها، تم استخدام 8 عوامل مؤثرة للتنبؤ بإنتاجية اليد العاملة لأعمال الطينة وتشمل: موقع تنفيذ الطينة، طريقة تنفيذ الطينة، عدد الأوجه، عدد فرق العمل، العمر، خبرة فريق العمل، الطقس، ارتفاع الطابق. تم تدريب الشبكة على عدة تصاميم معمارية، واختيار التصميم الموافق للخطأ الأصغري وأعلى معامل ارتباط كأفضل تصميم معماري، كانت الشبكة المثلى تتكون من 8 مدخلات للشبكة وطبقة خفية واحدة وعشر عقد وطبقة الخرج التي تتمثل بإنتاجية اليد العاملة. تم اختبار الشبكة المثلى على عينات لم تتدرب عليها مسبقاً، وأثبتت نتائج الاختبار دقة النموذج المقترح في التنبؤ بمعامل ارتباط $R=98.12\%$. وأخيراً تم تطوير واجهة برمجية تقدم إنتاجية اليد العاملة لأعمال الطينة بالاعتماد على الشبكة المطورة أعلاه.

الكلمات المفتاحية: الشبكات العصبية الاصطناعية، الإنتاجية، أعمال الطينة.



حقوق النشر : مجلة جامعة تشرين- سورية، يحتفظ المؤلفون بحقوق النشر بموجب الترخيص

CC BY-NC-SA 04

* أستاذ مساعد، قسم هندسة وإدارة التشييد، كلية الهندسة المدنية، جامعة تشرين، اللاذقية، سورية. Favezalijrad@gmail.com

** مدرس، قسم هندسة وإدارة التشييد، كلية الهندسة المدنية، جامعة تشرين، اللاذقية، سورية. S.makkieh@tishreen.edu.sy

*** طالب دراسات عليا (دكتوراة)، قسم هندسة وإدارة التشييد، كلية الهندسة المدنية، جامعة تشرين، اللاذقية، سورية.

Abdullah.ghbeish.94@tishreen.edu.sy

مقدمة:

تعرف الإنتاجية على أنها النسبة بين المخرجات والمدخلات، أو هي المقياس البسيط لقسمة المخرجات على المدخلات، أو هي الكمية التي ينتجها كل عنصر من عناصر الإنتاج على مدى فترة زمنية محددة من الزمن، وتعرف أيضاً بأنها تعظيم فائدة استخدام الموارد وتخفيف تكاليف الإنتاج. وينظر للإنتاجية من زاويتين: هندسية وإدارية، فالمفهوم الهندسي يشير إلى العلاقة النسبية بين المخرجات والمدخلات أي ما ينتجه الفرد أو الآلة أو المنظمة منسوباً إلى ما تم استخدامه من موارد وعناصر إنتاجية معينة، أما المفهوم الإداري يشير إلى مدى الفاعلية في استخدام تلك الموارد وليس فقط مجرد الكفاءة في تحقيق استخدام أمثل للموارد المتاحة [1]. تحتل اليد العاملة أهمية كبيرة في جميع مجالات التشييد، وغالباً ما يطغى العامل البشري على باقي العوامل المؤثرة في العملية الإنتاجية لكون نسبة كبيرة جداً من الأعمال تعتمد على العنصر البشري، فبدون هذا العنصر لن تتوفر القدرة على استغلال المواد الخام [2]. تعد عملية تقدير الإنتاجية ذات أهمية كبيرة في عملية التخطيط والجدولة في مشاريع التشييد مع الأخذ بعين الاعتبار العوامل المؤثرة على الإنتاجية لأنه في عملية التقييم والجدولة من المهم العمل على زيادة إنتاجية العمل والتنبؤ بمدة النشاط لتحقيق أقل سعر وأقل فترة زمنية للمشروع [3].

إن أهمية هذا الموضوع جعلت عملية تقدير الإنتاجية محط اهتمام مجموعة من الباحثين حتى وقتنا الحاضر. حيث تم تطوير نموذج لتقدير إنتاجية اليد العاملة لأعمال الطينة باستخدام تقنية الانحدار الخطي المتعدد في العراق، وتم تحديد العوامل المؤثرة على الإنتاجية من خلال مقابلات تم إجراؤها مع فرق العمل الخاصة بأعمال الطينة وكانت كالتالي: العمر، الخبرة، ارتفاع الحائط، العمالة الإضافية، الطقس، عمارة البناء، حالة الموقع. حيث تم تطوير 4 نماذج وأظهرت النتائج أن النموذج الرابع كان أكثر ملائمة مع متوسط نسبة دقة (95%) للتنبؤ بإنتاجية أعمال الطينة في المباني [4]. وأجريت دراسة في ماليزيا تم فيها قياس تأثير عوامل بيئة العمل في أعمال طينة الجدران، تم تحديد العوامل المؤثرة على الإنتاجية من خلال استبيانات تم توزيعها ومن خلال الدراسات السابقة وكانت كالتالي: انتظار المواد، حركة غير مبررة لأعضاء فريق العمل، مشرف غير كفاء، تغيرات الطقس، عدم كفاءة أو نقص الأدوات، إعادة العمل، انتظار فريق عمل آخر، وجود تداخلات من فريق عمل آخر، معلومات متأخرة أو غير واضحة من قبل المهندس أو مراقب العمال، ازدحام منطقة العمل، حدوث حوادث، حجم فريق العمل، عدم كفاءة المعدات أو تعطلها، انتظار التعليمات من قبل رئيس العمال أو المهندس، الوجود في الموقع بلا عمل. ونتيجة الدراسة بتطبيق معامل الانحدار المتعدد تبين أن عامل انتظار المواد يأتي في المرتبة الأولى من حيث التأثير على الإنتاجية، يليه انتظار التعليمات وإعادة العمل، وحدثت الحوادث أتى في المرتبة الأخيرة من حيث التأثير [5]. ولقد تم قياس تأثير الظروف الاجتماعية والاقتصادية وبيئة العمل على إنتاجية العمالة في أعمال الطينة وتركيب بلوك جدران المنازل المكونة من طابق واحد في إندونيسيا، حيث تناولت هذه الدراسة بأن إنتاجية اليد العاملة لأعمال الطينة وتركيب بلوك الجدران تتأثر بالظروف الاجتماعية والاقتصادية وبيئة العمل، ولمعرفة كيفية تأثير هذه العوامل على الإنتاجية تم توزيع استبيانات وإجراء مقابلات وكانت العوامل التي تم الحصول عليها بالنسبة للظروف الاجتماعية والاقتصادية: الخبرة العملية، والتعليم الرسمي، والتدريب المهني، والأجر، وتخزين مواد البناء، والمسافة بين مناطق التخزين وموقع العمل، وهذان العاملان يؤثران بنسبة % 63.7-59.7. وعنصر آخر له تأثير حاسم على الإنتاجية هو بيئة العمل بما في ذلك حالة العمل من عملية إلى أخرى، وتوافر مواد البناء، وكفاية المعدات المساعدة، وإحاطة المشرفين للعمال، وأساليب العمل، وظروف الطقس، وواجبات العمال، ودليل البناء المشاريع، وكان هذا العامل يؤثر بنسبة % 63.1-59.7 [6]. وفي دراسة أجريت في

سيريلانكا تم تحديد العوامل المؤثرة على إنتاجية اليد العاملة لأعمال الطينة، تم تحديد هذه العوامل من خلال المقابلات ومن خلال دراسة العمل، وكانت ضمن 5 مجموعات. المجموعة الأولى وهي عوامل الإدارة وتتألف من: جدولة العمل، ومهارات الإدارة، وتحفيز العمال. والمجموعة الثانية هي عوامل إدارة الموقع والموارد وتتألف من: جودة المواد والمعدات، توافر المواد والمعدات، الإشراف. والمجموعة الثالثة هي عوامل خاصة بالمشروع وتتألف من: العمل الإضافي، كيفية الوصول إلى الموقع. والمجموعة الرابعة هي عوامل خاصة بالقوى العاملة وتتألف من: نوعية وخبرة فرق العمل، تدريب العمال. والمجموعة الخامسة هي عوامل خاصة خارجية وتتألف من: عوامل الطقس، وعوامل السلامة [7]. ولقد تم تحديد إنتاجية اليد العاملة لأعمال الطينة والدهان والبلوك للعمال المحلية والغير محلية وإجراء مقارنة بينهم في إندونيسيا، تم الحصول على البيانات من خلال الملاحظات الميدانية ومن خلال الشركات والوكالات الإندونيسية، بعد إجراء الدراسة والتحليل تبين أن إنتاجية العمالة الغير محلية أعلى من إنتاجية العمالة المحلية ولكن بقيمة صغيرة جداً وليست ذات أهمية كبيرة، حيث بلغ متوسط إنتاجية أعمال الطينة من إنتاجية العمالة المحلية (2.429 m²/h) بينما تبلغ الإنتاجية غير المحلية (2.631 m²/h) [8]. وأيضاً دراسة أجريت في الجمهورية العربية السورية تم فيها تحديد العوامل الرئيسية المؤثرة على إنتاجية العمل وكانت كالتالي: التخطيط والمراقبة، العوامل المرتبطة بالمواد وأساليب البناء، إعادة العمل، ظروف ورشة العمل، الظروف الجوية. ثم تم اعتماد منهجية MCDM في توصيف الهدف والمعايير الرئيسية والثانوية. كانت النتائج بأن عوامل التخطيط والمراقبة مع عوامل الأمن والسلامة التي تتدرج تحت معيار ظروف ورشة العمل من أهم العوامل المؤثرة بشكل نسبي على العملية الإنتاجية وفعاليتها [9]. جميع الدراسات السابقة تناولت تحديد العوامل المؤثرة على إنتاجية اليد العاملة لأعمال الطينة في مشاريع التشييد ومقدار تأثير كل عامل على الإنتاجية، وهذه العوامل تختلف بحسب المشروع وبحسب طبيعة العمل وحسب البلد، وفي دراستنا هذه سنقوم بتحديد العوامل المؤثرة على إنتاجية اليد العاملة لأعمال الطينة، وتطوير نموذج للتنبؤ بإنتاجية اليد العاملة لأعمال الطينة باستخدام إحدى تقنيات الذكاء الصناعي وهي الشبكات العصبية الاصطناعية التي تنتبأ بالإنتاجية بشكل علمي ودقيق، وبالرغم من وجود عدد لا بأس به من الدراسات حول الإنتاجية والعوامل التي تؤثر عليها في بلدان عديدة، فإن عدد قليل جداً من الدراسات حول موضوع الإنتاجية لليد العاملة قد أجريت في الجمهورية العربية السورية، لذلك تعد هذه الدراسة التي تناولت تقدير إنتاجية اليد العاملة لأعمال الطينة باستخدام الشبكات العصبية الاصطناعية أول دراسة ضمن الواقع السوري بالرغم من تحديد أن التخطيط الذي يعتمد على تقدير الإنتاجية حُد كأولوية لتحسين أداء المشاريع في الأبحاث المحلية [10].

أعمال الطينة:

تعتبر الطينة من أهم أعمال الإكساء الداخلية والخارجية لكافة أنواع المشاريع، وتعد أول أعمال الإكساء بعد الانتهاء من تمديد سواد الصحية والكهرباء والتكليف وتركيب الملاين [11].

• يدخل في تركيبها:

1. الاسمنت المقاوم لأملاح الكلوريدات والكبريتات.
2. الماء العذب الصالح للشرب.
3. الرمل الخالي من الشوائب.

• تكمن أهميتها:

1. في حماية جسم المبنى من التعرض للعوامل الجوية والخارجية.

2. ضبط رأسية وأفقية الأسطح والزوايا بدرجة عالية.
3. مراعاة عيوب البيتون.
4. تشكيل أرضية تحتية لأعمال الدهان.
- **تتراوح سماكتها:**
 - ❖ للجدران الداخلية من 2 - 1.5 سم.
 - ❖ للجدران الخارجية من 3-4 سم.
 - ❖ للأسقف من 1-2 سم.
- **تكلفة أعمال الطينة تشمل:** كل من المواد اللازمة للتنفيذ والمعدات والسقالات وتكلفة اليد العاملة وكل ما يلزم للوصول إلى العمل المطلوب، وتقاس بالمتر المربع وتنفذ بالقدرة أو الودع أو حديثاً عن طريق الفذف.

أهمية البحث وأهدافه:

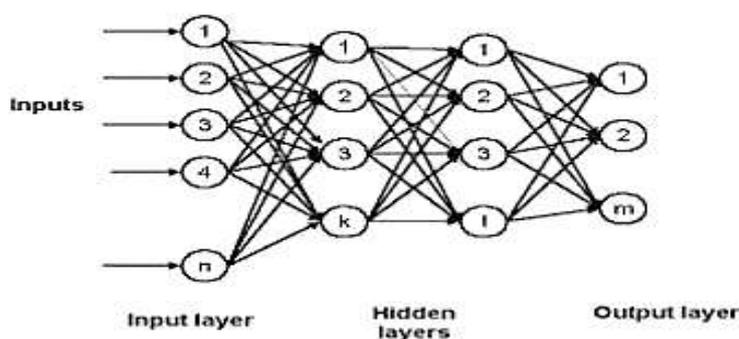
يعد تقدير الإنتاجية ذو أهمية كبيرة في عملية التخطيط والجدولة في مشاريع التشييد، وأن عدم تقديرها بشكل دقيق يؤدي إلى التأخر بزمّن المشروع وزيادة في كلفته. وعادةً يتم تقدير الإنتاجية بطريقة تقليدية غير دقيقة وذلك اعتماداً على إنتاجيات لمشاريع سابقة، أو تؤخذ جاهزة من دليل الأسعار ويقوم ثابتة، دون الأخذ بعين الاعتبار بأنها قد تختلف وفقاً للعديد من العوامل المؤثرة ووفقاً لظروف كل مشروع عن الآخر [12]، لذلك من الضروري التنبؤ بالإنتاجية بالرغم من وجود نورمات عالمية لذلك. وقد يعتمد بعض المقاولون على خبرتهم الشخصية في تقدير الإنتاجية. لذلك يعد هذا البحث محاولة لدراسة إمكانية استخدام أحد تطبيقات الذكاء الصناعي وهي الشبكات العصبية الاصطناعية للتنبؤ بالإنتاجية بشكل علمي ودقيق. لذلك يهدف هذا البحث إلى:

1. تحديد العوامل المؤثرة على إنتاجية اليد العاملة لأعمال الطينة.
2. تطوير نموذج شبكة عصبية يربط العوامل المؤثرة على الإنتاجية مع بعضها البعض.
3. مقارنة الإنتاجية المتوقعة التي تعطىها الشبكة العصبية مع الإنتاجية الحقيقية.

طرائق البحث ومواده:

الشبكات العصبية الاصطناعية Artificial Neural Networks:

حققت الشبكات العصبية الاصطناعية في العصر الحديث انتشاراً واسعاً في مختلف المجالات الطبية والهندسية والاقتصادية، إذ أنها تعتمد على آلية التعلم عبر تحليل كميات كبيرة من البيانات التاريخية مكتسبة الخبرة والمعرفة الضروريين في اتخاذ القرارات المستقبلية، كما تساعد على حل العديد من المسائل التي تكون العلاقة فيها بين متغيرات الدخل والخرج غير خطية. ما جعلها تتال اهتمام الباحثين للاستفادة من تطبيقاتها في مجال هندسة البناء وخاصة بعد أن أثبتت قدرتها الكبيرة في التنبؤ بكل من حالة الطقس، وتكاليف البناء، وتقييم المخاطر، وتسوية المنازعات، وتوقع الإنتاجية، وتقدير الجدول الزمن [13]. وتتألف الشبكة العصبية من مجموعة من الطبقات MULTI LAYERS، وكل طبقة تتألف من مجموعة من الوحدات Units أو العقد Nodes، حيث يختلف عدد الطبقات الأمثل ضمن الشبكة وعدد الوحدات داخل كل طبقة باختلاف المشكلة المطروحة [14]. يمثل الشكل (1) بنية الشبكة العصبية الاصطناعية [14]:



الشكل (1) بنية الشبكة العصبية الاصطناعية.

طبقة الدخل Input Layer:

تتكون طبقة الدخل من مجموعة من العقد أو عناصر المعالجة التي تعمل على توزيع القيم المدخلة إليها من الوسط الخارجي إلى الطبقة الخفية التي تليها عبر الارتباطات الموجودة بينهما، فهي بذلك لا تقوم بأية عملية حسابية.

الطبقات الخفية Hidden Layers:

وهي مجموعة الطبقات التي تقع بين طبقتي الدخل والخرج وتكون مكونة من طبقة واحدة أو أكثر، وذلك بحسب حجم المشكلة وطبيعتها، وقد تبين أن (85%) من التطبيقات المطورة تم الاكتفاء فيها بطبقة واحدة أو طبقتين. إن وحدات المعالجة الموجودة في هذه الطبقات هي التي تقوم بالعمليات الحسابية إذ تتلقى الإشارات من وحدات طبقة الدخل لتعالجها، وتطبق تابع التنشيط على تلك الإشارات ثم تحويلها إلى الطبقة الخفية التالية أو إلى طبقة الخرج.

طبقة الخرج Output Layer:

وهي الطبقة النهائية التي تقع عند المخرج، وتقوم عناصر المعالجة فيها باستلام الإشارات من الطبقة الخفية السابقة لتعالجها، وتقوم بإجراء العمليات الحسابية بشكل مشابه تماماً للطبقات الخفية لتعطي بعد ذلك النتيجة النهائية للمشكلة.

العوامل المؤثرة على الإنتاجية:

يوجد العديد من العوامل التي تؤثر على إنتاجية اليد العاملة ولقد اعتمد الباحثون على عوامل اختلفت من دراسة لأخرى وذلك حسب البيانات المتوفرة والمتاحة.

تم الاطلاع على عدد كبير من الدراسات السابقة وعلى العوامل التي تؤثر على الإنتاجية في كل دراسة، تبين وجود عدد كبير من العوامل الثابتة التي تؤثر على إنتاجية اليد العاملة يعتمدها الباحث في كل دراسة تتعلق بتقدير إنتاجية اليد العاملة في الأعمال الإنشائية. بناءً على ذلك تم تحديد عدد من العوامل التي تؤثر على الإنتاجية وهي (العمر، خبرة فريق العمل، عدد فرق العمل، ارتفاع الطابق، الظروف الجوية)، ثم تم عمل مقابلة مباشرة مع مدراء المشاريع ومهندسي الموقع والمقاولون وأصحاب المهن عن رأيهم عن العوامل الهامة التي تؤثر على إنتاجية اليد العاملة لأعمال الطينة، وبالإضافة إلى العوامل التي تم تحديدها من خلال الدراسات السابقة تم إضافة العديد من العوامل المؤثرة ومن أهمها: مكونات الطينة، بعد سكن العامل عن موقع العمل، وجود فترات للراحة أثناء العمل، عدد ساعات العمل في اليوم، طريقة تنفيذ الطينة، عدد الأوجه، موقع تنفيذ الطينة، الحالة الصحية لفريق العمل، المكافآت، بيئة العمل الآمنة، الإشراف على العمال. ولكن تم الاعتماد على عدد منها وذلك وفقاً لمعطيات الواقع والبيانات المتوفرة التي تم الحصول عليها. وكانت العوامل النهائية التي تم الاعتماد عليها [2، 3، 15-19]:

- موقع تنفيذ الطينة (داخلية - خارجية).
- طريقة تنفيذ الطينة (قده - ودع).
- عدد الأوجه (وجهان - ثلاثة أوجه).
- عدد فرق العمل (فريق العمل يتكون من معلم + عامل).
- العمر (وسطي مجموع أعمار العمال).
- خبرة فريق العمل (وسط - جيدة - جيدة جداً).
- الطقس (حار - معتدل - بارد).
- ارتفاع الطابق (بسقالة - بلا سقالة).

معالجة المعطيات:

يقصد بمعالجة المعطيات بتحويل المعطيات النصية إلى معطيات رقمية لتتلاءم مع طبيعة الشبكة العصبية التي تتعامل مع معطيات الدخل بمعطيات رقمية. يوضح الجدول (1) العوامل التي تم اعتمادها مدخلات للشبكة مع توضيح القيم المحولة لكل عامل من العوامل.

الجدول (1) تحويل المعطيات النصية إلى رقمية.

رقم العامل	العامل	تصنيف قيم العامل
1	موقع تنفيذ الطينة	1 = داخلية 2 = خارجية
2	طريقة تنفيذ الطينة	1 = قده 2 = ودع
3	عدد الأوجه	1 = وجهان 2 = ثلاثة أوجه
4	عدد فرق العمل	رقمي
5	العمر	رقمي
6	خبرة فريق العمل	1 = وسط 2 = جيدة 3 = جيدة جداً
7	الطقس	1 = حار 2 = معتدل 3 = بارد
8	ارتفاع الطابق	1 = بسقالة 2 = بلا سقالة

جمع البيانات:

تحتاج الشبكة العصبية إلى عدد من العينات لتتدرب وتصبح قادرة على التعلم وتعطي نتائج دقيقة، في هذه الدراسة تم جمع 117 عينة من مشاريع مختلفة (سكنية - تعليمية - تجارية)، ومن عناصر مختلفة (أعمدة، جوائز، جدران بلوك، جدران قص، أسقف). ويوضح الجدول (2) عينة من البيانات التي تم جمعها والحصول عليها، حيث تم جمع البيانات من مؤسسة الإنشاءات العسكرية، المؤسسة العامة للبناء والتعمير، شركة يونس للتجارة والمقاولات الهندسية. الجدول (2) بعض البيانات التي تم جمعها لإنتاجية اليد العاملة لأعمال الطينة.

أعمال الطينة															
رقم العينة	موقع تنفيذ الطينة	طريقة تنفيذ الطينة		عدد الأوجه		عدد العمال (عدد فرق العمل)	العمر	خبرة فريق العمل	الطقس			ارتفاع الطابق (m)		الإنتاجية	
		قده	ودع	وجهان	ثلاثة أوجه				حار	معتد	بارد	بسقالة	بلا سقالة		
1	✓	✓			✓	2	35	جيدة	✓			✓		18	2م
2	✓	✓		✓		3	32	جيدة		✓			✓	27	2م
3	✓		✓		✓	5	37	جيدة	✓				✓	42	2م
4	✓		✓		✓	3	40	جيدة	✓				✓	23	2م
5	✓		✓		✓	4	33	جيدة	✓			✓		36	2م
6	✓		✓		✓	3	35	جيدة	✓		✓		✓	20	2م
7	✓	✓		✓		2	43	جيدة		✓			✓	25	2م
8	✓	✓		✓		3	31	وسط	✓			✓		26	2م
9	✓		✓		✓	4	35	جيدة	✓				✓	50	2م
10	✓	✓		✓		5	32	جيدة		✓			✓	62	2م
11	✓		✓		✓	4	32	جيدة	✓			✓		27	2م
12	✓		✓		✓	4	40	جيدة ج		✓	✓		✓	40	2م
13	✓		✓		✓	4	33	جيدة		✓		✓		35	2م
14	✓		✓		✓	3	35	جيدة		✓	✓		✓	20	2م
15	✓	✓		✓		3	46	جيدة		✓			✓	31	2م

وتم تقسيمها إلى 70% للتدريب و 15% للتحقق و 15% للاختبار وذلك وفقاً لأعلى معامل ارتباط كما هو موضح في الجدول (3). وتم استبعاد 20 عينة بشكل عشوائي لاختبار الشبكة. الجدول (3) تقسيم البيانات وفقاً لأعلى معامل ارتباط.

R	MSE			تقسيم البيانات		
	اختبار	تحقق	تدريب	بيانات الاختبار	بيانات التحقق	بيانات التدريب
93.62	0.036	0.011	0.0015	20	20	60
90.36	0.032	0.011	0.009	20	15	65

98.12	0.065	0.0046	0.0005	15	15	70
91.01	0.051	0.013	0.0052	15	10	75
96.52	0.013	0.011	0.0033	10	10	80
94.91	0.049	0.031	0.001	10	5	85
97.49	0.068	0.003	0.0006	5	5	90

الأداة المستخدمة في تطوير نموذج الشبكة العصبية:

هناك العديد من لغات البرمجة المطورة المتاحة للاستخدام في عملية بناء نماذج الشبكات العصبية الصناعية، إحدى تلك الأدوات هي برنامج MATLAB حيث استخدم عدد كبير من الباحثين تلك الأداة في تطوير العديد من الشبكات العصبية في مختلف التطبيقات وقد ساعدت في إعطاء نتائج دقيقة للغاية، لذلك تم اعتمادها في هذا البحث في تصميم الشبكة العصبية وفي تدريبها واختبارها.

تحديد معمارية الشبكة العصبية:

طبقة الدخل وعدد عناصر المعالجة:

تتألف كل شبكة عصبية من طبقة دخل واحدة تحوي عدداً من عناصر المعالجة مساوية لعدد متغيرات الدخل المختارة. وفي هذه الدراسة لدينا 8 متغيرات دخل التي تمثل العوامل المؤثرة على الإنتاجية التي تم تحديدها سابقاً.

طبقة الخرج وعدد عناصر المعالجة:

تتألف كل شبكة عصبية من طبقة خرج واحدة تحوي عدداً من عناصر المعالجة مساوية لعدد المخرجات النهائية المطلوبة من الشبكة. لدينا في هذه الدراسة عنصر معالجة واحد يعطي الخرج الذي صممت لأجله شبكة التنبؤ بإنتاجية اليد العاملة لأعمال الطينة.

الطبقة الخفية:

في هذه الدراسة تم تجريب عدد كبير من معماريات الشبكة العصبية وذلك بطبقة خفية واحدة وبطبقتان خفيتان وبعدها مختلف من الخلايا في كل منها، وتم الاعتماد في النهاية على طبقة خفية واحدة.

تابع التحويل:

تم استخدام تابع التحويل الأسّي (Sigmoid) أثناء معالجة وضبط قيمة الدخل الصافي لكل من عصبونات الطبقة الخفية وعصبونات طبقة الخرج، تتمثل وظيفة هذا التابع بأخذ قيم الدخل المحصورة بين $(-\infty)$ و $(+\infty)$ وجعل قيم الخرج محصور بين (0 و 1)، تلجأ خوارزمية الانتشار العكسي (Backpropagation algorithm) إلى تطبيق هذا التابع لامتلاكه خصائص هامة، إذ أنه تابعاً انسيابياً ومستمر وقابل للاشتقاق ومشتقه سهل الحساب، ويعطى بالعلاقة:

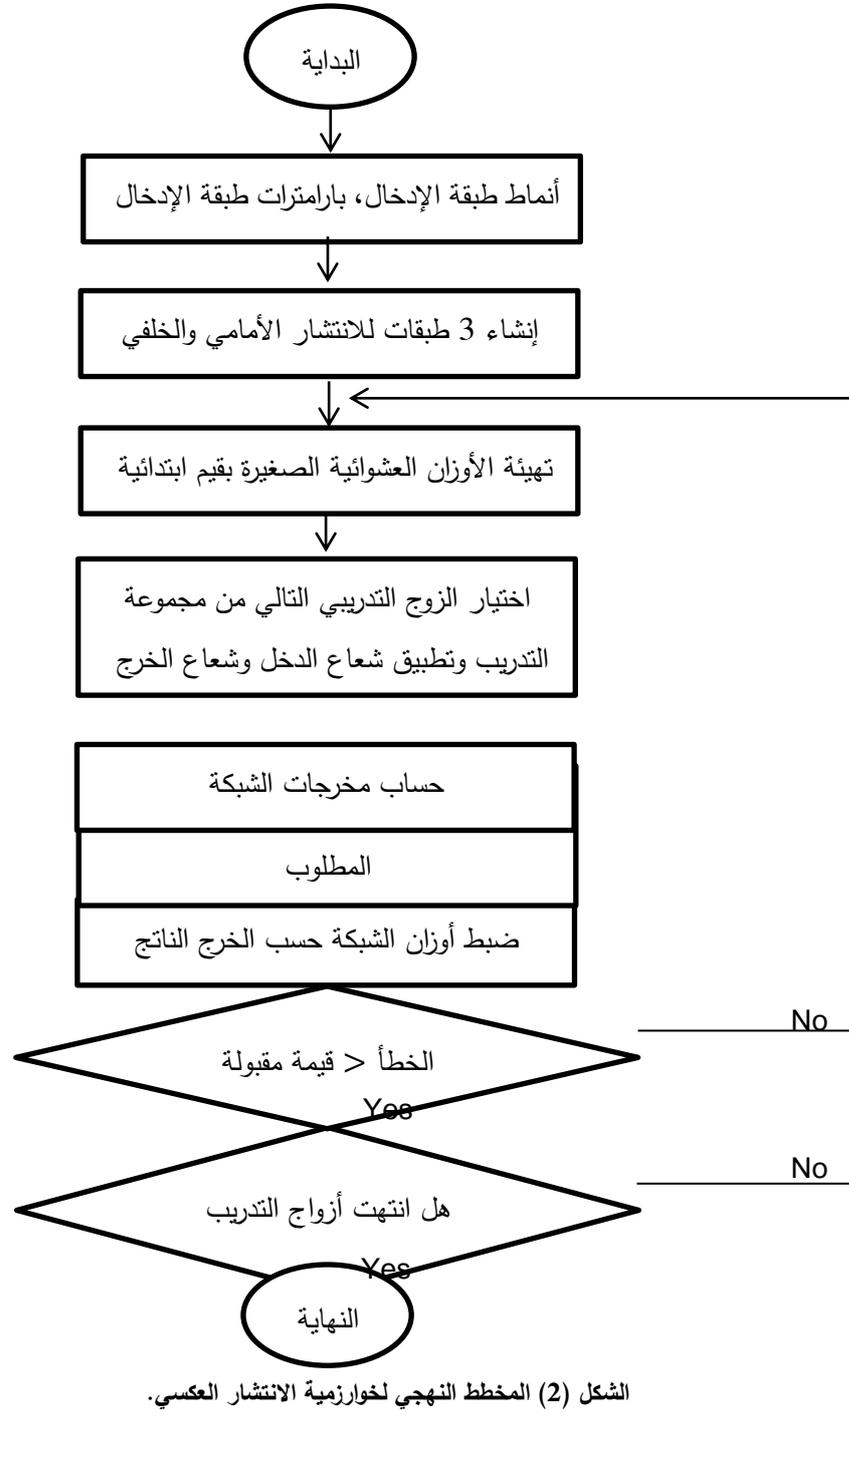
$$F(x) = \frac{1}{1 + e^{-x}}$$

النتائج والمناقشة:

مرحلة تدريب الشبكة:

تم تقديم عينات التدريب المتمثلة بالمدخلات والخرج المقابل لها إلى الشبكة العصبية وذلك بعد إعطاء قيم عشوائية صغيرة لأوزان الشبكة، ثم من أجل كل عينة تدريب تم تدفق ومعالجة المعطيات من طبقة إلى أخرى بشكل متسلسل وفق مسار أمامي فقط (Feed Forward)، والذي منه تم الحصول على خرج الشبكة ومقارنته مع القيمة الأولية

المطلوبة من الشبكة وحساب مقدار الخطأ، ثم تم اتباع خطوة تراجعية (Backward) لتعديل الأوزان بهدف تصغير مقدار الخطأ استناداً إلى قاعدة الانحدار التدريجي لخوارزمية الانتشار العكسي ومعيار معلوم للخطأ، يوضح الشكل (2) المخطط النهجي لخوارزمية الانتشار العكسي [20].



الشكل (2) المخطط النهجي لخوارزمية الانتشار العكسي.

تم تجريب 10 حالات معمارية مختلفة للشبكة العصبية، تتألف جميعها من طبقة خفية واحدة وتختلف عن بعضها البعض بعدد العقد في الطبقة الخفية. يبين الجدول (4) نتائج تدريب الشبكة، حيث يظهر عدد العصبونات في الطبقة

الخفية مع قيمة الخطأ المتوسط التربيعي MSE وقيمة معامل الارتباط R% لكل منها ومعامل التحديد R²% وقيمة الخطأ المتوسط النسبي المطلق MAPE ومتوسط نسبة الدقة AA%.

الجدول (4) نتائج تدريب الشبكة باختلاف عدد العصبونات في الطبقة الخفية.

عدد العصبونات	MSE	R%	R ² %	MAPE	AA%
5	0.0094	93.75	87.89063	5.14	94.86
10	0.0029	98.12	96.27534	2.57	97.43
15	0.0112	92.83	86.17409	3.15	96.85
20	0.0062	96.41	92.94888	3.09	96.91
25	0.0095	93.69	87.77816	3.15	96.85
30	0.0077	94.98	90.212	2.32	97.68
35	0.0193	90.05	81.09003	3.93	96.07
40	0.0035	97.85	95.74623	1.92	98.08
45	0.0141	91.48	83.6859	4.72	95.28
50	0.0083	94.97	90.19301	3.58	96.42

من خلال نتائج التدريب لوحظ أن الشبكة العصبية المثلى النهائية تتكون من:

- 8 مدخلات للشبكة
- طبقة خفية واحدة بعشر خلايا (وذلك وفقاً لأعلى معامل ارتباط)
- طبقة خرج واحدة متمثلة بالإنتاجية
- تابع التحويل المستخدم تابع السيجمويد (التابع الأسّي)
- معدل التعلم Learning Rate= 0.01
- معدل الزخم Momentum Term= 0.9
- الخوارزمية المستخدمة هي خوارزمية الانتشار الخلفي Backpropagation algorithm وتابع

التدريب TRAINLM

وأن كل من الخطأ المتوسط التربيعي MSE والخطأ المتوسط النسبي المطلق MAPE ومتوسط نسبة الدقة AA%

يعطى بالعلاقة التالية:

$$MSE = \frac{1}{n} * \sum_{i=1}^n et^2$$

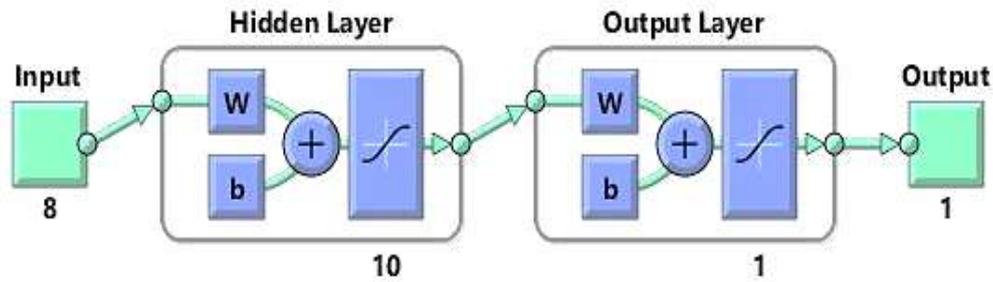
$$MAPE = \frac{1}{n} * \sum_{i=1}^n \frac{et}{A} * 100$$

$$AA\% = 100 - MAPE$$

حيث أن:

n: عدد العينات، et= (A - P)، A: الخرج الحقيقي، P: الخرج الناتج عن الشبكة العصبية

يوضح الشكل (3) معمارية الشبكة العصبية المثلى:



الشكل (3) معمارية الشبكة العصبية المثلى.

يبين الجدول (5) المعايير الإحصائية للشبكة العصبية النهائية.

الجدول (5) المعايير الإحصائية للشبكة العصبية النهائية.

المعايير الإحصائية	القيم الإحصائية لنموذج الشبكة العصبية
معامل الارتباط R%	98.12
معامل التحديد R ² %	96.27
الخطأ المتوسط النسبي المطلق MAPE	2.57
الخطأ المتوسط التربيعي MSE	0.0029
متوسط نسبة الدقة AA%	97.43

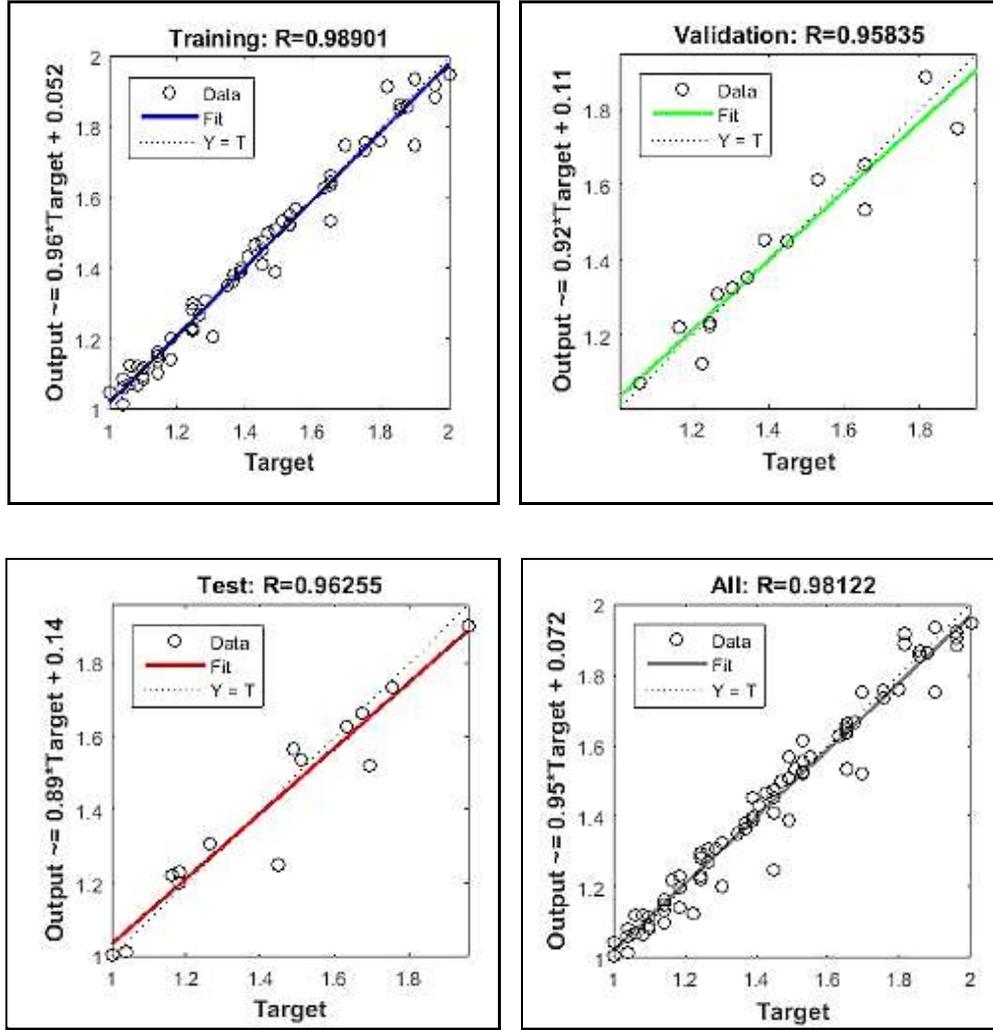
يبين الشكل (4) نتائج التدريب للشبكة المختارة الخاصة بالتنبؤ بالإنتاجية، حيث كان

معامل الارتباط بمرحلة التدريب: R= 95.835%

معامل الارتباط بمرحلة التحقق: R= 98.901%

معامل الارتباط بمرحلة الاختبار: R= 96.255%

معامل الارتباط الكلي: R= 98.122%



الشكل (4) نتائج التدريب للشبكة المختارة الخاصة بالتنبؤ بالإنتاجية.

حيث أن:

X: محور المخرجات الحقيقية، Y: محور المخرجات المحسوبة، O: البيانات المدخلة، R: معامل الارتباط الخط المنقط هو المثالي والخط المستمر هو الذي يحقق الملائمة الأفضل.

مرحلة الاختبار النهائية:

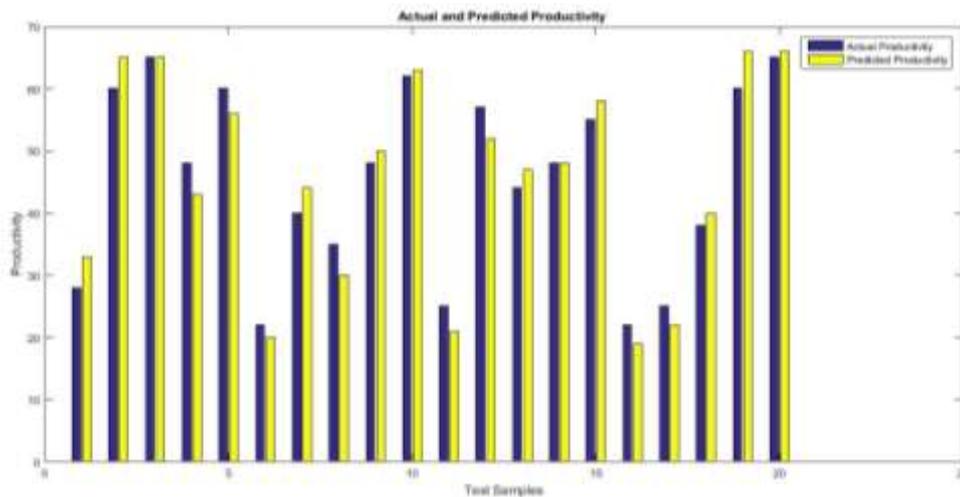
تم اختبار الشبكة النهائية المثلى على العينات التي تم استبعادها وتقدر ب 20 عينة وتم حساب الخطأ المتوسط التربيعي $MSE = 0.0059$ وحساب معامل الارتباط $R = 97.66\%$. ويبين الجدول (6) نتائج اختبار الشبكة بمدخلات جديدة.

الجدول (6) نتائج اختبار الشبكة بمدخلات جديدة.

NO.	ACTUAL PRODUCTIVITY	PREDICTED PRODUCTIVITY	DIFFERENCE	MSE
1	28	33	-5	0.0059
2	60	65	-5	
3	65	65	0	

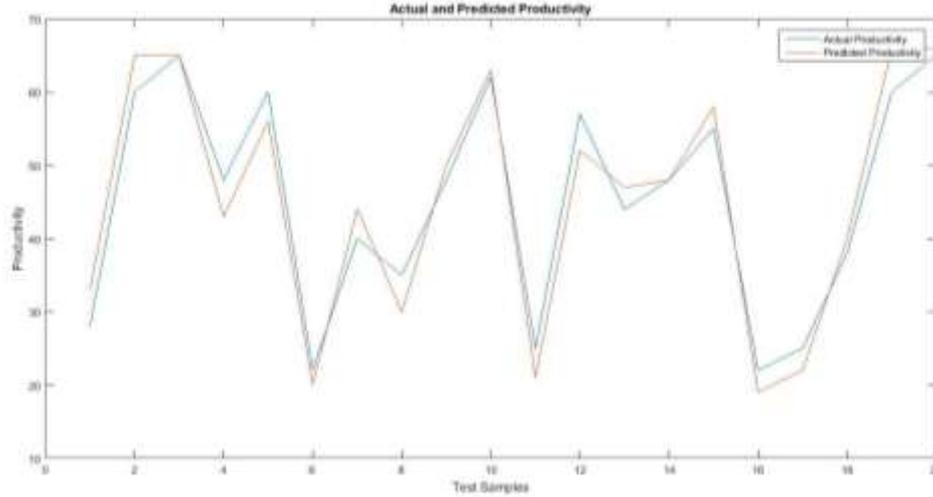
4	48	43	5
5	60	56	4
6	22	20	2
7	40	44	-4
8	35	30	5
9	48	50	-2
10	62	63	-1
11	25	21	4
12	57	52	5
13	44	47	-3
14	48	48	0
15	55	58	-3
16	22	19	3
17	25	22	3
18	38	40	-2
19	60	66	-6
20	65	66	-1

وبعد ذلك تم إجراء مقارنة بين الإنتاجية الحقيقية والإنتاجية المتوقعة التي تعطيها الشبكة العصبية كما هو موضح في الشكل (5) و (6).



الشكل (5) مقارنة بين الإنتاجية الحقيقية والإنتاجية المتوقعة.

- اللون الأزرق يمثل الإنتاجية الحقيقية.
- اللون الأصفر يمثل الإنتاجية المحسوبة.
- محور X يمثل عينات الاختبار.
- محور Y يمثل الإنتاجية.



الشكل (6) مقارنة بين الإنتاجية الحقيقية والإنتاجية المتوقعة.

- اللون الأزرق يمثل الإنتاجية الحقيقية.
- اللون الأحمر يمثل الإنتاجية المحسوبة.
- محور X يمثل عينات الاختبار.
- محور Y يمثل الإنتاجية.

وقد تظهر النتائج بأن هناك توافق كبير بين قيم الإنتاجية الحقيقية والإنتاجية المتوقعة من الشبكة، وهذا يعني بأنه تم الوصول إلى شبكة عصبية مثلى تستطيع التنبؤ بإنتاجية اليد العاملة لأعمال الطينة بمستوى جيد من الدقة وهذا يمكن من وضع الشبكة قيد الاستثمار.

وبعد مقارنة الإنتاجية الحقيقية مع الإنتاجية المتوقعة والإنتاجية التي تقدمها النورمات المحلية والعالمية نلاحظ بأن الإنتاجية التي تم التنبؤ بها أقرب بكثير إلى الإنتاجية الحقيقية من الإنتاجية التي تقدمها النورمات لذلك يفضل التنبؤ بالإنتاجية باستخدام الذكاء الصناعي أكثر من الاعتماد على النورمات.

استثمار الشبكة المطورة:

بعدما تم الانتهاء من تطوير الشبكة العصبية المثلى تم تطوير واجهة برمجية بواسطة برنامج MATLAB تسهل على المستخدمين الذين ليس لديهم خبرة في الشبكات العصبية بالاستفادة منها، وذلك من خلال إدخال العوامل المؤثرة على الإنتاجية للحصول مباشرة على الخرج المطلوب دون القيام بتشكيل ملف للإدخالات، ودون الحاجة إلى معالجة المدخلات الرمزية، أو الحاجة إلى العودة إلى الشبكة المثلى، فاختصر ذلك على المستخدمين الكثير من الوقت والجهد. يوضح الشكل (7) الواجهة البرمجية التي تم تطويرها والتي تنتبأ بالإنتاجية، والشكل (8) مثال على كيفية استخدام هذه الواجهة.

تقدير انتاجية أعمال الطينة

داخلية	موقع تنفيذ الطينة
قده	طريقة تنفيذ الطينة
وجهان	عدد الأوجه
	عدد فرق العمل
	العمر
وسط	خبرة فريق العمل
حان	الطقس
بسقالة	ارتفاع الطابق

2م 0 الإنتاجية RUN

الشكل (7) الواجهة البرمجية.

ويبين الشكل (8) مثال على كيفية استخدام الواجهة البرمجية في الحصول على الإنتاجية.

تقدير إنتاجية أعمال الطينة

موقع تنفيذ الطينة	خارجية
طريقة تنفيذ الطينة	قده
عدد الأوجه	وججان
عدد فرق العمل	2
العمر	32
خبرة فريق العمل	جيدة جداً
الطقس	معتدل
ارتفاع الطابق	بسقالة

2م
39
الإنتاجية
RUN

الشكل (8) مثال على كيفية استخدام الواجهة البرمجية.

الاستنتاجات والتوصيات:

الاستنتاجات:

1. تم تحديد العوامل المؤثرة على إنتاجية اليد العاملة لأعمال الطينة استناداً للدراسات السابقة، ومن خلال إجراء عملية رصد لآراء مدراء المشاريع ومهندسي الموقع والمقاولون، ومن خلال البيانات التي تم الحصول عليها، وكانت 8 عوامل نهائية مؤثرة على الإنتاجية: موقع تنفيذ الطينة، طريقة تنفيذ الطينة، عدد الأوجه، عدد فرق العمل، العمر، خبرة فريق العمل، الطقس، ارتفاع الطابق.
2. استطاعت الشبكة العصبية ذات المعمارية (8-10-1) المدربة على خوارزمية الانتشار العكسي (Backpropagation algorithm) قدرتها على التنبؤ بإنتاجية اليد العاملة لأعمال الطينة، حيث أعطت قيمة للخطأ المتوسط التربيعي $MSE = 0.0029$ وقيمة عالية لمعامل الارتباط $R = 98.12\%$.
3. إن التوافق الكبير بين القيم الفعلية والقيم الناتجة عن الشبكة يؤكد إمكانية استخدامها لتقدير إنتاجية اليد العاملة لأعمال الطينة في مشاريع أخرى.

4. تم تطوير واجهة برمجية تقوم بتقدير الإنتاجية بشكل دقيق دون الحاجة إلى وجود خبرة برمجية لدى المستخدمين وتوفر الكثير من الوقت والجهد.
5. جميع الدراسات السابقة قامت بتحديد العوامل المؤثرة على الإنتاجية، ولكن لم يتم استخدام أي منها ضمن شبكة عصبية للتنبؤ بالإنتاجية، ومن العوامل التي لم يتم ذكرها ضمن أي دراسة سابقة (موقع تنفيذ الطينة، طريقة تنفيذ الطينة، عدد الأوجه).

التوصيات:

1. ضرورة توثيق المهندسين لكافة معلومات المشاريع المنفذة فيما يخص الإنتاجيات والعوامل المؤثرة عليها، وذلك لتكوين قاعدة بيانات تتضمن جميع المعطيات للاستفادة منها لاحقاً في بناء نماذج شبكات عصبية أكثر دقة.
2. العمل على تطوير برنامج باستخدام الشبكات العصبية يقوم بتقدير جميع الإنتاجيات (يد العاملة - آليات) يراعي جميع الأعمال في المشروع، وعدم أخذ هذه الإنتاجيات من دليل الأسعار لأنها قد تختلف وفقاً للعديد من العوامل المؤثرة ووفقاً لظروف المشروع.
3. العمل على تطوير الواجهة البرمجية السابقة ليكون لها تغذية راجعة تُحدث من بيانات مشاريع أخرى مستقبلية.

References:

1. Ali, A.Z.S. and H.A. Abdalaziz, *A study of the factors affecting the site productivity of construction projects in the state of Khartoum*. 2018, Sudan University of Science and Technology.
2. Al-Zwainy, F.M.S., H.A. Rasheed, and H.F. Ibraheem, *Development of the construction productivity estimation model using artificial neural network for finishing works for floors with marble*. ARPN Journal of Engineering and Applied Sciences, 2012. 7(6): p. 714-722.
3. Mady, M., *Prediction Model of Construction Labor Production Rates in Gaza Strip using Artificial Neural Networks*. Unpublished Msc Thesis. The Islamic university of Gaza (IUG), 2013: p. 1-117.
4. Jahanger, Q.K., *Using multiple linear regression technique for predicting the productivity of gypsum plastering works in Buildings*. Journal of Environmental Studies, 2013. 12(1): p. 39-47.
5. Agbo, E.A., Y.D. Izam, and C. Ayegba, *Quantifying the Impact of Work Environment Factors on the Variability of Labour Productivity in Wall Plastering*. Journal of Construction in Developing Countries, 2022: p. 109-125.
6. Sugiyanto, S., M. Wena, and C.P. Dewi. *Effect of socioeconomic conditions and work environment on labour productivity in bricklaying and plastering walls for single-storey house*. in *AIP Conference Proceedings*. 2022. AIP Publishing LLC.
7. Pasath, V., et al., *Labour productivity in plastering works in Sri Lankan construction industry*. International Conference of Faculty of Architecture Research Unit (FARU), 2018: p. 271-279.
8. ABDULLAH, M.G., *PRODUCTIVITY COMPARISON OF LOCAL AND NON LOCAL ON BRICK MASONS, PLASTERING AND COATING WORKS*. 2017: p. 1-14.
9. Janood, A. and H. Jded, *Importance of MCDM in Labor Productivity for Construction Projects*. Tishreen University Journal -Engineering Sciences Series, 2020. 4 : (1)2p. 377-391.

10. Hassan, B., J. Omran, and R. Maya, *Defining the Areas and Priorities of Performance Improvement in Construction Companies Case Study for General Company for Construction and Building*. Tishreen University Journal for Research and Scientific Studies, 2016. **37**(6): p. 47-68.
11. MOHAMMED, B., et al. *Plaster and Paint*. 2019; Available from: <https://fliphtml5.com/bstat/hnlo>.
12. Jrad, F. and N. Joulak, *Developing a Model to Estimate the Actual Productivity of Loader in Construction Projects*. Tishreen University Journal-Engineering Sciences Series, 2020. **42**(2): p. 159-181.
13. Makkieh, S., *Forecasting the Estimate Completion Time of Syrian Building Projects Using Earned Value Management and Artificial Intelligence*. Tishreen University Journal-Engineering Sciences Series, 2021. **43**(2): p. 41-58.
14. Omran, J., N. Hani, and M.M. Soufan, *Improving the Opportunity of Winning a Project Tender of Schools Using Artificial Neural Network*, in *Tishreen University Journal-Engineering Sciences Series*. 2 :004Syria. p. 175-192.
15. Aswed, G., *Productivity estimation model for bricklayer in construction projects using neural network*. Al-Qadisiyah J Eng Sci, 2016. **9**(2): p. 183-199.
16. Najafi, A. and R.T.L. Kong, *Productivity analysis of precast concrete operations by artificial neural networks*. ARPN Journal of Engineering and Applied Sciences, 2016. **11**(17): p. 10512-10521.
17. Mohammed, S.R. and A.S. Tofan, *Neural networks for estimating the ceramic productivity of walls*. Journal of Engineering, 2011. **17**(2):(p. 200-217.
18. Mugeem, S., et al., *Construction labor production rates modeling using artificial neural network*. Journal of Information Technology in Construction (ITcon), 2012. **16**(42): p. 713-726.
19. Dayanand, T.A. and S. Shanmugaoriya, *ANN model for estimation of construction labour productivity*. Int J Modern Trends Eng Sci, 2016. **3**(8): p. 231-238.
20. Ammar, G.A. and B.Y. Haidar, *The Effect Of Adding Time Factor On The Artificial Neural Network Performance In Estimating Daily Evaporation In Mountainous Region From Syrian Coast*. Tishreen University Journal-Engineering Sciences Series, 2016. **38**(1): p. 105-114.