

التنبؤ بكلفة ومدة تنفيذ إعادة تأهيل المدارس باستخدام الشبكات العصبونية الاصطناعية

ميس زياد الشريفي¹ د.م حمزة علي²

(الإيداع: 12 كانون الثاني 2026، القبول: 9 آذار 2026)

الملخص:

تمثل عملية إعادة تأهيل البنية التحتية التعليمية في سوريا أولوية وطنية وحاجة ملحة في مرحلة إعادة الإعمار، نظراً لتعرض آلاف المدارس لأضرار بالغة نتيجة القصف والنزاع المسلح، وتواجه مشاريع إعادة التأهيل تحديات كبيرة في التخطيط والتنفيذ، أبرزها صعوبة تقدير التكاليف ومدة التنفيذ بدقة وسرعة بسبب الاعتماد على الأساليب التقليدية التي تحتاج إلى وقت وجهد كبيرين بالإضافة إلى تقلب الأسعار.

يهدف هذا البحث إلى تطوير نموذج تنبؤي باستخدام تقنيات الذكاء الاصطناعي، وتحديد الشبكات العصبونية الاصطناعية (ANN)، لتقدير كلفة ومدة تنفيذ إعادة تأهيل المدارس المتضررة.

اعتمد البحث على منهجية تطبيقية شملت تحليل بيانات 262 مدرسة في محافظة حماة للفترة بين 2018-2022، وتم اختيار ستة متغيرات مدخلة رئيسية للنموذج، وهي: حجم الضرر العام، ضرر البلاط، ضرر الحريق، ضرر التمديدات الصحية، النموذج المدرسي (المساحة وعدد الطوابق)، والموقع الجغرافي.

باستخدام بيئة MATLAB، تم بناء وتدريب عدة نماذج عصبونية اصطناعية، حيث أظهر النموذج ذو البنية [6-36-2] (ستة مدخلات، 36 عصبوناً في الطبقة الخفية، ومخرجين) أداءً مثالياً.

حقق النموذج دقة تنبؤية عالية حيث بلغ معامل الارتباط فيها ($R=0.973$) لمدة التنفيذ و ($R=0.989$) للكلفة، مع أخطاء تنبؤ منخفضة تمثلت بجذر متوسط مربعات الخطأ ($RMSE=3.04$ days) للمدة و ($RMSE=5.38$ Million) للكلفة، كما تم تطوير واجهة مستخدم رسومية (GUI) لتسهيل تطبيق النموذج عملياً، مما يعزز من إمكانية استخدامه في التخطيط المسبق واتخاذ القرار في ظروف تستوجب سرعة الاستجابة.

تؤكد هذه النتائج قدرة الشبكات العصبونية الاصطناعية على معالجة انخفاض الدقة المرتبط بالطرق التقليدية، وتقديم أداة فعالة لصانعي القرار في تخطيط الموارد المالية والزمنية لمشاريع إعادة الإعمار، مما يساهم في تحديد أولويات إعادة التأهيل بشكل أكثر فاعلية.، وعليه، يوصي هذا البحث بتوسيع قاعدة البيانات لتشمل محافظات أخرى في سوريا، ودمج تقنيات متقدمة مثل نمذجة معلومات البناء (BIM) لتمكين متخذي القرار من تحقيق تقديرات أدق تسرع عملية إعادة الإعمار.

الكلمات المفتاحية: التنبؤ بالكلفة، التنبؤ بالمدة، الشبكات العصبونية الاصطناعية (ANN)، إعادة تأهيل البنى التحتية، إعادة الإعمار.

¹ طالبة ماجستير، قسم الإدارة الهندسية والإنشاء، كلية الهندسة المدنية، جامعة حمص، سوريا .

² أستاذ دكتور، قسم الإدارة الهندسية والإنشاء كلية الهندسة المدنية، جامعة حمص، سوريا.

Predicting the Cost and Duration of Schools Rehabilitation Using Artificial Neural Networks

Mais Ziad Al-Sharifi ¹ Dr. Eng. Hamza Ali ²

(Received: 12 January 2026, Accepted: 9 March 2026)

Abstract:

The rehabilitation of educational infrastructure in Syria represents a national priority and an urgent necessity in the post-conflict reconstruction phase, as thousands of schools have sustained severe damage due to bombardment and armed conflict. These rehabilitation projects face substantial planning and implementation challenges, most notably the difficulty of accurately estimating costs and durations owing to reliance on traditional methods and price volatility.

This research aims to develop a predictive model using artificial intelligence techniques, specifically Artificial Neural Networks (ANN), to estimate the cost and duration of rehabilitating damaged schools. The study adopted an applied methodology involving the analysis of data from 262 schools in Hama Governorate during the period 2018–2022. Six main input variables were selected for the model: overall damage level, floor damage, fire damage, sanitary installations damage, school typology (area and number of floors), and geographical location.

Using the MATLAB environment, several artificial neural network models were built and trained. The model with architecture [6-36-2] (six inputs, 36 neurons in the hidden layer, and two outputs) demonstrated optimal performance. The model achieved high predictive accuracy, with correlation coefficients of $R = 0.973$ for project duration and $R = 0.989$ for project cost, and low prediction errors represented by Root Mean Square Error (RMSE = 3.04 days for duration and RMSE = 5.38 million monetary units for cost). In addition, a graphical user interface (GUI) was developed to facilitate the practical application of the model, thereby enhancing its usability for pre-planning and decision-making.

These results confirm the capability of Artificial Neural Networks to overcome the low accuracy associated with traditional methods and to provide an effective tool for decision makers in planning financial and temporal resources for reconstruction projects, contributing to more efficient prioritization of rehabilitation interventions. Accordingly, the study recommends expanding the database to include other Syrian governorates and integrating advanced techniques such as Building Information Modeling (BIM) to enable decision makers to achieve more accurate estimates and accelerate the reconstruction process.

Keywords: Cost prediction, duration prediction, Artificial Neural Networks (ANN), infrastructure rehabilitation, post-conflict reconstruction.

¹ student, Department of Engineering Management and Construction, Faculty of Civil Engineering, Homs University, Syria (msharifa@homs-univ.edu.sy)

² Professor, Department of Engineering Management and Construction, Faculty of Civil Engineering, Homs University, Syria.

1- مقدمة

تكتسب عمليات إعادة تأهيل المدارس في سورية أولوية استثنائية لضمان استمرارية التعليم واستقرار المجتمع وتسرع عودة المناطق المتضررة ، خاصة في ظل الدمار الهائل الذي لحق بالبنية التحتية التعليمية جراء النزاع المسلح، حيث أن (أكثر من 10,000 مدرسة متضررة وفقاً لتصريحات صادرة عن وزارة التربية السورية)، إلا أنها تواجه تحديات كبيرة تشمل: تفاوت مستويات الضرر، وغياب قواعد بيانات موحدة، واعتماد الأساليب التقليدية التي تحتاج إلى وقت من أجل تقدير الكلفة والزمن، ما يؤدي إلى إعاقة صنع القرار وتأخير التنفيذ.

في سياق إعادة إعمار المدارس المتضررة من زلزال "تشي تشي" في تايوان، طور (Chen & Huang, 2006) [1] نموذجاً هجيناً يجمع بين الانحدار الخطي المتعدد (MLR) والشبكات العصبية الاصطناعية (ANN) للتنبؤ المتزامن بتكلفة ومدة إعادة تأهيل هذه المدارس، مستندين إلى بيانات 132 مشروعاً، حيث حقق النموذج دقة تنبؤية تفوق 90% اعتماداً على عدد محدود من المتغيرات كالمساحة الإجمالية.

كما تفوق نموذج (Kim et al, 2021) [2] للشبكات العصبية العميقة على الانحدار المتعدد بنسبة 86% في الدقة (MAE=1.506) عند تحليل 1125 منشأة فندقية متضررة بفعل الكوارث الطبيعية، مؤكداً أهمية المؤشرات البيئية (كشدة الزلازل والموقع الجغرافي) في تحسين التوقعات.

قدمت دراسة (Charalambos et al, 2014) [3] إطاراً متكاملًا يدمج نمذجة معلومات البناء (BIM) مع (ANN) لتقدير كلفة ومدة إعادة تأهيل المباني المتضررة بالزلازل، مع تصنيف الضرر إلى 5 مستويات وعرضه بصرياً عبر نماذج ثلاثية الأبعاد، وأظهرت النتائج ارتباطاً وثيقاً بين شدة الضرر وكل من كلفة مدة الإصلاح.

أما في مشاريع البنى التحتية، حقق نموذج (Shehab & Farooq, 2013) [4] دقة تنبؤية عالية ($R^2=0.89$) لتقدير كلفة إعادة تأهيل شبكات الصرف الصحي في كاليفورنيا، كما تفوق نموذج (Cirilovic et al, 2014) [5] لتقدير تكاليف إعادة تأهيل الطرق باستخدام (ANN) على الانحدار التقليدي بمعامل تحديد ($R^2=0.75$) مقابل ($R^2=0.63$) وذلك في تحليل 200 مشروع عبر 14 دولة في أوروبا، مؤكداً قدرة ANN على نمذجة المتغيرات الاقتصادية كالنضخم.

وفي سياق التكيف مع نقص البيانات، أثبتت الشبكات العصبية الاصطناعية (ANN) تفوقها في التنبؤ الدقيق بتكلفة ومدة المشاريع المعقدة ، ففي مشاريع التجديد والترميم، نجح نموذج (Papadimitriou & Aretoulis, 2024) [6] في تقدير تكاليف تجديد 52 مبنى في اليونان بخطأ نسبي يقارب الصفر، معتمداً على 3 متغيرات فقط: التكلفة الأولية، المدة التعاقدية، وتكاليف الهدم.

أما في سياق المراقبة الديناميكية أثناء التنفيذ، فدمجت دراسة (Akhbari, 2018) [7] بين محاكاة مونت كارلو و (ANN) للتنبؤ بالكلفة والمدة باستخدام بيانات وقتية (كالتكلفة الفعلية عند إنجاز 50% من المشروع)، مسجلة (MSE=0.0505)، وفي تأكيد على قدرة (ANN) على تجاوز حدود النماذج الإحصائية التقليدية، أظهرت دراسة (Trijeti et al, 2023) [8] تفوقاً واضحاً لنموذجها المطبق -على مشاريع في إندونيسيا- على نماذج الانحدار المتعدد (MLR) بمعامل تحديد قيمة ($R^2=0.9995$) ومتوسط خطأ مطلق (MAE=0.2952)، مع إبراز دور المساحة وعدد الطوابق كعاملين حاسمين في دقة التنبؤ.

تظهر نتائج الدراسات السابقة أن الشبكات العصبية الاصطناعية (ANN) قادرة على نمذجة العلاقات غير الخطية بين المتغيرات المعقدة (كالمدة، النضخم، مستوى الضرر) بدقة تفوق الأساليب الإحصائية التقليدية كما أكدت دراسات [9] و [10] فاعلية تطبيقها في التخطيط المبكر، إذ تساهم في تقليل المخاطر المالية وتدعم صنع القرار في القطاعات الحيوية لاسيما في مشاريع إعادة التأهيل.

يركز هذا البحث على المدارس المتضررة في محافظة حماة وريفها، والتي خضعت لعمليات الترميم وإعادة التأهيل خلال الفترة المدروسة.

ويعود اختيار محافظة حماة لعدة أسباب منها:

- أن المحافظة شهدت عدداً كبيراً من مشاريع إعادة التأهيل مقارنة بمحافظات أخرى ماتزال فيها عمليات الترميم محدودة أو لم تبدأ بعد.
- توفر تقارير تقييم الأضرار والكشوفات الفنية في مديرتي التربية والخدمات الفنية والتي شكلت مصدراً أساسياً للمعلومات التي تم جمعها وترميزها لتشكيل قاعدة بيانات مناسبة لبناء نموذج تنبؤي قابل للاختيار.
- كما أن تنوع مستويات الضرر في مدارس المحافظة يتيح اختبار النموذج التنبؤي ضمن حالات متنوعة.
- الاستقرار النسبي في المحافظة مقارنة بمناطق أخرى يصعب الوصول إليها - أو لم تستأنف فيها أعمال الترميم بعد - ساهم في إمكانية التحقق من المعلومات ومتابعتها ميدانياً.

انطلاقاً من ذلك، يهدف هذا البحث إلى تطوير أداة فعالة ضمن بيئة برنامج (MATLAB) لدعم عمليات التخطيط وتوزيع الموارد المحدودة ويساهم في سرعة اتخاذ القرار، وذلك من خلال تصميم نموذج تنبؤي يعتمد على الشبكات العصبية الاصطناعية في تقدير المدة الزمنية والكلفة اللازمة لإعادة تأهيل المدارس المتضررة في محافظة حماة.


2- أهداف البحث:

يسهم النموذج التنبؤي (ANN) في تقدير كلفة ومدة تنفيذ إعادة تأهيل المدارس في تمكين صناع القرار من ترتيب الأولويات وتوجيه الموارد المحدودة نحو المشاريع الأكثر إلحاحاً، مما يحقق رفع كفاءة التخطيط وتسريع استجابة الجهات المعنية لترميم قطاع التعليم بدقة وفعالية في المناطق المتضررة مما يساهم في عودة الحياة لهذه المناطق. ولتحقيق هذا الهدف، يسعى البحث إلى:

1. استخدام نموذج الشبكات العصبية الاصطناعية في التنبؤ بكلفة ومدة تنفيذ ترميم وإعادة تأهيل المدارس المتضررة.
2. تقييم كفاءة الشبكات العصبية الاصطناعية في التنبؤ باستخدام معايير إحصائية مناسبة (R; RMSE).
3. إعداد واجهة مستخدم GUI تعمل على منصة ويندوز لمحاكاة النموذج المقترح.

3- منطقة الدراسة

في مرحلة المعالجة الأولية لبيانات (262) مدرسة خضعت لإعادة التأهيل في محافظة حماة وريفها خلال الفترة (2018-2022)، شملت المدخلات على ست مؤشرات تتضمن: ضرر البلاط، حجم الضرر العام (يشمل الأضرار الإنشائية وغير الإنشائية للمبنى)، ضرر التمديدات، ضرر الحريق، النموذج المدرسي (عدد الطوابق والمساحة)، والموقع الجغرافي للمدرسة بالنسبة لمركز مدينة حماة، ويوضح الشكل (1) توزيعها الجغرافي ضمن محافظة حماة.



الشكل رقم (1): التوزيع الجغرافي للمدارس المتضررة ضمن محافظة حماة.

في مرحلة المعالجة الأولية للبيانات، تم تصنيف الأضرار إلى ثلاثة مستويات (خفيف، متوسط، كبير) بما يتلاءم مع طبيعة البيانات المتاحة من الكشوفات الفنية والتي في معظمها بيانات وصفية لحالة الضرر، حيث تم ترميزها رقمياً بطريقة الترتيب (0, 1, 2, ..) للحفاظ على العلاقة الترتيبية بين مستويات الضرر، وهذا يتيح بناء نموذج عصبي أكثر توازناً مع تجنب تعقيد النموذج والإفراط في التدريب.

- رمزت متغيرات ضرر البلاط، حجم الضرر العام، ضرر التمديدات الصحية، ضرر الحريق، في ثلاثة مستويات من الضرر وهي: خفيف (0)، متوسط (1)، كبير (2).
- في حين تم ترميز النموذج المدرسي بخمسة مستويات، وذلك من حيث المساحة وعدد الطوابق، كما هو موضح في الجدول (1).

الجدول رقم (1): ترميز مستويات الضرر في نموذج المدارس (المساحة، عدد الطوابق).

الرمز النموذج	المساحة (m ²)	عدد الطوابق	ترميز النموذج
20/60	618.6375	3	4
71/ أ	452.6850	2	3
B/70	429.6	3	2
أ/73 (6 صفوف)	292.539	2	1
		2	0

- كما ترميز متغير الموقع وفق ثلاث مستويات حسب البعد عن مركز مدينة حماة، كما هو موضح في الجدول (2).


الجدول رقم (2): ترميز الموقع الجغرافي للمدارس المتضررة كبعد عن مركز مدينة حماة.

الترميز	البعد (Km)
1	10-0.38
2	25-10
3	64-25

4- مواد وطرق البحث

4-1- الشبكات العصبية الاصطناعية (Artificial Neural Networks) ANNs

الشبكات العصبية الاصطناعية (ANNs) هي أنظمة حسابية تحاكي عمل الدماغ البشري، وتتكون من عقد (عصبونات) مترابطة تقوم بتخزين المعرفة وضبط الأوزان التجريبية؛ وتتميز بمعالجة البيانات على التوازي (Parallel)، مما يمكنها من حل المشكلات المعقدة ذات الفرضيات الكثيرة والمتغيرات بكفاءة وسرعة عالية [11]. يوضح الشكل (2) آلية عمل النموذج العصبي الاصطناعي بعدد عصبونات K.



الشكل رقم (2): نموذج عصبي بعدد عصبونات K [12].

يتم حساب ناتج العصبون الاصطناعي عن طريق تطبيق دالة التنشيط (Activation Function) على المجموع المرجح (Weighted Sum) للإشارات الداخلة، بعد ضرب كل إشارة في وزنها المشبكي وإضافة الانحياز (Bias) [13]. توصف هذه العملية بالمعادلتين الرياضيتين:

$$u_k = \sum_{i=1}^m x_i * w_{ki} \quad \dots \dots (1)$$

$$y_k = f(u_k + b_k) \quad \dots \dots (2)$$

حيث (u_k) ناتج جمع المجموع المرجح؛ (x_i) المدخلات، (w_{ki}) الأوزان المشبكية، (b_k) الانحياز قيمة خاصة تضاف إلى المجموع المرجح للمدخلات، غرضه منح الخلية العصبية حرية إضافية لضبط المخرجات، $f(\cdot)$ دالة التنشيط، (y_k) خرج العصبون k.

4-2- مكونات الشبكات العصبية الاصطناعية (ANN)

تتألف الشبكات العصبية من المكونات الأساسية الآتية أو بعضاً منها على الأقل [14]، وهذه المكونات هي:

- **طبقة الإدخال (Input Layer):** تستقبل هذه الطبقة بيانات المتغيرات المستقلة (مدخلات النموذج) وتوزعها على الطبقات التي تليها دون أي معالجة.
- **الطبقات الخفية (Hidden Layers):** تقع بين طبقتي الإدخال والإخراج، وتجرى فيها معظم العمليات الحسابية عبر تحويلات غير خطية باستخدام دوال تنشيط (Activation Functions).
- يحدد عدد هذه الطبقات وتعقيدها حسب طبيعة المشكلة المراد حلها، ولا توجد قاعدة ثابتة لتحديد عدد الطبقات - بل تختبر تجريبياً لتحسين الأداء [15].
- **طبقة الخرج (Output Layer):** تنتج هذه الطبقة النتائج النهائية للنموذج من معالجة البيانات في الطبقة الخفية [12]، والتي تمثل في هذا البحث المدة والكلفة المتوقعين.

تمثل الأوزان (Weights) قيمة تحدد أهمية أو تأثير كل مدخل على مخرجات الشبكة، وتضبط قيمها أثناء التدريب باستخدام خوارزميات مثل خوارزمية الانتشار العكسي لتقليل الفرق بين التوقعات والقيم الفعلية، وتبدأ القيم الابتدائية للأوزان عشوائياً عادة، مما يؤثر في سرعة التقارب والأداء النهائي [16].




أما معامل الانحياز (Bias) فيضاف إلى حاصل مجموع المدخلات التي ضربت قبل تطبيق دالة التنشيط مما يمنح الشبكة مرونة إضافية في تعلم الأنماط واتخاذ القرارات.

دوال التنشيط (Activation Functions): تعرف أيضاً باسم دوال التحويل (Transfer Functions) - تطبق دالة التنشيط على نتيجة المجموع المرجح لتحديد الناتج النهائي للخلية العصبية، وبدون دالة تنشيط سيكون ناتج الخلية العصبية مزيجاً خطياً بسيطاً من المدخلات، مما يحد من قدرة الشبكة على نمذجة أنماط معقدة وغير خطية. ويجب أن تتميز بالخصائص التالية: أن تكون تابعة مستمرة، قابلاً للاشتقاق مع مشتق سهل الحساب، وأن تكون انسيابية غير متناقصة [17].

تلعب هذه الدوال دوراً محورياً في تحديد آلية تحويل إشارات الدخل إلى إشارات خرج ضمن نطاق محدد، إما بالشكل الثنائي ضمن المجال $\{0, +1\}$ ، أو التمثيل ثنائي القطبية $\{-1, +1\}$ ، للذان يوفران توازناً للمتغيرات وتسهلاً لعملية التدريب، وبالتالي زيادة استقرارية النموذج في النتائج التي سنحصل عليها، وتستخدم ثلاثة أنواع رئيسية - شائعة في بيئة MATLAB - من هذه الدوال (خطية/غير خطية) في طبقات ANN، لكل منها آثار مميزة على الأداء والتطبيق، يوضح الجدول أدناه دوال التنشيط الأكثر شيوعاً [18].

يتم اختيار دوال التحويل عادة عبر المحاولة والخطأ لعدم وجود معيار ثابت، ويلخص الجدول (3) الفروق الأساسية بين الأنواع المستخدمة بكثرة في MATLAB.

الجدول رقم (3): الاختلافات الرئيسية بين دوال التنشيط المستخدمة [18].

الدالة	Linear (Purelin)	Logistic Sigmoid (logsig)	Hyperbolic Tangent (tansig)
$F(x) =$	x	$\frac{1}{1 + e^{(-x)}}$	$\frac{e^x - e^{-x}}{e^x + e^{-x}}$
التمثيل			
النطاق الخطية	$\{-\infty, +\infty\}$ خطي	$\{0, 1\}$ غير خطي	$\{-1, +1\}$ غير خطي

هناك العديد من نماذج الشبكات العصبية الاصطناعية (ANNs) التي تم اقتراحها مؤخراً للتنبؤ بالمدة الزمنية والكلفة التقديرية لأبحاث الهندسة المدنية، وكل نوع من هذه الأنواع له خصوصية في آلية معالجة المعلومات والمعمارية من خلال عدد العصبونات ونوع دوال التنشيط وآلية تعديل الأوزان، استخدمت شبكة الانتشار العكسي ذات التغذية الراجعة (Feedforward- Backpropagation) ضمن بيئة برنامج MATLAB مع خوارزمية تدريب LM (Levenberg-Marquardt) ومعيار متوسط مربعات الأخطاء MSE (Mean Squared Error) لتقييم بنية الشبكة العصبية. تعد خوارزمية LM من التقنيات المثالية في ضبط الأوزان والانحياز، والتي عادة ما تكون أسرع وأكثر موثوقية من خوارزميات الانتشار العكسي الأخرى [19].

تمثل هذه الخوارزمية مزيجاً بين طريقة نيوتن المعدلة وخوارزمية الانحدار التدريجي، وتتميز بسرعة التقارب العالية مما يجعلها مناسبة للشبكات التي تتعامل مع بيانات عالية الجودة [20].

قسمت البيانات خلال فترة اختيار بنية الشبكة إلى ثلاث مجموعات [21]، والغرض من ذلك هو قياس كفاءة الشبكة العصبية الاصطناعية ولمعرفة ما إذا تم تدريب الشبكة الاصطناعية بشكل صحيح أم لا، وهذه المجموعات هي:

• مجموعة التدريب (Training Set)

تمثل النسبة الأكبر من البيانات غالباً وتستخدم لتعديل الأوزان ومعاملات الانحياز في الشبكة، الهدف الأساسي منها هو تمكين النموذج من تعلم الأنماط الكامنة في البيانات وتقليل خطأ التدريب.

• مجموعة التحقق (Validation Set)

تستخدم أثناء عملية التدريب لمراقبة أداء الشبكة على بيانات مستقلة عن التدريب بهدف تجنب مشكلة الإفراط في التعلم (overfitting)، عند ملاحظة تدهور الأداء على هذه المجموعة يمكن إيقاف التدريب مبكراً [22].

• مجموعة الاختبار (Testing Set)

تستخدم بعد اكتمال التدريب لتقييم الأداء النهائي للنموذج على بيانات لم تستخدم في أي مرحلة من مراحل الضبط أو التدريب.

3-4- تقييم أداء النموذج المقترح

يمكن تعريف مقياس الأداء على أنه بناء منطقي ورياضي مصمم لقياس مدى قرب النتائج الفعلية من المتوقعة [23]، ونظراً لعدم وجود مقياس واحد يعد الأنسب لتقييم دقة التنبؤات، يوصى بمقارنة عدة مقاييس إحصائية للحكم على دقة وكفاءة النموذج، نذكر منها:

- الجذر التربيعي لمتوسط مربعات الخطأ RMSE (Root Mean Square Error):

$$RMSE = \sqrt{MSE} = \sqrt{\frac{\sum (Y_t - \hat{Y}_t)^2}{n}} \dots \dots (3)$$

حيث: n : عدد القيم، Y_t : القيم الحقيقية، $\hat{Y}_t$: القيم المتنبأ بها.

- متوسط الخطأ المطلق MAE (Mean Absolute Error):

$$MAE = \frac{\sum_{t=1}^n |Y_t - \hat{Y}_t|}{n} \quad \dots \dots (4)$$

كلما اقترب مؤشر RMSE، MAE من الصفر يعني هذا أن كفاءة النماذج عالية في التنبؤ.

- متوسط الخطأ النسبي المطلق MAPE (Mean Absolute Percentage Error):

$$MAPE = \frac{1}{n} * \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| * 100 \quad \dots \dots (5)$$

- معامل كفاءة ناش NSE (Nash–Sutcliffe model efficiency coefficient)

$$NSE = 1 - \left[\frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{\sum_{t=1}^n (Y_t - \bar{y}_i)^2} \right] \quad \dots \dots (6)$$

- معامل الارتباط R (Correlation Coefficient):

$$R = \frac{\sum_{t=1}^n (Y_t - \bar{Y}_t)(\hat{Y}_t - \bar{\hat{Y}})}{\sqrt{\sum_{t=1}^n (Y_t - \bar{Y}_t)^2 * \sum_{t=1}^n (\hat{Y}_t - \bar{\hat{Y}})^2}} \quad \dots \dots (7)$$


4-4- إعداد واجهة تصميم وتدريب النموذج العصبي (ANN)

تم اعتماد بيئة MATLAB 2016a لتطوير النموذج العصبي في هذا البحث لما توفره من مميزات متكاملة، حيث تشمل حزمة Neural Network Toolbox المتخصصة إطار عمل مجرب لبناء وتدريب الشبكات العصبية بكفاءة عالية، بالإضافة إلى مرونة برمجية تتيح تطوير خوارزميات مخصصة لأتمتة اختبار النماذج المتعددة، مع إمكانية تطوير واجهات تطبيقية (GUI).

للتغلب على القيود التي تواجهها الواجهات الجاهزة في برنامج MATLAB مثل (nftool; nntool; nnstart) المتمثلة بمحدودية التحكم في معالجة البيانات وصعوبة حفظ إعدادات النماذج - تم تطوير واجهة مستخدم رسومية (GUI) مخصصة. تدمج هذه الواجهة جميع مراحل العمل البحثي ضمن بيئة واحدة موحدة، توفر مرونة عالية في ضبط الإعدادات وتجريب آلاف النماذج الشبكية تلقائياً لتحديد البنية الأمثل.

تميزت الواجهة المطورة بمجموعة من الميزات المتكاملة، شملت: الأتمتة الشاملة لاختبار تركيبات دوال التنشيط وعدد العصبونات، وإدارة مرنة لتقسيم البيانات بعدة طرق (يدوية، متسلسلة، وعشوائية)، وتقييم أداء معياري عبر حساب مؤشرات الأداء مثل (R, RMSE) لكل مجموعة (تدريب، تحقيق، اختبار)، مع توثيق منظم للنتائج في ملفات (Excel) كما وفرت آلية منهجية لاختيار النموذج الأمثل (تصميم الشبكة) من حيث عدد العصبونات في الطبقة الخفية، ودوال التنشيط (Tansig, Logsig, Purelin) في كل من الطبقة الخفية وطبقة الخرج، من خلال فحص شامل لأدائه الإحصائي، مع إمكانية إعادة التدريب لضمان استقرار النتائج، بالإضافة إلى ضبط بارامترات التدريب مثل الخوارزمية (trainlm) وعدد التكرارات (Epochs) ومعدل التعلم (Learning Rate)، وعرض منحنيات الأداء (Mse VS Epochs)، وتحليل الأخطاء إضافة إلى تمثيل النتائج على شكل مخططات وجدول بيانات.

يوضح الشكل (3) واجهة مستخدم رسومية (GUI) تم تطويرها ضمن بيئة (MATLAB R2016a).



الشكل رقم (3): واجهة المستخدم GUI الخاصة بتصميم وتدريب نماذج ANN.

بعد اكتمال عملية التدريب، يوفر التطبيق مجموعة متكاملة من أدوات التحليل والتقييم، تشمل عرض منحنيات الأداء (Mse VS Epochs) ورسم العلاقة بين القيم المتوقعة والفعلية، وعرض بنية الشبكة الأمثل، بالإضافة إلى عرض النتائج في جداول بيانية مع حساب مؤشرات الأداء الإحصائية لكل من مجموعات البيانات. هذه الميزات تتيح للمستخدم تقييمًا شاملاً ومرناً للنماذج المبنية، مما يجعل التطبيق أداة فعالة في سياق النمذجة التنبؤية باستخدام الشبكات العصبية الاصطناعية. يوضح الشكل (4) واجهة مستخدم رسومية (GUI) فرعية لعرض نتائج المجموعات الثلاث (تدريب، تحقيق، اختبار) والأداء الإحصائي لكل منها.

تكمن الأهمية العلمية لهذه الواجهة في تبسيط عمليات النمذجة والمحاكاة، حيث توفر بيئة بحثية مرنة تسمح بتعديل المعاملات وإدخال البيانات ومشاهدة النتائج بصرياً وبشكل فوري.



الشكل (4): عرض نتائج محاكاة النموذج العصبي (ANN).

5- النتائج ومناقشتها

تم تصميم النماذج العصبية (ANN) المختارة باعتماد بنية ذات طبقة خفية (hidden Layers) واحدة، بما يتلاءم مع طبيعة المشكلة المعالجة وحجم مجموعة البيانات، وذلك لتحقيق توازن أمثل بين قدرة النموذج على التعلم وتجنب التدريب المفرط (Overfitting).

ولتدريب هذا النموذج، تم استخدام خوارزمية LM (Levenberg–Marquardt) الشائعة الاستخدام نظراً لكفاءتها العالية في تحقيق سرعة تقارب فائقة، حيث تجمع بين خصائص طريقة نيوتن (للتقارب السريع) وطريقة الانحدار (للاستقرار)، مما يجعلها مثالية للتدريب على الشبكات ذات الأحجام الصغيرة إلى المتوسطة مثل النموذج المطور في الدراسة.

تم تحديد البنية (Structure) الأمثل للشبكة العصبية من خلال الاختبار الآلي الممنهج ضمن الواجهة الرسومية (GUI) للتطبيق، وتضمنت هذه العملية على تقييم مجموعة من التصاميم المختلفة لشبكة الانتشار العكسي ذات التغذية الراجعة (Feedforward–Backpropagation)، والتي شملت المعاملات الرئيسية التالية:


- دوال التنفيع (Activation functions): تم اختبار أنماط مختلفة من الدوال (Logsig, Tansig, Purelin) في الطبقتين الخفية والخروج، حيث يعتبر ترتيب واختيار هذه الدوال عاملاً حاسماً في كفاءة النموذج.
- عدد العصبونات (Neurons Number): تم استكشاف المدى التجريبي لعدد العصبونات في الطبقة الخفية من 20 إلى 50 عصبوناً بخطوة انتقال قدرها 2 عصبون، للتوصل إلى العدد الأمثل الذي يتجنب الإفراط في التدريب (Overfitting) ويحقق أداء تنبؤياً عالياً.
- معايير التدريب: جرى تشغيل كل تصميم ضمن إطار تحكم ثابت، حيث استخدمت مجموع مربعات الخطأ (RMSE) ومعامل الارتباط (R) كمعايير لتقييم الأداء (Performance) والمفاضلة بين النماذج من حيث درجة الملائمة (Fitness)، كما حدد عدد التكرارات (Epochs) بـ 500 تكرار، وعدد مرات إعادة التدريب (Retrain) مرة واحدة لكل نموذج، ومعدل التعلم (0.001).
- يبين الجدول (4) بارامترات النموذج العصبي المستخدمة في تحديد البنية الأمثل (دوال التنفيع، عدد العصبونات) للنموذج، بهدف تجنب تعقيد مع تحقيق أفضل النتائج الممكنة.

الجدول رقم (4): بارامترات النماذج العصبية (ANN) المرشحة لاختيار البنية الأمثل

Parameters	Setting
Network type	Feed-forward back propagation
Number of hidden neurons	From 20 to 50, step2
Training function	Levenberg–Marquardt (Trainlm)
Data division	Random
Activation functions	Logsig, Tansig, Purelin
Performance	RMSE; R
Epochs	500
Learning rate	0.001
Retrain	1
Calculation	MATLAB
Sampling	
Training	samples)18470%, (
Testing	samples)3915%, (
Validation	samples)3915%, (

يبين الشكل (5) هيكلية النموذج العصبي [2-36-6] ANN المقترح، الموافق لـ 6 عصبونات في طبقة الدخل (Input Layer) تمثل متغيرات الدخل، و36 عصبون في الطبقة الخفية (Hidden Layer) يتم فيها معالجة ناتج ضرب الأوزان


بالمدخلات وإضافة معاملات الانحياز الخاصة بكل عصبون قبل تمريرها على دوال التنفيع مع استخدام دالة التنفيع (logsig) في الطبقة الخفية، و2 عصبون في طبقة الخرج (Output Layer) تمثل نتائج محاكاة كل من المدة والكلفة، مع استخدام دالة التنفيع (purline) في طبقة الخرج.




الشكل رقم (5): بنية النموذج العصبي ANN [6-36-2] الأفضل في محاكاة مدة وكلفة المشروع.

أظهر النموذج ANN [2-36-6] أداء متفوقاً في تقدير كل من المدة والكلفة لمشاريع إعادة تأهيل المدارس، وذلك بناءً على مقاييس الأداء الإحصائية (R , RMSE)، مقارنةً بالنماذج الأخرى التي تم اختبارها، حيث أظهرت نتائج محاكاة مدة المشروع معامل ارتباط بلغ ($R=0.97$) والموافق لجذر متوسط مربعات الأخطاء ($RMSE=3.28$ days)، كما هو موضح في الشكل (6).

أما فيما يتعلق بمحاكاة كلفة المشروع، بلغ معامل الارتباط ($R=0.99$) مع جذر متوسط مربعات الأخطاء ($RMSE=4.9106$ million)، كما هو موضح في الشكل (7).



الشكل رقم (6): نتائج النماذج العصبية المرشحة لاختيار النموذج الأمثل ANN [2-36-6] لمحاكاة مدة المشروع.



الشكل رقم (7): نتائج النماذج العصبية المرشحة لاختيار النموذج الأمثل ANN [6-36-2] لمحاكاة كلفة المشروع. يبين الجدول (5) نتائج المعايير الإحصائية (R, RMSE) لأفضل خمس نماذج عصبية في الأداء والتي تظهر تفوق تصميم النموذج ANN [6-36-2] في محاكاة كل من مدة وكلفة مشاريع إعادة تأهيل المدارس المتضررة في محافظة حماة. الجدول رقم (5): نتائج المعايير (R, RMSE) لأفضل خمس نماذج عصبية في الأداء.

النموذج	دالة التنفيل في الطبقة الخفية	دالة التنفيل في طبقة الخرج	نتائج المحاكاة	Regression	RMSE
[6-36-2]	logsig	Purelin	المدة	0.965	3.289
			الكلفة	0.991	4.911
-2]34[6-	tansig	Purelin	المدة	0.964	3.564
			الكلفة	0.988	5.550
-2]32[6-	tansig	tansig	المدة	0.961	3.631
			الكلفة	0.987	5.992
-2]24[6-	logsig	Purelin	المدة	0.965	3.452
			الكلفة	0.986	6.062
[6-32-2]	logsig	Purelin	المدة	0.968	3.290
			الكلفة	0.986	6.091


أظهرت نتائج تقييم النموذج العصبي ANN [6-36-2] الموضحة في الجدول (6) كفاءة في تقدير مدة وكلفة المشاريع، حيث اقتربت قيم معامل الارتباط R من الواحد (0.973 للمدة و0.989 للكلفة) مما يشير إلى قوة العلاقة بين التوقعات والقيم الفعلية، كما تدعم قيم معامل ناش-سوتكليف NSE المرتفعة (أعلى من 0.9 لدى جميع المجموعات) كفاءة النموذج في محاكاة البيانات الحقيقية، بينما تؤكد قيم الأخطاء المنخفضة نسبياً على دقته، حيث سجلت مقاييس RMSE و MAPE أدنى مستوياتها في مجموعة التدريب (2.75 و 8.96 للمدة على التوالي) مع ارتفاع طفيف في مجموعتي التحقق والاختبار الذي يبقى ضمن النطاق المقبول، كذلك الأمر بالنسبة إلى تقدير الكلفة حيث حافظ النموذج على أداء متجانس بين مجموعات البيانات مما يؤكد متانته وغياب مشكلة الإفراط في التدريب.

الجدول رقم (6): نتائج المعايير الإحصائية في تقدير مدة وكلفة المشروع وفق المجموعات الثلاث (تدريب، تحقق اختبار).


	Nu#	Parameter	RMSE	R	NSE	MAD	MAPE
All Data	262	Time	3.289	0.965	0.945	2.13	10.44
		Cost	4.911	0.991	0.978	3.86	36.77
Train Set	184	Time	2.75	0.979	0.959	1.79	8.96
		Cost	4.90	0.990	0.979	3.42	32.83
Validation Set	39	Time	3.79	0.948	0.896	3.03	14.92
		Cost	6.46	0.991	0.981	5.28	45.54
Test Set	39	Time	3.47	0.955	0.908	2.84	12.93
		Cost	6.26	0.983	0.966	4.50	46.57

تظهر مخططات الارتباط لأداء النموذج العصبي [6-36-2] بين القيم المتوقعة والفعلية لمجموعات البيانات الثلاث (التدريب، التحقق، والاختبار) في الشكل (8) والشكل (9) كفاءة تنبؤية عالية لكل من مدة المشروع وتكلفته، حيث تتجمع نقاط البيانات حول خط (1:1) في مجموعات التدريب والتحقق والاختبار.

وسجلت معاملات الارتباط قيما مرتفعة ومتقاربة عبر المجموعات الثلاث (0.973 للمدة و0.989 للتكلفة في البيانات الكلية)، مع احتفاظ النموذج بأداء متجانس في مجموعتي التحقق والاختبار مما يؤكد متانته وغياب الإفراط في التدريب، وهو ما يعزز موثوقيته كأداة فعالة في تقدير المدة والكلفة.



الشكل رقم (8): معاملات الارتباط في المجموعات الثلاث (تدريب-تحقيق - اختبار) لمحاكاة النموذج ANN [6-36-2] لمدة المشروع.



الشكل رقم (9): معاملات الارتباط في المجموعات الثلاث (تدريب-تحقيق - اختبار) لمحاكاة النموذج ANN [6-36-2] لكلفة المشروع.

يظهر تحليل الأداء الإحصائي في الجدول (7) كفاءة النموذج العصبي ANN[2-36-6] في التعميم والتنبؤ بدقة عبر نطاق القيم كافة، حيث يحافظ نموذج المحاكاة على تقارب ملحوظ بين المتوسطات الحقيقية والمتوقعة مع تقارب الانحراف المعياري عبر مجموعات البيانات الثلاث.

كما تؤكد دقة توقعاته للقيم العظمى والدنيا - رغم هوامش الخطأ المطلق (Absolute Error) المقبولة - متانة النموذج وقدرته على محاكاة الواقع في تقدير المدة والكلفة، مما يجعله أداة موثوقة لدعم قرارات إدارة المشاريع.


الجدول رقم (7): الثوابت الإحصائية للقيم الفعلية (المدة، الكلفة) والقيم الناتجة عن النموذج العصبي.

Set	#	التكلفة			المدة		
		Target	Output	AE	Target	Output	AE
All Data	Mean	26.6	26.9	0.3	25.1	24.9	0.2
	St. Dv	36.2	36.5	0.2	13.0	12.6	0.4
	Max	267.0	276.5	9.5	90.0	89.8	0.2
	Min	1.1	0.2	0.9	10.0	12.1	2.1
Train	Mean	27.1	27.2	0.1	25.7	25.7	0.0
	St. Dv	34.1	34.3	0.2	13.6	13.3	0.3
	Max	218.3	218.0	0.3	90.0	89.8	0.2
	Min	1.1	4.1	3.0	11.0	12.1	1.1
Validation	Mean	26.9	27.2	0.3	23.8	23.3	0.6
	St. Dv	46.8	47.9	1.1	11.7	10.7	1.0
	Max	267.0	276.5	9.5	65.0	67.9	2.9
	Min	2.1	0.2	2.0	10.0	13.6	3.6
Test	Mean	24.1	25.2	1.1	23.8	22.9	0.9
	St. Dv	33.7	32.8	0.8	11.3	10.9	0.5
	Max	206.8	202.4	4.4	60.0	52.4	7.6
	Min	2.0	4.1	2.1	10.0	13.3	3.3


يظهر التمثيل البياني (الأشكال 10-13) للقيم الفعلية والقيم الناتجة عن محاكاة المدة والكلفة للمشاريع في مرحلتي التحقيق والاختبار - درجة عالية من التطابق بين القيم الفعلية والمتنبأ بها، مع قدرة ملحوظة على تتبع الأنماط غير الخطية والمعقدة في البيانات.

أما مخططات توزيع الأخطاء (الشكل 14 للمدة، والشكل 15 للكلفة) فتظهر تركيزاً واضحاً للفروقات حول الصفر مع توزيع طبيعي ضيق النطاق، مما يؤكد دقة النموذج وخلوه من الانحياز في المراحل الثلاث (تدريب، تحقيق، اختبار).


هذا الثبات في مستوى الدقة عبر مجموعات البيانات المختلفة، مع القدرة على محاكاة القيم المتطرفة واحتواء هامش الخطأ ضمن حدود مقبولة، يعد دليلاً على متانة النموذج وقابليته للتعميم، مما يجعله أداة موثوقة لدعم عمليات اتخاذ القرار في مجال إدارة المشاريع.




الشكل رقم (10): القيم الفعلية والقيم الناتجة عن النموذج العصبي ANN في محاكاة مدة المشروع (مرحلة التحقيق).




الشكل رقم (11): القيم الفعلية والقيم الناتجة عن النموذج العصبي ANN في محاكاة مدة المشروع (مرحلة الاختبار).



الشكل رقم (12): القيم الفعلية والقيم الناتجة عن النموذج العصبي ANN في محاكاة كلفة المشروع (مرحلة التحقق).



الشكل رقم (13): القيم الفعلية والقيم الناتجة عن النموذج العصبي ANN في محاكاة كلفة المشروع (مرحلة الاختبار).




الشكل رقم (14): تكرار الأخطاء الناتجة عن محاكاة النموذج العصبي لمدة المشروع في المجموعات تدريب والتحقيق والاختبار.




الشكل رقم (15): تكرار الأخطاء الناتجة عن محاكاة النموذج العصبي لكلفة المشروع في المجموعات تدريب والتحقيق والاختبار.

تظهر نتائج مخطط الانتشار للقيم المتبقية (Residuals) للنموذج العصبي (المجموعة الاختبار) في الشكل (16) الخاص بتقدير كلفة المشروع والشكل (17) الخاص بتقدير مدة المشروع، انتشارا عشوائيا للنقاط حول المحور الصفري دون وجود أي نمط أو اتجاه واضح، مما يؤكد ثبات التباين في أخطاء النموذج، ويعزز وقدرة النموذج على تقديم تنبؤات غير منحازة عبر النطاق الكلي للبيانات.



الشكل رقم (16): مخطط انتشار الخطأ بتقدير كلفة المشروع.



الشكل رقم (17): مخطط انتشار الخطأ بتقدير مدة المشروع.

بهدف تقديم بديل عملي وفعال لطريقة التنفيذ التقليدية المعتمدة على كتابة الأكواد البرمجية مباشرة، تم إنشاء الواجهة الموضحة في الشكل (18) باستخدام أدوات تطوير (Guide) المتكاملة في MATLAB، حيث تم تصميم تخطيط مرئي يتضمن مربعات إدخال، وأزرار تحكم، ومناطق عرض رسومية، وربط جميع هذه العناصر بوظائف ودوال (Callbacks) مسؤولة عن تنفيذ النموذج الرياضي وإجراء الحسابات. وبالتالي، تجسد هذه الأداة خلاصة الجهد البحثي في شكل تطبيق تفاعلي وسهل الاستخدام، يسهل مشاركته وتطويره لمزيد من التطبيقات المستقبلية.

mais

تقدير كلفة ومدة إعادة تأهيل المدارس

المدخلات

ضرر البلاط: 0 خفيف

حجم الضرر العام: 0 خفيف

ضرر التمديدات الصحية: 0 خفيف

ضرر الحريق: 0 خفيف

النموذج المدرسي: 1 عدد الطوابق 2... نموذج 73/أ

الموقع الجغرافي: 1 أقل من 10 كم

النتائج

المدة الزمنية (اليوم):

الكلفة (مليون ل.س):

إعادة تعيين

دليل ترميز البيانات

عرض النتيجة

عرض الشبكة العصبونية

الشكل رقم (18): واجهة مستخدم (GUI) لتقدير مدة وكلفة مشاريع إعادة تأهيل المدارس.

أظهرت نتائج هذا البحث كفاءة عالية للنموذج العصبي الاصطناعي المطور [2-36-6] ANN في التنبؤ بكل من مدة وتكلفة مشاريع إعادة تأهيل المدارس، حيث حقق معاملات ارتباط بلغت ($R = 0.973$ للمدة و $R = 0.989$ للتكلفة) وقيم أخطاء منخفضة ($RMSE = 3.04$ يوم للمدة و $RMSE = 5.38$ مليون للتكلفة).

هذه الدقة العالية تتوافق مع ما أكدته دراسة (Chen & Huang, 2006) [1] حول تفوق نماذج ANN في تحقيق دقة تنبؤية تفوق 90% عند معالجة بيانات مشاريع إعادة التأهيل، كما تعززها نتائج (Kim et al. 2021) [2] التي سجلت تفوق الشبكات العصبية بنسبة 86% في الدقة مقارنة بالأساليب الإحصائية التقليدية.

تميز النموذج الحالي بقدرته على التعامل مع العلاقات الغير خطية والمعقدة بين متغيرات الضرر (كمدخلات) ومتغيري المدة والتكلفة (كمخرجات)، وهي ميزة أكدت بشكل خاص دراسة (Charalambos et al, 2014) [3] عند دمجها لنمذجة المعلومات (BIM) مع ANN لإدارة تعقيدات مشاريع إعادة التأهيل.

كما أن البنية المثلى للنموذج [6-36-2]، التي توازن بين البساطة والدقة عبر استخدام 36 عصبوناً في الطبقة الخفية، تتفق مع النهج الذي اتبعته دراسة (Papadimitriou & Aretoulis. 2024) [6] في تحقيق دقة عالية (خطأ نسبي $\approx 0\%$) باستخدام نموذج مبسط بمعاملات محددة.

علاوة على ذلك، فإن أداء النموذج المتجانس عبر مجموعات البيانات الثلاث (التدريب، التحقق، الاختبار)، مع الحفاظ على دقة عالية في مجموعة الاختبار غير المرئية خلال التدريب، يثبت متانة النموذج وغياب الإفراط في التدريب (Overfitting) وهذا ما يتطابق مع استنتاجات (Cirilovic et al. 2014) [5] حول قدرة نماذج ANN على التعميم الجيد عند اختبارها على مشاريع من سياقات مختلفة، كما تدعمها آلية التقسيم العشوائي للبيانات التي أوصت بهادراسة (Shehab & Farooq. 2013) [4].

من جهة أخرى، تبرز هذه الدراسة ميزة عملية إضافية من خلال دمج النموذج العصبي ضمن واجهة مستخدم رسومية (GUI)، وهو تطور عملي يسهل نشر الأداة البحثية واستخدامها من قبل المخططين ومديري المشاريع في الميدان دون الحاجة إلى خبرة برمجية.

هذا الجانب التطبيقي يسد فجوة أشارت إليها العديد من الدراسات السابقة [7] [8]، التي ركزت على التطوير النظري للنماذج دون تقديم حلول تطبيقية سلسلة قابلة للتطبيق الميداني المباشر في ظل ظروف نقص الموارد والبيئات غير المستقرة. تتوافق دقة ومتانة النموذج المطور مع نتائج الأدبيات السابقة، مما يعزز من مصداقية تطبيق تقنيات الذكاء الاصطناعي في مجال إدارة مشاريع إعادة التأهيل والترميم، وهنا تبرز الحاجة إلى تقديم إطار عملي ملموس، من خلال الواجهة الرسومية (GUI) القابلة للنشر على نطاق واسع. تسهم هذه الأداة في سد الفجوة بين البحث النظري والتطبيق العملي، وتمهد الطريق لتبني هذه التقنيات المتقدمة في سياقات تنفيذية حقيقية لدعم عمليات إعادة الإعمار واتخاذ القرار في المناطق المتضررة.

6- الاستنتاجات والتوصيات

1. أثبت النموذج العصبي الاصطناعي ANN بنيته [2-36-6] كفاءة تنبؤية في تقدير كل من المدة والكلفة لمشاريع إعادة تأهيل المدارس، مما يدل على قدرته في التعامل مع البيانات غير الخطية ويجعله أداة موثوقة لدعم قرارات التخطيط في سياق إعادة الإعمار.
2. أظهر تحليل الأخطاء ومنحنيات التدريب والتحقق والاختبار أن النموذج يتمتع باستقرار جيد ولم يقع في مشكلة التدريب المفرط حيث بقيت فروق الخطأ بيت التدريب والتحقق متوازنة.
3. ساهم تطوير واجهة مستخدم رسومية (GUI) في تحويل النموذج التنبؤي إلى أداة تطبيقية مرنة الاستخدام من قبل الجهات المعنية وغير المختصين وتقلل من هامش الخطأ والوقت اللازم للتقديرات.
4. أكدت الدراسة على أهمية اتباع منهجية دقيقة في تحضير البيانات وتصميم واختيار بنية الشبكة العصبية لتجنب الإفراط في التدريب وضمان قدرة النموذج على التعميم.
5. أكدت الدراسة على تفوق الشبكات العصبية الاصطناعية على الأساليب التقليدية نظراً لقدرتها على التقاط العلاقات غير الخطية والمعقدة بين المتغيرات واستخلاص الأنماط الخفية ضمن البيانات الميدانية مما مكننا من الوصول إلى تقديرات أكثر دقة وموثوقية وساهم في سرعة اتخاذ القرار كون الأساليب التقليدية تحتاج إلى مزيد من الوقت في ظروف تستوجب سرعة الاستجابة..
6. نوصي باعتماد منهجية تفصيلية لتقييم الأضرار ليشمل تصنيفاً دقيقاً للعناصر الإنشائية المتضررة (مثل الأعمدة، الجسور، الأسقف، الجدران الحاملة) بشكل مستقل، نظراً للدور الحاسم لهذه العناصر في تحديد الكلفة والمدة الفعلية لمشاريع إعادة التأهيل.
7. كما نوصي بدمج النموذج العصبي (ANN) ونمذجة معلومات البناء (BIM) للربط بين التقديرات التنبؤية والنماذج الرقمية التفصيلية للمباني، مما يمكن من محاكاة سيناريوهات إعادة التأهيل المختلفة بصرياً وكمياً، وتقديم تقارير تنبؤية فورية حول الأولويات، وتوزيع الموارد، وتقدير الميزانيات بشكل ديناميكي.

7- المراجع

- [1]. Chen, W. T; & Huang, Y. (2006). Approximately predicting the cost and duration of school reconstruction projects in Taiwan. Construction Management and Economics, 24(12), 1231–1239. <https://doi.org/10.1080/01446190600953805>
- [2]. Kim, J; Yum, S; Son, S; Son, K; & Bae, J. (2021). Modeling Deep Neural Networks to Learn Maintenance and Repair Costs of Educational Facilities. Buildings, *11*(4), 165. <https://doi.org/10.3390/buildings11040165>.

- [3]. Charalambos, G; Dimitrios, V; & Symeon, C. (2014). Damage Assessment, Cost Estimating, and Scheduling for Post-Earthquake Building Rehabilitation Using BIM. *Computing in Civil and Building Engineering* (2014), 398–405. <https://doi.org/10.1061/9780784413616.050>.
- [4]. Shehab, T; & Farooq, M. (2013). Neural network cost estimating model for utility rehabilitation projects. *Engineering, Construction and Architectural Management*, 20(2), 118–126. <https://doi.org/10.1108/09699981311302991>
- [5]. Cirilovic, J; Vajdic, N; Mladenovic, G; & Queiroz, C. (2014). Developing cost estimation models for road rehabilitation and reconstruction: Case study of projects in Europe and Central Asia. *Journal of Construction Engineering and management*, 140(3), 04013065. [https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0000817](https://doi.org/10.1061/(ASCE)CO.1943-7862.0000817)
- [6]. Papadimitriou, V. E; & Aretoulis, G. N. (2024). A Final Cost Estimating Model for Building Renovation Projects. *Buildings*, 14(4), 1072. <https://doi.org/10.3390/buildings14041072>.
- [7]. Akhbari, M. (2018). Project time and cost forecasting using Monte Carlo simulation and artificial neural networks. *Int. J. Ind. Eng. Prod. Res*, 29(2), 231–239.
- [8]. Trijeti, Irwanto, R; Rahayu, T; & Panudju, A. T. (2023). Artificial Neural Networks for Construction Project Cost and Duration Estimation. *Revue d'Intelligence Artificielle*, 37(6), 1449–1460.
- [9]. Safapour, E; Kermanshachi, S; & Nipa, T. J. (2020, June). Analysis of cost performance indicators in reconstruction projects: a comparative study of low vs high level damages. In *Creative Construction e-Conference 2020*. Budapest University of Technology and Economics.
- [10]. Castro Miranda, S. L; Del Rey Castillo, E; Gonzalez, V; & Adafin, J. (2022). Predictive analytics for early-stage construction costs estimation. *Buildings*, 12(7), 1043
- [11]. MAKRIDAKIS, S; WHEELWRIGHT, S. C; HYNOMAN, R. J. (1998). *Forecasting Methods and Application*. New York: John Wiley & Sons, 1998, 1–8.
- [12]. Haykin, S (2009). *Neural Networks and Learning Machines*; Prentice Hall: Pearson Upper Saddle River, NJ, USA.
- [13]. Wang, X; Liu, Y; & Xin, H. (2021). Bond strength prediction of concrete-encased steel structures using hybrid machine learning method. *Structures*, 32, 2279–2292. <https://doi.org/10.1016/j.istruc.2021.04.018>

- [14]. Zurada, J. M (1992). Introduction to Artificial Neural Systems. West Publishing Company, U.S.A.
- [15]. Wilmot, C.G; Mei, B (2005). Neural Network Modeling of Highway Construction Costs. Journal of Construction Engineering and Management ASCE.
- [16]. Jain, S. K; Singh, V. P (2003). Applications of artificial neural networks to water resources. Water and Environment International Conference (WE-2003), Bhopal, India.
- [17]. Zupan, J. (1994). Introduction to Artificial Neural Network (ANN) Methods: What They Are and How to Use Them. Acta Chimica Slovenica, 41(3), 327–352
- [18]. Yaldi, G; M. Nur, I; & Apwiddhal, (2020). Calibrating Trip Distribution Neural Network Models with Different Scenarios of Transfer Functions Used in Hidden and Output Layers. International Journal on Advanced Science, Engineering and Information Technology, 10(6), 2410–2418. <https://doi.org/10.18517/ijaseit.10.6.7189>
- [19]. Hagan, M.T; Menhaj, M.B (1994). Training feed forward networks with Marquardt algorithm. IEEE Trans Neural, 989–993.
- [20]. Al-Shamisi, M. H; H; A; & N. Hejase, H. A. (2011). Using MATLAB to Develop Artificial Neural Network Models for Predicting Global Solar Radiation in Al Ain City – UAE. In A. Assi (Ed.), Engineering Education and Research Using MATLAB. InTech. <https://doi.org/10.5772/25213>
- [21]. Shahin, M; Maier, H. R; & Jaksa, M. B. (2004). Data Division for Developing Neural Networks Applied to Geotechnical Engineering. Journal of Computing in Civil Engineering, 18(2), 105–114. [https://doi.org/10.1061/\(ASCE\)0887-3801\(2004\)18:2\(105\)](https://doi.org/10.1061/(ASCE)0887-3801(2004)18:2(105))
- [22]. Mehrotra, K; Mohan, C. K; & Ranka, S. (1997). Elements of artificial neural networks. MIT Press.
- [23]. Botchkarev, A. (2019). A New Typology Design of Performance Metrics to Measure Errors in Machine Learning Regression Algorithms. Interdisciplinary Journal of Information, Knowledge, and Management, 14, 045–076. <https://doi.org/10.28945/4184>