

A Proposed Model for Predicting Cost and Schedule Overruns Caused by Risks in Bridge Construction Projects

Rasha Nasr Osefory* 
Dr. Fayez Jarad**

(Received 9 / 7 / 2025. Accepted 20 / 8 / 2025)

□ ABSTRACT □

Bridge projects in Syria face complex challenges due to unforeseen risks that impact costs, schedules, and execution quality, making risk management essential for ensuring planned project delivery.

This study proposes an advanced predictive model using Artificial Neural Networks (ANN) to analyze and evaluate the impact of various risks on bridge projects in Syria.

A comprehensive methodology was adopted, including a field study of 45 completed bridge projects and a specialized questionnaire distributed to experts to identify and classify key risk factors. Based on this data, two models were developed using Multilayer Perceptron (MLP) neural networks: one for predicting cost overruns and the other for schedule delays.

The models demonstrated high predictive accuracy, with R^2 values of 0.95 for cost and 0.94 for schedule delays. Sensitivity analysis identified the most influential factors: economic risks such as inflation and price fluctuations were the main drivers of cost overruns, while poor planning and design were leading causes of schedule delays. These findings highlight the urgent need for proactive, data-driven strategies based on the proposed model to effectively manage risks in Syria's bridge construction sector.

Keywords: Risk management, bridge projects, cost & schedule delay, artificial neural networks (ANN), sensitivity analysis.

Copyright  :Latakia University journal(Formerly Tishreen)-Syria, The authors retain the copyright under a CC BY-NC-SA 04

* Master's Student, Department of Management and Construction Engineering, Faculty of Civil Engineering, Latakia University(Formerly Tishreen), Latakia, Syria. Rasha.osefory@gmail.com

**Professor, Department of Management and Construction Engineering, Faculty of Civil Engineering, Latakia University(Formerly Tishreen), Latakia, Syria. Fayezalijrad@gmail.com

اقتراح نموذج للتنبؤ بانحرافات الكلفة والزمن التي تسببها مخاطر مشاريع الجسور

رشا نصر عصفوري* 

د. فايز جراد**

(تاريخ الإيداع 2025 / 7 / 9. قُبِلَ للنشر في 2025 / 8 / 20)

□ ملخص □

تواجه مشاريع الجسور في سوريا تحديات معقدة ناجمة عن مخاطر غير متوقعة تؤثر على التكاليف والجدول الزمني وجودة التنفيذ، مما يجعل إدارة المخاطر عنصراً حيوياً لضمان تنفيذ المشاريع وفق المعايير المخططة. تقدم هذه الدراسة نموذجاً تنبؤياً متطوراً يعتمد على الشبكات العصبية الاصطناعية (ANN)، لتحليل وتقييم تأثير المخاطر المختلفة على مشاريع الجسور في سوريا.

اعتمد البحث على منهجية شاملة تضمنت دراسة ميدانية لـ 45 مشروع جسر منفذ في سوريا، بالإضافة إلى تصميم استبيان متخصص تم توزيعه على خبراء في المجال لتحديد وتصنيف أهم عوامل الخطر. بناءً على هذه البيانات، تم تطوير نموذجين باستخدام الشبكات العصبية متعددة الطبقات (MLP): خصص النموذج الأول للتنبؤ بانحرافات التكلفة، بينما ركز الثاني على التنبؤ بانحرافات الجدول الزمني.

أظهرت النتائج دقة تنبؤية عالية للنموذجين، حيث سجل معامل التحديد (R^2) قيمة بلغت 0.95 و 0.94 على التوالي. كما كشف تحليل الحساسية عن العوامل الأكثر تأثيراً، حيث تصدرت المخاطر الاقتصادية مثل التضخم وتقلبات الأسعار قائمة مسببات انحراف التكلفة، بينما كان سوء التخطيط والتصميم من أبرز مسببات التأخير الزمني. هذه النتائج تبرز الحاجة الملحة لتطوير استراتيجيات استباقية قائمة على النموذج المقترح للتعامل مع هذه المخاطر في قطاع مشاريع الجسور في سوريا.

الكلمات المفتاحية: إدارة المخاطر، مشاريع الجسور، انحراف الكلفة و الزمن، الشبكات العصبية الاصطناعية ، تحليل الحساسية.



حقوق النشر : مجلة جامعة اللاذقية (نشرين سابقاً) - سورية، يحتفظ المؤلفون بحقوق النشر بموجب

الترخيص CC BY-NC-SA 04

* طالبة ماجستير ، قسم هندسة وإدارة التشييد ، كلية الهندسة المدنية ، جامعة اللاذقية (نشرين سابقاً) ، اللاذقية ، سورية .

Rasha.osefory@gmail.com

** أستاذ ، قسم هندسة وإدارة التشييد، كلية الهندسة المدنية، جامعة اللاذقية، (نشرين سابقاً) اللاذقية، سورية.

Fayezalijrad@gmail.com

مقدمة:

تُمثل مشاريع الجسور عنصراً حيوياً في منظومة النقل والمواصلات، حيث لا تقتصر أهميتها على كونها منشآت إنشائية فحسب، بل تشكل شرياناً رئيسياً للتنمية الاقتصادية والاجتماعية. وتواجه مشاريع الجسور في سوريا تحديات غير مسبقة تتفاقم بسبب الظروف الاستثنائية التي تمر بها البلاد، مما يؤثر سلباً على مقومات نجاحها الأساسية المتمثلة في الكلفة والزمن والجودة.

تتميز مشاريع الجسور بدرجة عالية من التعقيد والتفرد، حيث يتأثر كل مشروع بمجموعة متشابكة من العوامل تشمل خصائص الموقع، والظروف المناخية، والإمكانيات الفنية، والموارد المالية المتاحة. هذا التفرد يجعلها عرضة لمخاطر متعددة تزيد من احتمالية انحراف الكلفة والجدول الزمني عن المخطط له، خاصة مع تزايد حجم وتعقيد المشاريع الإنشائية الحديثة. مما يستدعي اتباع منهجيات فعالة لتحليل وإدارة تلك المخاطر، تجنباً لانحرافات التنفيذ أو فشل المشروع. وتُعد إدارة المخاطر عاملاً حاسماً في ضمان نجاح المشاريع، إذ يؤدي ضعفها إلى نتائج سلبية قد تشمل تجاوز التكاليف، وتأخير الإنجاز، أو حتى الإخفاق التام في تحقيق الأهداف المرجوة [5].

ولا تقتصر إدارة المخاطر على التعامل مع المشكلات بعد وقوعها، بل تشمل أيضاً التنبؤ بها في مراحل مبكرة. وفي ظل التطور السريع في أدوات الذكاء الاصطناعي، برزت تقنيات مثل الشبكات العصبية الاصطناعية كأدوات فعالة في تحليل البيانات المعقدة والتنبؤ بسلوك المشاريع المستقبلية. وقد أظهرت الأبحاث أن استخدام هذه التقنيات يساهم في تحسين دقة القرارات وتقييم المخاطر [16].

بناءً على ذلك، تهدف هذه الدراسة إلى تقييم تأثير المخاطر على مشاريع الجسور في سوريا من خلال تطوير نموذج تنبؤي يعتمد على الشبكات العصبية الاصطناعية. بحيث يساهم النموذج في تحسين القدرة على التنبؤ بانحرافات الكلفة والجدول الزمني، مما يعزز من كفاءة التخطيط واتخاذ القرار في مشاريع الجسور المستقبلية.

الدراسات المرجعية:

شهد مجال إدارة مخاطر التشييد تطوراً لافتاً في العقدين الأخيرين مع اعتماد تقنيات الذكاء الصناعي، وخاصةً في المشاريع المعقدة مثل الجسور والأنفاق والطرق السريعة.

تبرز دراسة [3] كإحدى المبادرات المبكرة التي دمجت بين الشبكات العصبية الاصطناعية (ANN) وتحليل الانحدار المتعدد (MRA) لتحسين تقييم مخاطر صيانة الجسور، حيث حقق النموذج الهجين دقةً تنبؤيةً تجاوزت 96%، متفوقاً على النماذج الخطية التقليدية التي فشلت في تفسير العلاقات غير الخطية بين متغيرات المخاطر. في السياق ذاته، قدمت دراسة [12] إطاراً ضبابياً عصبياً (Fuzzy-BP) لتحليل مخاطر بناء بوابات الأنفاق، مع التركيز على العوامل الجيولوجية مثل عدم استقرار المنحدرات وتدفق المياه، حيث صنفت المخاطر إلى أربعة مستويات، وأثبتت فعالية النموذج في تحسين قرارات التحكم بالمخاطر حيث بلغت دقة تنبؤه 97.94%. من جهة أخرى، قام الباحثون [20] في تحليل 17 عامل خطر شاملة المخاطر المالية والسياسية والتنفيذية، باستخدام شبكة عصبية متعددة الطبقات (MLP)، حيث تفوق النموذج على أدوات تقليدية مثل تحليل أنماط الفشل (FMEA) في التعامل مع البيانات غير المكتملة وحقق دقة تنبؤية.

في سياق متقدم، استخدمت دراسة [4] الشبكات العصبية العميقة (DNN) لتحليل تأثير 14 عامل خطر على انحرافات الكلفة والجدول الزمني في مشاريع الطرق، حيث تفوق نموذج DNN على النماذج الضحلة (BNN) وخوارزمية انحدار الغابات العشوائية (RFR)، مما أظهر قدرة التقنيات العميقة على كشف العلاقات المعقدة بين المتغيرات. أما دراسة [1]

، فقد طورت نموذج ANN للتنبؤ بتدهور حالة الجسور الأمريكية مع تحقيق دقة تنبؤية بلغت 89% لمكونات الجسر الرئيسية (السطح، البنية الفوقية، التحتية)، مما ساهم في تحسين سياسات الصيانة الاستباقية. على صعيد التكامل بين التقنيات، قدمت دراسة [7] نموذجاً هجيناً يجمع بين الشبكات العصبية وخوارزمية الغابة العشوائية حيث تم استخراج خمس سمات من أصل 59 سمة باستخدام خوارزمية الغابة العشوائية وذلك لبيانات 11,180 جسراً في الطرق الفيتنامية، حيث أدى استخراج السمات المميزة إلى تحسين دقة النموذج وتقليل الأخطاء بنسبة 23% مقارنة بالطرق التقليدية القائمة على استبيانات الخبراء.

على الرغم من اختلاف أدوات التحليل (الهيكلية، الضبابية، العميقة)، تشترك هذه الدراسات في سعيها لتجاوز محدوديات النماذج التقليدية مثل التحليل الهرمي (AHP) أو طريقة مونت كارلو، التي تعتمد على افتراضات خطية أو بيانات محدودة. إلا أن التباين يكمن في طبيعة المشكلات المستهدفة؛ فبينما ركزت بعض الدراسات على مخاطر محددة (كالتدهور الإنشائي أو العوامل الجيولوجية)، تناولت أخرى مخاطر شاملة (كالمخاطر المالية أو البيئية). كما اختلفت في حجم البيانات المُعالَجة، من عينات صغيرة إلى بيانات ضخمة (أكثر من 11,000 جسر).

رغم التقدم الملحوظ، أغفلت معظم الدراسات التحليل الكمي المباشر لتأثير المخاطر على مؤشري الأداء الرئيسيين: انحرافات التكلفة وانحراف الجدول الزمني، حيث اقتصر على التصنيف النوعي للمخاطر أو تقدير الاحتمالات العامة. يُعالج البحث الحالي هذه الفجوة عبر تطوير نموذج ANN مُخصص لتقييم التأثير الكمي المشترك لكل من المخاطر والخصائص الهندسية للجسور على انحرافات التكلفة والزمن في مشاريع الجسور في سوريا والتنبؤ بها للمشاريع الجديدة، ويقدم هذا النموذج إطاراً قابلاً للتطبيق لدعم قرارات إدارة المخاطر، مع إمكانية دمجها مع أنظمة إدارة المشاريع (مثل Primavera أو MS Project) لتحسين التخطيط وتخصيص الموارد.

إدارة المخاطر:

تُعد مشاريع الجسور من أكثر المشاريع عرضةً للمخاطر بسبب تعقيداتها وطول مدة تنفيذها، مما يؤثر على التكلفة والجدول الزمني والجودة. وتُعرف إدارة المخاطر وفق معهد إدارة المشاريع [1] بأنها عملية منظمة لتحديد المخاطر وتحليلها ووضع استراتيجيات للاستجابة لها ومراقبتها بهدف تقليل التهديدات وتعزيز فرص نجاح المشروع. وتشمل العملية خمس مراحل رئيسية:

1. **التخطيط:** إعداد خطة تحدد منهجية التعامل مع المخاطر وتنسيق الأدوار بين الأطراف.
2. **التحديد:** حصر وتوصيف المخاطر المحتملة باستخدام أدوات مثل العصف الذهني والاستبيانات.
3. **التحليل:** تقييم المخاطر نوعياً بتصنيفها حسب الشدة والاحتمالية، أو كمياً باستخدام النماذج الرقمية.
4. **الاستجابة:** وضع استراتيجيات لتجنب المخاطر أو تقليلها أو نقلها أو قبولها، مع استثمار الفرص الإيجابية.
5. **المراقبة:** متابعة تطور المخاطر وفعالية الاستجابات وتحديث سجل المخاطر بشكل دوري.

إدارة مخاطر مشاريع الجسور في سوريا

أن غياب منهجيات واضحة لإدارة المخاطر في مشاريع الجسور في سوريا كان من أبرز أسباب فشل بعض المشاريع، كما في "عقدة الحفة" عام 2018، التي عانت من عيوب فنية بعد التسليم نتيجة أوامر تغيير مفاجئة ودراسات تمهيدية غير كافية، مما أدى إلى تصميمات غير واقعية [6]. وتتفاقم هذه الإشكالات في بيئة ما بعد الأزمات، حيث تغيب البيانات التاريخية ويصعب التنبؤ بالمخاطر بدقة. من هنا، تبرز الحاجة إلى تطوير أطر تحليلية قائمة على الذكاء الاصطناعي لسد الفجوة بين الدراسات النوعية السابقة التي اعتمدت على التصنيف الاحتمالي، وبين الحاجة الملحة

لتحليل كمي مباشر لانحرافات التكلفة والتأخير الزمني كمؤشرين أساسيين لأداء المشروع. ويسعى هذا التوجه نحو إدارة مخاطر متكاملة تستند إلى التنبؤ الاستباقي، ومراجعة دورية للخطط، وربط المخرجات الهندسية بالمواصفات الفنية والاقتصادية، بما يعزز قدرة مشاريع الجسور على التكيف مع المتغيرات الديناميكية ويحقق التوازن المطلوب بين الدقة التخطيطية والمرونة التنفيذية.

أهمية البحث وأهدافه:

أهمية البحث:

تتبع أهمية هذا البحث من الحاجة الماسة إلى تطوير أدوات فعالة لإدارة المخاطر في مشاريع الجسور في سوريا، نظراً لما تشهده من تحديات تنفيذية معقدة أثّرت سلباً على جودة المشاريع والتزامها بالتكلفة والجدول الزمني. وفي ظل قصور الأدوات التقليدية عن التعامل مع العلاقات غير الخطية والمعقدة بين عوامل الخطر، يقَدِّم هذا البحث نموذجاً تنبؤياً مبتكراً يعتمد على تقنيات الشبكات العصبية الاصطناعية، لتقييم التأثير الكمي للمخاطر والتنبؤ بانحرافات الكلفة والزمن بدقة أعلى. ويسهم هذا النموذج في تعزيز كفاءة التخطيط ودعم اتخاذ القرار، مما يتيح تبني استراتيجيات استباقية أكثر فاعلية لرفع معدلات نجاح مشاريع البنية التحتية في البيئات عالية المخاطر مثل سوريا.

أهداف البحث:

يهدف هذا البحث بشكل رئيسي إلى تطوير نموذج تنبؤي يعتمد على الشبكات العصبية الاصطناعية لتقييم التأثير الكمي للمخاطر على التكلفة والجدول الزمني في مشاريع الجسور في سوريا، بما يعزز فاعلية اتخاذ القرار ويُحسن كفاءة التخطيط والتنفيذ. ويتضمن ذلك تحليل واقع مشاريع الجسور وتحديد أبرز التحديات المرتبطة بها، وتصنيف وتقييم المخاطر المؤثرة استناداً إلى بيانات واقعية، وتصميم نموذج يدمج بين هذه المخاطر والخصائص الهندسية للجسور. كما يشمل البحث اختبار كفاءة النموذج عبر تطبيقه على حالات فعلية، واستخلاص توصيات عملية قابلة للتطبيق تهدف إلى تحسين إدارة المخاطر وضمان نجاح المشاريع في البيئات المعقدة.

طرائق البحث ومواده:

مراحل البحث:

بدأت المرحلة الأولى من البحث بتحديد أهم المخاطر التي تواجه مشاريع الجسور في سوريا، حيث تم جمع 54 خطراً محتملاً من خلال مراجعة الأدبيات العلمية والدراسات السابقة ذات الصلة. جرى تصنيف هذه المخاطر ضمن 14 فئة رئيسية، شملت: مخاطر الدراسة والتصميم، المخاطر التنفيذية، مخاطر المواد والآليات، اليد العاملة، المخاطر الإدارية، الاقتصادية، القانونية، السياسية، مخاطر الظروف القاهرة، الاجتماعية، البيئية، الأمن والسلامة، والسلامة الهيكلية. في المرحلة الثانية، تم إجراء زيارات ميدانية لكل من: الشركة العامة للطرق والجسور - فرع اللاذقية، ومؤسسة الإنشاءات العسكرية، والمؤسسة العامة للمواصلات الطرقية - فرعي اللاذقية وطرطوس. وقد شملت هذه المرحلة تحليل وثائق مشاريع جسور منجزة بهدف التحقق من طبيعة التحديات الواقعية المرتبطة بالمخاطر. بناءً على ذلك، تم تصميم استبيان يستند إلى قائمة المخاطر المستخلصة من الدراسات السابقة، مع إتاحة المجال للمشاركين لإضافة مخاطر جديدة ناتجة عن خبراتهم المباشرة.

تألف الاستبيان من قسمين: الأول لجمع البيانات (المؤهل العلمي، مجال العمل، عدد سنوات الخبرة)، والثاني لتقييم كل خطر من حيث شدة التأثير على الكلفة، الزمن، والجودة، بالإضافة إلى احتمالية الحدوث. استخدمت مقياس ليكرت من خمس درجات لكل بُعد، حيث تم توزيع 45 استبياناً على خبراء ومهندسين ومشرفين ومقاولين في مجال الجسور، وبلغ معدل الاستجابة 89%. تم تحليل البيانات باستخدام برنامج SPSS، وتحقق من ثبات أداة القياس باستخدام معامل ألفا كرونباخ، الذي بلغت قيمته (0.878)، مما يشير إلى موثوقية عالية. بعدها، تم حساب درجة المخاطرة (Risk Score) باستخدام المعادلة (2):

$$\text{Risk score (R)} = \text{Probability (P)} \times \text{Severity of Impact (I)} \dots\dots\dots (2)$$

حيث تتراوح القيم بين 1 و25 لكل خطر. بناءً على متوسط تقييمات المشاركين، تم تحديد المخاطر ذات التأثير المرتفع جداً والمرتفع فقط [13-14]، لتكون مدخلات النموذج التنبؤي لاحقاً. وقد بلغ عدد هذه المخاطر: 15 خطراً مؤثراً على كلفة المشروع، و21 خطراً مؤثراً على زمن التنفيذ، كما هو موضح في الجداول (1) و(2)

الجدول (1) درجة الخطر بالنسبة للكلفة

رمز الخطر	اسم الخطر	احتمالية حدوث الخطر	شدة تأثير الخطر	درجة الخطر بالنسبة للكلفة
R1	التضخم وتقلبات الأسعار	4.35	4.65	20.23
R2	تغيير سعر الصرف	4.05	4.6	18.63
R3	صعوبة استيراد المواد بسبب الحصار الاقتصادي	4.05	4.2	17.01
R4	نقص في التمويل وعدم كفاية التدفق النقدي	3.8	4.35	16.53
R5	عدم الالتزام بالبرنامج الزمني للتنفيذ	4	4.1	16.40
R6	التأخر في صرف الكشوف	3.8	4.05	15.39
R7	سوء التخطيط والتصميم	3.9	3.8	14.82
R8	تغيير في نوع التربة أو حدوث هبوطات مفاجئة	3.6	4	14.40
R9	حروب	3.13	4.57	14.30
R10	عدم ذكر تكنولوجيا التنفيذ	3.6	3.95	14.22
R11	تحريرات جيولوجية ناقصة	3.4	4.15	14.11
R12	تعليق العمل	3.08	4.5	13.86
R13	عوائق استملاك	3.78	3.63	13.72
R14	قلة عدد العمال من ذوي الخبرة والكفاءة بأعمال الجسور	3.65	3.75	13.69
R15	ضعف كفاءة الآليات الموجودة	3.78	3.6	13.61

تُظهر النتائج تقاوم تحديات إدارة مخاطر مشاريع الجسور في سوريا، لا سيما بسبب التضخم الحاد وتقلبات سعر الصرف الناتجة عن العقوبات الدولية التي تزيد من تكلفة المواد وتعرقل استيرادها. كما تُبرز التحديات المحلية مثل البيروقراطية الإدارية التي تعرقل سير المشاريع، وضعف الإمكانيات التقنية في التحريات الجيولوجية، إضافة إلى صعوبات صيانة المعدات الناتجة عن ضعف الاستثمارات.

الجدول(2)درجة الخطر بالنسبة للزمن


رمز الخطر	اسم الخطر	احتمالية حدوث الخطر	شدة تأثير الخطر	درجة الخطر بالنسبة للزمن
R1	تعطل الآليات	3.85	5	19.25
R2	عدم الالتزام بالبرنامج الزمني للتنفيذ	4	4.57	18.28
R3	التضخم وتقلبات الأسعار	4.35	4.05	17.62
R4	سوء التخطيط والتصميم	3.9	4.38	17.08
R5	تغيير في نوع التربة أو حدوث هبوطات مفاجئة	3.6	4.65	16.74
R6	الروتين الإداري وتأخر المراسلات الرسمية	3.8	4.35	16.53
R7	صعوبة استيراد المواد بسبب الحصار الاقتصادي	4.05	4.08	16.52
R8	نقص في التمويل وعدم كفاية التدفق النقدي	3.8	4.2	15.96
R9	عوائق استملاك	3.78	4.2	15.88
R10	التأخير في تسليم المواد من قبل الموردين	3.48	4.38	15.24
R11	ضعف كفاءة الآليات الموجودة	3.78	4.02	15.20
R12	التأخر في صرف الكشوف	3.8	3.98	15.12
R13	تحريرات جيولوجية ناقصة	3.4	4.35	14.79
R14	تغيير سعر الصرف	4.05	3.55	14.38
R15	حروب	3.13	4.48	14.02
R16	قلة عدد العمال من ذوي الخبرة والكفاءة بأعمال الجسور	3.65	3.83	13.98
R17	عدم توفر قطع غيار للآليات	3.38	4.13	13.96
R18	ضعف إنتاجية العمال	3.58	3.88	13.89
R19	تعليق العمل	3.08	4.45	13.71
R20	أحوال جوية سيئة	3.55	3.85	13.67
R21	نقص في الآليات الخاصة بأعمال الجسور	3.33	3.9	12.99

كشف التحليل أن تعطل الآليات وعدم الالتزام بالبرنامج الزمني يمثلان أبرز التحديات التشغيلية المباشرة التي تؤثر على إنجاز مشاريع الجسور في سوريا. بشكل عام، تؤكد هذه النتائج على ضرورة اعتماد منهجية لإدارة المخاطر تتكيف مع خصوصية بيئة تنفيذ مشاريع التشييد في سوريا، بدل الاعتماد الحصري على النماذج التقليدية. ويتمشى ذلك مع هدف البحث الذي يركز على استخدام نماذج الذكاء الاصطناعي لتحليل وإدارة مخاطر مشاريع الجسور، حيث تدمج هذه النماذج الخصائص الهندسية مع تقييمات الخطورة لرصد التأثير التراكمي للمخاطر، مما يسهم في التنبؤ الدقيق بانحرافات الزمن والكلفة قبل تفاقمها.

بناء النموذج المقترح القائم على الشبكات العصبية

شهدت الشبكات العصبية الاصطناعية في العصر الحديث انتشاراً واسعاً في العديد من المجالات الطبية والهندسية والاقتصادية، حيث تعتمد على آلية التعلم من خلال تحليل كميات ضخمة من البيانات التاريخية لاكتساب الخبرة والمعرفة اللازمة لاتخاذ قرارات مستقبلية دقيقة. وتتميز الشبكات العصبية بقدرتها على التعامل مع المسائل التي تتميز بالعلاقات غير الخطية بين المتغيرات المدخلة والمخرجات، مما يجعلها أداة فعالة في التنبؤ بحالات الطقس، وتكاليف البناء، وتقييم المخاطر، وتسوية المنازعات، وتوقع الإنتاجية، وتقدير الجداول الزمنية [8].

تتألف الشبكة العصبية من عدة طبقات، حيث تحتوي كل طبقة على مجموعة من الوحدات أو العقد (Nodes)، ويختلف عدد الطبقات وعدد الوحدات داخل كل طبقة باختلاف طبيعة المشكلة التي يتم حلها [9]. ويوضح الشكل (1) البنية العامة للشبكة العصبية الاصطناعية.



الشكل (1) بنية الشبكة العصبية الاصطناعية

1. طبقة الدخل: (Input Layer)

تتكون هذه الطبقة من مجموعة من العقد التي تستقبل القيم المدخلة من البيئة الخارجية وتقوم بتمريرها إلى الطبقة المخفية التالية دون إجراء عمليات حسابية، حيث تعمل فقط كناقل للبيانات.

2. الطبقة الوسيطة أو المخفية: (Hidden Layer)

تقوم الطبقة المخفية بمعالجة البيانات عن طريق اكتشاف الخصائص وتمييز الأنماط في المدخلات، حيث يتم إعطاء أوزان معينة لكل مدخل وتعديلها باستخدام دالة تحليلية بناءً على الفرق بين النتائج المتوقعة والنتائج الفعلية. يتم تحديد عدد الوحدات في هذه الطبقة عادة عبر التجربة والخطأ لضمان أفضل أداء.

3. طبقة المخرجات: (Output Layer)

تستلم هذه الطبقة الإشارات من الطبقة المخفية وتعالجها لإنتاج النتائج النهائية المرتبطة بالمشكلة قيد الدراسة.

بناء نموذج الشبكة العصبية المقترح:

استناداً إلى ما سبق، تم تصميم شبكتين عصبيتين مستقلتين بهدف التنبؤ بانحراف كلفة مشروع الجسر عن التكلفة المخططة، وانحراف الزمن عن الجدول الزمني المحدد. تعتمد هذه النماذج على مدخلات مستمدة من الخصائص الهندسية والمخاطر المؤثرة التي تم تحديدها مسبقاً وتحليلها، بهدف توفير أداة تنبؤية دقيقة تدعم اتخاذ القرار في إدارة مشاريع الجسور في ظل الظروف المعقدة التي تواجهها سوريا

أولاً: مدخلات الشبكة العصبية

أ. الشبكة الأولى (التنبؤ بانحراف التكلفة): تتكون مدخلات الشبكة الأولى من نوعين:

النوع الأول: درجة الخطورة لـ 15 عاملاً من أهم عوامل المخاطر المؤثرة على التكلفة، والتي تم الحصول عليها من تقييم خبراء مشاريع تشييد الجسور [3-11]، كما هو موضح في الجدول (1).

النوع الثاني: المواصفات الهندسية للجسور، والتي تشمل: نوع الجسر، القطاع التنفيذي (عام/خاص)، المقطع العرضي، الطول، العرض، الارتفاع الحر، طول الفتحة الأعظمية، عدد الفتحات، ارتفاع الركائز الطرفية، موضحة في الجدول (3)

الجدول (3) الخصائص الهندسية لعينة من الجسور

اسم الجسر	القطاع	المقطع العرضي	الطول (m)	العرض (m)	الارتفاع (m)	طول الفتحة الأعظمية (m)	عدد الفتحات	ارتفاع الركيزة الطرفية 1 (m)	ارتفاع الركيزة الطرفية 2 (m)
الشيخ سعد	عام	جوائز وبلاطة	71	14.4	5	23.5	4	7	7
21	عام	بلاطة دون جيزان	44	24	6.5	22	2	9.96	9.96
B51	خاص	بلاطة دون جيزان	54.85	6	6	17.6	4	7.32	7.32
B99	خاص	بلاطة دون جيزان	54.34	12.6	5.88	13	4	9.6	9.8
B85	خاص	بلاطة دون جيزان	59.4	12.5	6.58	20.05	4	10.1	11
B96	خاص	بلاطة دون جيزان	69.36	17.8	6	20.8	4	11.9	7.92
B121	خاص	بلاطة دون جيزان	18	18.75	6.7	18.75	1	8.44	8.44
B12	خاص	بلاطة دون جيزان	100	13	7	20	5	10.50	11.50
عقدة الشيخ صالح العلي	عام	جوائز وبلاطة	180	13.5	7.5	15	5	10	10

ب. الشبكة الثانية (التنبؤ بانحراف الزمن):

النوع الأول: درجة الخطر تم الحصول عليها من تقييم الخبراء لـ 21 عاملاً من أهم عوامل المخاطر المؤثرة على زمن تنفيذ المشروع وهي الموضحة بالجدول (2)

النوع الثاني: المواصفات الهندسية للجسور، وهي نفسها المدخلات الهندسية للشبكة الأولى

ثانياً: مخرجات الشبكة العصبية:

مخرجات الشبكة الأولى: مؤشر انحراف الكلفة (CVP: Cost Variance Percentage).

مخرجات الشبكة الثانية: مؤشر انحراف الزمن (TVP: Time Variance Percentage).

تجميع البيانات:

تم الاطلاع على الأضابير والكشوف والمخططات المتوفرة في الشركة العامة للطرق والجسور، والمؤسسة العامة للطرق والمواصلات، وعدة مؤسسات أخرى، حيث جُمعت بيانات 45 جسراً خرسانياً منفذاً في سوريا، موزعة كالتالي:

- 40 جسراً من النوع ذي البلاطات الخرسانية المسلحة (بدون جيزان).
- 5 جسور ذات مقاطع عرضية مركبة (بلاطات مع جيزان).
- التوزيع الجغرافي: 32 مشروعاً على طريق اللاذقية-أريحا، 8 مشاريع في دمشق، 3 في اللاذقية، وجسرين في طرطوس

معالجة البيانات (Data Processing) :

تتم معالجة البيانات بتحويل المدخلات الخام إلى صيغة مناسبة للشبكة العصبية لتحسين التدريب والتنبؤ. تشمل هذه العملية ترميز المتغيرات الفئوية مثل نوع الجسر والقطاع التنفيذي باستخدام الترميز الأحادي، بينما تُقَيَس المتغيرات الرقمية وفقاً لطبيعة توزيعها. تُستخدم تقنية Robust Scaling للخصائص التي تحتوي على قيم متطرفة مثل طول الجسر والفتحة الأعظمية، في حين يُطبق التقييس Z-Score على المتغيرات ذات التوزيع الطبيعي كعرض الجسر والارتفاع الحر. أما في حالات التوزيع غير المتماثل مثل الكلفة التقديرية، فيُجرى تحويل لوغاريتمي أولاً ثم تطبيق Z-Score.

تقسيم البيانات (Data Division) :

للشبكات العصبية قدرة عالية على التمييز والتعميم، ولذلك تم تقسيم البيانات إلى مجموعتين رئيسيتين لضمان جودة التدريب والتقييم [21].

تم اعتماد تقسيم 80% تدريب (36 عينة) و 20% اختبار (9 عينات)، وهو مناسب لحجم العينة 45.

تطوير نماذج الشبكة العصبية (Design of ANN Models) :

من بين الأنواع المختلفة للشبكات العصبية الاصطناعية ANN يركز هذا البحث على الشبكات العصبية متعددة الطبقات (MLP) حيث تُعد أحد النماذج الأساسية في التعلم الآلي التي تُستخدم بشكل فعال في مهام التنبؤ، بما في ذلك تقدير التكاليف والأزمنة. وفي إطار تطوير نموذج شبكة الإدراك متعددة الطبقات (Multi-Layer Perceptron – MLP)، تم تنفيذ النموذج باستخدام مكتبة Scikit-learn في بيئة Python على منصة Google Colab، لما توفره من مرونة وكفاءة في تصميم الشبكات.

إدخال البيانات :

تم إدخال البيانات على شكل مصفوفات (inputs, target)

inputs: المتغيرات المستقلة (عوامل الخطر + المواصفات الهندسية) بعد المعالجة والتقييس.

target: المتغير التابع (القيمة المستهدفة) وهي CVP أو TVP حسب الشبكة.

تحديد هيكلية الشبكة العصبية:

تحديد الهيكلية المناسبة للشبكة يشكل تحدياً بسبب تعدد العوامل المؤثرة مثل معدل التعلم، عدد الطبقات المخفية، عدد العقد داخل كل طبقة، ودالة التنشيط [19] وبما أنه لا توجد قواعد رياضية ثابتة، تم اعتماد منهجية التجربة والخطأ، بدءاً بطبقة مخفية واحدة مع عقدة واحدة، وزيادة عدد العقد تدريجياً من 1 إلى 15، مع مراقبة الأداء عند كل خطوة. هذا النهج مناسب لحجم العينة المحدود (45 عينة)، ويسعى لتحقيق توازن بين تعقيد النموذج وقدرته على التعميم [15]، مع تقادي التكيف الزائد (Overfitting).

بنية الشبكة:

طبقة الدخل وعدد العقد: تحتوي طبقة الدخل في كل شبكة على عدد عقد مساوي لعدد المتغيرات المدخلة: 25 مدخلاً في شبكة التنبؤ بالتكلفة، و 31 مدخلاً في شبكة التنبؤ بالزمن.

طبقة الخرج وعدد العقد: تحتوي طبقة الخرج على عقدة واحدة في كل شبكة تمثل مؤشر الانحراف المطلوب (CVP أو TVP).

دوال التنشيط المستخدمة:


• **في الطبقات المخفية:** دالة (Rectified Linear- ReLU): والتي تعرف بالصيغة $f(x)=\max(0,x)$ ، لما لها من فاعلية في إدخال عدم الخطية، وتجنب مشكلة تلاشي التدرج (Vanishing Gradient)، بالإضافة إلى كفاءتها الحسابية التي تسهل تسريع التدريب.

• **في طبقة الخرج:** الدالة الخطية (Identity) ذات الصيغة $f(x)=x$ للحفاظ على مدى غير محدود للقيم المتوقعة، وهو أمر حاسم في مهام الانحدار مثل تقدير نسب الانحراف (CVP/TVP)، مع تجنب تشويه النتائج عبر ضغطها ضمن نطاق ضيق.

النتائج والمناقشة:**مرحلة تدريب الشبكة :**

في إطار تدريب النموذج المقترح، تم اعتماد بنية شبكة عصبية ذات تغذية أمامية (Feedforward Neural Network) مع خوارزمية الانتشار العكسي (Backpropagation) لتحديث الأوزان، مستخدمةً خوارزمية التحسين Adam لما تتمتع به من كفاءة حسابية وسرعة في التقارب، بالإضافة إلى قدرتها على التكيف مع معدل التعلم. تضمن إعداد النموذج ضبط مجموعة من المعايير الأساسية، شملت تحديد عدد التكرارات القصوى بـ 3000 تكرار، مع تفعيل آلية الإيقاف المبكر (Early Stopping) في حال عدم تحسن الأداء خلال 50 تكراراً متتالياً، ما يساهم في منع الإفراط في التدريب (Overfitting). كما تم اعتماد معدل تعلم أساسي بقيمة 0.001، وتنظيم L2 بقوة 0.01 بهدف تحسين قدرة النموذج على التعميم والحد من تعقيده.

خلال مرحلة التدريب، تم تقييم أداء النموذج باستخدام بيانات اختبارية مستقلة لم تدخل في عملية التعلم، وتم احتساب مؤشرات الأداء الرئيسية، مثل متوسط مربع الخطأ (MSE) ومعامل الارتباط (R) ومعامل التحديد (R^2)، لقياس دقة النموذج وفعاليته في التنبؤ.



الشكل(2) مخطط يوضح خوارزمية الانتشار الخلفي

تحسين النموذج واختيار البنية المثلى:

أولاً: نموذج التنبؤ بانحراف الكلفة (CVP):

تم اختبار 15 تكويناً مختلفاً لعدد العُقد في الطبقة المخفية (من 1 إلى 15)، مع تثبيت خوارزمية التحسين (Adam)، واستخدام دالة التنشيط ReLU في الطبقة المخفية و Identity في طبقة الإخراج. وقد أظهرت النتائج أن النموذج الذي يحتوي على 11 عقدة مخفية هو الأفضل، حيث حقق أقل خطأ اختبار ($MSE = 0.041$) وأعلى معامل ارتباط ($R = 0.9753$).


ثانياً: نموذج التنبؤ بانحراف الزمن (TVP):

بنفس الطريقة، تم اختبار نفس التكوينات، وأظهرت النتائج أن أفضل أداء تحقق عند استخدام 14 عقدة مخفية، حيث تم الوصول إلى أقل MSE بمقدار 0.0313، وأعلى قيمة لمعامل الارتباط $R = 0.969$.

الجدول (4) محاولات التجربة والخطأ للتنبؤ بانحراف الكلفة CVP

عدد العقد في الطبقة المخفية	تابع التنشيط		MSE		معامل الارتباط R		عدد مرات التدريب
	الطبقة المخفية	طبقة الخرج	التدريب	الاختبار	التدريب	الاختبار	
1	ReLU	Identity	0.0370	0.0328	0.8824	0.4976	300
2	ReLU	Identity	0.0728	0.1649	0.8753	0.4400	230
3	ReLU	Identity	0.0240	0.1600	0.8856	0.4102	300
4	ReLU	Identity	0.0877	0.0879	0.9649	0.4244	300
5	ReLU	Identity	0.2026	0.3785	0.9080	0.2431	139
6	ReLU	Identity	0.1153	0.3023	0.9082	0.5246	300
7	ReLU	Identity	0.1103	0.1284	0.9720	0.3525	217
8	ReLU	Identity	0.1762	0.2688	0.9180	0.5444	300
9	ReLU	Identity	0.0265	0.0907	0.9178	0.5169	300
10	ReLU	Identity	0.1254	0.3830	0.9302	0.5828	300
11	ReLU	Identity	0.0351	0.0410	0.9823	0.9753	300
12	ReLU	Identity	0.3388	0.3551	0.8967	0.4498	135
13	ReLU	Identity	0.0618	0.1389	0.9433	0.2939	162
14	ReLU	Identity	0.1696	0.9319	0.9084	0.4002	294
15	ReLU	Identity	0.2548	0.5912	0.8416	0.4167	300

يعبر الشكل (3) عن المخطط الكتلي للشبكة العصبية المثلى لنموذج التنبؤ بانحراف الكلفة من حيث عدد المدخلات وعدد العقد بالطبقة المخفية ودوال التنشيط وعدد المخرجات




الشكل (3) المخطط الكتلي للشبكة العصبية المثلى لنموذج التنبؤ بانحراف الكلفة

الجدول (5) محاولات التجربة والخطأ لنموذج التنبؤ بانحراف الزمن

عدد العقد في الطبقة المخفية	تابع التنشيط		MSE		معامل الارتباط R		عدد مرات التدريب
	الطبقة المخفية	طبقة الخرج	التدريب	الاختبار	التدريب	الاختبار	
1	ReLU	Identity	0.0678	0.1383	0.6285	0.4886	300
2	ReLU	Identity	0.2056	0.5010	0.9656	0.2386	300
3	ReLU	Identity	0.0409	0.0580	0.8585	0.4999	227
4	ReLU	Identity	0.0620	0.5415	0.7912	0.4441	70
5	ReLU	Identity	0.0278	0.2833	0.9173	0.7374	300
6	ReLU	Identity	0.1100	0.5670	0.8827	0.5260	215
7	ReLU	Identity	0.2221	0.9742	0.9614	0.4940	300
8	ReLU	Identity	0.1125	0.6035	0.8886	0.0942	339
9	ReLU	Identity	0.7021	0.8462	0.9607	0.0128	145
10	ReLU	Identity	0.1942	0.9512	0.9508	0.4563	113
11	ReLU	Identity	0.6821	0.6902	0.8587	0.0370	300
12	ReLU	Identity	0.0563	0.3605	0.8593	0.6145	300
13	ReLU	Identity	0.0696	0.7273	0.9747	0.5676	297
14	ReLU	Identity	0.0294	0.0313	0.9712	0.9690	300
15	ReLU	Identity	0.2787	0.7566	0.9083	0.2677	315

يعبر الشكل (4) عن المخطط الكتلي للشبكة العصبية المثلى لنموذج التنبؤ بانحراف الزمن من حيث عدد المدخلات وعدد العقد بالطبقة المخفية ودوال التنشيط وعدد المخرجات



الشكل (4) المخطط الكتلي للشبكة العصبية المثلى لنموذج التنبؤ بانحراف الزمن

هيكلية النموذج النهائي وتنفيذه:

بعد اختيار التكوينات المثلى، تم اعتماد نموذجين نهائيين تم تنفيذهما باستخدام مكتبة Scikit-learn في Python يتكوّن النموذج الأول (CVP) من طبقة مخفية واحدة تحتوي على 11 عقدة، بينما يحتوي النموذج الثاني (TVP) على طبقة مخفية واحدة تضم 14 عقدة. تم اعتماد دالة ReLU في الطبقة المخفية، ودالة Identity في طبقة الإخراج لكلا النموذجين.

تم تدريب النموذجين باستخدام:

- عدد تكرارات أقصى: 3000
 - تنظيم L2 بقوة $\alpha = 0.01$
 - آلية إيقاف مبكر: 50 تكراراً دون تحسن
- أظهرت النتائج استقراراً في الخطأ بعد التكرار 300، مما أدى إلى تفعيل الإيقاف المبكر. بلغت نتائج التدريب النهائية:
- نموذج CVP: $R = 0.9823$ ، $MSE = 0.0351$
 - نموذج TVP: $R = 0.9712$ ، $MSE = 0.0294$


اختبار النموذج وتقييم الأداء:

بعد نجاح مرحلة التدريب، تم اختبار كل نموذج باستخدام 9 عينات مستقلة لم تدخل في عملية بناء النموذج، وذلك لتقييم قدرة النموذج على التعميم. ضمن الحدود التي تضعها بيانات التدريب بدلاً من مجرد حفظ علاقات المدخلات والمخرجات التي ترد فيها [2] تم استخدام مؤشرات MSE و R و MAE و R^2 كمعايير تقييم للأداء، كما هو موضح في الجدول التالي:


الجدول (6) معايير تقييم أداء النموذجين

المعيار	نموذج انحراف الكلفة		نموذج انحراف الزمن	
	التدريب	الاختبار	التدريب	الاختبار
MSE	0.0351	0.0410	0.0294	0.0313
R	0.9823	0.9753	0.9712	0.9689
MAE (%)	0.34%	0.97%	0.31%	0.52%
R^2	0.9649	0.9512	0.9432	0.9387

يُعتبر معامل التحديد (R^2) المقياس الأكثر دلالة على دقة النموذج التنبؤي، حيث حقق النموذج نتائج استثنائية في تفسير التباين في البيانات. تُظهر هذه القيم أداءً ممتازاً للنموذجين، حيث تجاوزت قيم R^2 نسبة 93% في جميع الحالات هذه النتائج تقع ضمن نطاق الدقة للدراسات السابقة المتروحة مابين (89-98%) وهي نسبة جيدة جداً مقارنةً بها، مع متوسط أخطاء منخفض جداً ($MSE < 0.05$ و $MAE < 1\%$).




الشكل (5) دالة الانحدار الخطي لنموذج MLP للتنبؤ بانحراف الكلفة



الشكل (6) دالة الانحدار الخطي لنموذج MLP للتنبؤ بانحراف الزمن


تؤكد نتائج النموذجين قدرة الشبكة العصبية على النقاط الأنماط غير الخطية المعقدة في بيانات مشاريع الجسور بدقة عالية. وقد تم التحقق من صحة هذه النماذج من خلال مقارنة مخرجات الشبكة مع القيم الفعلية، حيث أظهرت محاكاة دقيقة للواقع ضمن الحدود المقبولة. وتظهر الأشكال (7) و(8) نتائج القيم الفعلية لانحرافات الكلفة CVP وانحرافات الزمن TVP (القيم الأصلية للمشاريع) والقيم المحسوبة وفق الشبكة المثلى لانحراف الكلفة والزمن ، للعينات الداخلة في عملية الاختبار

العدد	اسم الجسر	القيم الفعلية (الأصلية للمشاريع) %CVP	القيم المتنبأ بها من الشبكة %CVP
1	الشيخ سعد	-21%	-23%
2	21	-33.63%	-34.30%
3	B51	-9.49%	-10.20%
4	B99	16.34%	16.10%
5	B85	13.97%	13.20%
6	B96	-3.39%	-2.90%
7	B121	17.98%	19.50%
8	B12	-8.11%	-10.10%
9	عقدة الشيخ صالح العلي	-26.20%	-25.89%



الشكل (7) نتائج انحراف الزمن وفق الشبكة المثلى، للعينات الداخلة في عملية الاختبار

العدد	اسم الجسر	القيم الفعلية (الأصلية للمشاريع) %TVP	القيم المتنبأ بها من الشبكة %TVP
1	الشيخ سعد	-37.50%	-38.70%
2	21	-42.10%	-42.50%
3	B51	-16.20%	-15.80%
4	B99	-12.80%	-12.50%
5	B85	-10.50%	-11.50%
6	B96	-14.50%	-14.70%
7	B121	-9.80%	-10%
8	B12	-14.90%	-15%
9	عقدة الشيخ صالح العلي	-18%	-18.90%



الشكل

(8) نتائج انحراف الزمن وفق الشبكة المثلى، للعينات الداخلة في عملية الاختبار

تؤكد هذه النتائج أن الشبكة العصبية المختارة نجحت في تحقيق توازن بين الدقة والتعميم، دون الوقوع في الإفراط في التخصيص، مما يجعلها أداة موثوقة للتنبؤ بانحراف الكلفة والزمن في مشاريع الجسور.

تحليل الحساسية :

تم إجراء تحليل الحساسية لعوامل التأثير على انحراف الكلفة والزمن في مشاريع الجسور باستخدام طريقة موريس (Morris Method)، تم قياس أهمية كل متغير من خلال قيمة *mustar* (متوسط التأثير المعياري المطلق)، والتي تعكس مقدار التأثير الذي يحدثه كل مدخل في مخرجات النموذج عند تغييره ضمن مجاله الطبيعي يهدف هذا التحليل إلى تحديد المتغيرات الأكثر تأثيراً على مخرجات النموذج، وتوجيه جهود الإدارة الهندسية نحو ضبط العوامل الحرجة. أظهرت نتائج التحليل أن مخاطر التضخم وتقلبات الأسعار جاءت في صدارة العوامل المؤثرة على انحراف الكلفة بمؤشر تأثير يقارب (6.56) ما يتوافق مع دراسات سابقة [18]، الجسر بتأثير (5.58)، ثم تغير سعر الصرف (5.5) وعرض الجسر (4.4)، بينما جاء الارتفاع الحر كأقل العوامل تأثيراً (1.5). يشير ذلك إلى أن العوامل الاقتصادية والتنظيمية تتفوق من حيث التأثير على العوامل الفنية فيما يتعلق بانحراف الكلفة. أما بالنسبة لـ انحراف الزمن، فقد بين التحليل أن سوء التخطيط والتصميم هو المسبب الأبرز للتأخير بمؤشر (2.3) وهو ما يتماشى مع الأدبيات [14]، تغير نوع التربة بتأثير (2.25)، ثم تعطل الآليات (2.10) وعوائق الاستملاك (1.95)، بينما جاءت الأجواء الجوية السيئة كأقل العوامل تأثيراً (1.9)، مما يؤكد أهمية العوامل الإدارية والتعاقدية في التأثير على الجدول الزمني للمشروع.

بناءً على هذه النتائج، يمكن اقتراح مجموعة من الإجراءات لمعالجة المخاطر الأعلى تأثيراً، منها:

- المخاطر الاقتصادية: نقل جزء من المخاطر عبر عقود التأمين وضمانات الأداء.
 - المخاطر التصميمية: التعاقد مع مكاتب استشارية متخصصة وفق عقود دقيقة تحدد المسؤوليات وضوابط الجودة.
 - مخاطر الآليات: اعتماد خطط صيانة استباقية وتوفير مخزون استراتيجي من قطع الغيار.
 - مخاطر التربة والطقس: تنفيذ دراسات جيوتكنيكية شاملة وتبني حلول هندسية مرنة مع خطط استجابة ديناميكية للتغيرات المناخية.
- تعزز هذه الاستراتيجيات فعالية إدارة المخاطر في مختلف مراحل دورة حياة المشروع، وتدعم تحقيق مستويات أعلى من الكفاءة التشغيلية والجودة.

الاستنتاجات والتوصيات:

الاستنتاجات

1. تُظهر مشاريع الجسور في سوريا انحرافات كبيرة في الكلفة والزمن، حيث تم تحديد 15 عاملاً مؤثراً على الكلفة و 21 عاملاً مؤثراً على الجدول الزمني.
2. الشبكة العصبية متعددة الطبقات (MLP) ذات الهيكلية 1-11-25 للتنبؤ بانحراف الكلفة والشبكة ذات الهيكلية 1-14-31 للتنبؤ بانحراف الزمن أثبتت كفاءة عالية في التنبؤ حيث تجاوزت قيم R^2 نسبة 93% في النموذجين هذه النتائج تقع ضمن نطاق الدقة للدراسات السابقة المتروحة ما بين (89-96%).
3. يتميز النموذج بدمج المعطيات الهندسية مع مؤشرات المخاطر، مما يعزز فعاليته كأداة داعمة للقرار في بيانات غير مستقرة.

4. تفوق النموذج على الأساليب التقليدية في نمذجة العلاقات غير الخطية، ونجح في تحقيق دقة تنبؤية رغم محدودية البيانات.
 5. أظهر تحليل الحساسية أن العوامل الاقتصادية هي الأكثر تأثيراً على الكلفة، في حين أن سوء التخطيط والتصميم هو العامل الأكثر تأثيراً على الزمن.
- التوصيات:**
1. إنشاء هيكل مؤسسي متكامل لإدارة المخاطر في قطاع الجسور في سوريا ، تشمل فرق متخصصة، قاعدة بيانات مركزية، برامج تدريبية، وتبني تقنيات حديثة مثل BIM والذكاء الاصطناعي. واتباع المعايير الدولية في تقييم المخاطر لضمان كفاءة أعلى وتقليل التكاليف والتأخيرات
 2. زيادة حجم العينة وتنوع مصادر البيانات لتشمل مناطق متعددة وأنواع مختلفة من المشاريع لتعزيز موثوقية النموذج.
 3. اعتماد النماذج التنبؤية بعد تطويرها كأدوات رسمية في تخطيط وتنفيذ مشاريع الجسور لما أثبتته من دقة وكفاءة.
 4. تكامل النماذج التنبؤية مع أنظمة إدارة المشاريع لتسهيل المتابعة الآنية واتخاذ قرارات تصحيحية سريعة.
 5. تحسين الأداء التنبؤي للنموذج من خلال دمج بتقنيات الذكاء الاصطناعي الأخرى، كالخوارزميات الجينية.
 6. تطوير واجهات استخدام برمجية مبسطة تتيح لغير المختصين بالذكاء الاصطناعي الاستفادة من إمكانيات النموذج بسهولة.
 7. إنشاء نظام متكامل لإدارة المعرفة وأرشفة البيانات يشمل آليات جمع وتحليل وتصنيف البيانات التاريخية لدعم الأبحاث المستقبلية.

References:

- [1] E.Althaqafi and E.Chou," Developing Bridge Deterioration Models Using an Artificial Neural Network". *Infrastructures*, vol.7,no.8,pp.101-118, 2022
- [2] E.D.A.AL-Zubaidi, A. H.Yas, , and H. F. Abbas,"Guess the time of implementation of residential construction projects using neural networks ANN".*Periodicals of Engineering and Natural Sciences*, vol.7,no.3,pp. 1218-1227 , 2019
- [3] T. M. S. Elhag,, and Y. M. Wang, "Risk Assessment for Bridge Maintenance Projects : Neural Networks versus Regression Techniques".*Journal of Bridge Engineering*, vol.12,no.4,pp. 456-465, 2007.
- [4] M.A., Isah, and B.-S. Kim,"Assessment of risk impact on road project using deep neural network".*KSCE Journal of Civil Engineering*,vol.26,no.3,pp.1014–1023 ,2021.
- [5] ISO. 31000:2018."Risk Management – Guidelines".* International Organization for Standardization*, 2018.
- [6] J.Fayez. "An Analytical Study to Manage the Risks of Highroads Projects in Syria". *Hama University Journal*, vol.4,no.8,pp.42–60, 2021.
- [7] D. D. Lam,, L. D. Anh,, , L. T. Giang, and H. Ha,," Risk Identification and Prediction for Highway Bridge Projects Using an Artificial Intelligence Model". *Journal of Construction Engineering and Management*, vol.149,no.3,pp.711-719,2023.
- [8] S. Makkieh, "Forecasting the Estimate Completion Time of Syrian Building Projects Using Earned Value Management and Artificial Intelligence". *Tishreen University Journal-Engineering Sciences Series*, vol.43,no.2,pp.41-58, 2021.
- [9] J. Omran, N. Hani, and M. Soufan, "Improving the Opportunity of Winning aProject Tender of Schools Using Artificial Neural Network", *Tishreen University Journal-Engineering Sciences*, vol.26,no.2,pp.175-192, 2004.

- [10] Project Management Institute. *A guide to the project management body of knowledge (PMBOK guide) *. (7th ed.). Pennsylvania: PMI, 2021.
- [11] X.Wang, and Y. Wang, "The research on bridge engineering risk management and assessment model based on BP neural network". *Proceedings of the 6th International Conference on Environmental Science and Civil Engineering*.vol.455,no.1,pp. 012127, 2020.
- [12] T. Xu, R. Wang, and X. Deng, " Risk Evaluation Model of Highway Tunnel Portal Construction Based on BP Fuzzy Neural Network". *Computational Intelligence and Neuroscience*, Article ID 8547313,pp. 1–16, 2018.
- [13] R.Al-Homsi, "Development a Tool for Construction Risk Analysis During procurement". A thesis submitted for the degree of Master of Science, Faculty of Civil Engineering, University of Damascus, Syria, 2013.
- [14] F. A. Al-Mohammad, "Developing a Model to Predict Delay of Residential Projects at Implementation Stage using Artificial Neural Network". Department of Construction and Engineering Management, Faculty of Civil Engineering, University of Damascus, Syria, 2023.
- [15] F.Bouarouri, "Contribution of Artificial Neural Networks in Forecasting Sales Volume to Support Administrative Decision-Making in Economic Enterprises: A Case Study of Selected Algerian Enterprises". Ferhat Abbas University Setif 1, Algeria, 2019.
- [16] L. Bouzidi, and R.Aichouche, The Role of Artificial Neural Network Technology in Risk Management in Industrial Enterprises.*Journal of Financial and Business Economics*, vol.1,no.4,pp. 45–54, 2017.
- [17] Hamadeh, Mona, Amoudi, Omar and Nayfeh, Omar."Risk Management in the Construction Phase of Construction Projects in Syria". *Damascus University Journal for Engineering Sciences, vol.28,no.1,pp. 129–150,2012.
- [18] S.Hussien, "Developing a Methodology for Managing Bridges Construction Risks in Syria". A thesis submitted for the degree of Master of Science, Department of Construction Engineering and Management, Faculty of Civil Engineering, Tishreen University, Syria, 2024.
- [19] I. A. Zaki, *Neural Networks: Architecture – Algorithms – Applications*. Shoa for Publishing and Media, Aleppo, 2000.
- [20] L.H.Ha, L.M.Hung, and L.Q.Trung, "A risk assessment framework for construction project using artificial neural network". *Journal of Science and Technology in Civil Engineering (STCE) – HUCE*, vol.12,no.5,pp. 51-62, 2018.
- [21] M. A. Shahin, M. B. Jaksa, and H. Maier, "State of the art of artificial neural networks in geotechnical engineering". *Electronic Journal of Geotechnical Engineering*, vol.8,no.1,pp. 1-26, 2008.