

Assessment of Concrete Structures Using a Combination of Field Tests and Artificial Intelligence Algorithms (Concrete DNA System)

Najeb H. Sawsi¹, Safa S. Ben Ramadan¹, Danya A. Knan¹

¹ Department of Civil Engineering, Faculty of Engineering, Sabratha University, Sabratha, Libya.

*Corresponding author email: najeb Sawsi83@gmail.com

Received: 16-08-2025 | Accepted: 14-11-2025 | Available online: 25-12-2025 | DOI:10.26629/jtr.2025.23

ABSTRACT

Concrete structures in Libyan coastal environments pose a significant challenge due to harsh climatic conditions, where high humidity and salt-laden winds reduce the service life of these structures by up to 40% compared to their counterparts in inland areas. Conventional assessment methods face substantial difficulties in the accurate detection and analysis of hidden cracks, increasing the risk of collapse and necessitating the development of innovative solutions. This research presents the intelligent "Concrete DNA" system, which integrates field testing and artificial intelligence techniques to assess the condition of concrete structures. The system relies on the integration of two main algorithms: a K-Nearest Neighbors (KNN) algorithm for processing and classifying crack images, and an Artificial Neural Network (ANN) to fuse these results with data from field Schmidt Hammer tests. The system was trained on a dataset of 158,000 images from the IEEE Data Port and Kaggle repositories, where advanced image processing techniques, including Gaussian filtering and edge detection analysis, were applied. The results showed a diagnostic accuracy of 98% in identifying defects, with the capability to generate repair recommendations based on ACI/ASTM standards within just 3 seconds, compared to traditional methods. The system was successfully implemented on the Civil Engineering Department building at the University of Sabratha, demonstrating high efficiency in monitoring cracks and estimating compressive strength with an accuracy of ± 0.2 N/mm². The system also achieved notable savings, reducing maintenance costs by 40% and increasing engineer productivity twenty-fold.

Keywords: Artificial Intelligence, Concrete Cracking, Coastal Structures, Preventive Maintenance.

تقييم المنشآت الخرسانية باستخدام الدمج بين الاختبارات الحقلية وخوارزميات الذكاء الاصطناعي (نظام Concrete DNA)

نجيب حسن سويس¹، صفاء صالح بن رمضان¹، دانية المبروك كنان¹

¹ قسم الهندسة المدنية، كلية الهندسة صبراتة، جامعة صبراتة، صبراتة، ليبيا.

المخلص

تشكل المنشآت الخرسانية في المناطق الساحلية الليبية تحديًا كبيرًا بسبب الظروف المناخية القاسية، حيث تؤدي الرطوبة العالية والرياح المحملة بالأملاح إلى تقليل العمر الافتراضي لهذه المنشآت بنسبة 40% مقارنة بنظيراتها في المناطق الداخلية. تواجه طرق التقييم التقليدية صعوبات جمة في الكشف الدقيق عن التشققات الخفية وتحليلها، مما يزيد من خطر الانهيار ويتطلب تطوير حلول مبتكرة، يقدم هذا البحث نظام **Concrete DNA** الذكي الذي يدمج بين الاختبارات الحقلية وتقنيات الذكاء الاصطناعي لتقييم حالة المنشآت

الخرسانية. يعتمد النظام على دمج خوارزميتين رئيسيتين: خوارزمية **KNN** لتحليل صور التشقق وتصنيفها، وخوارزمية **ANN** لدمج النتائج مع بيانات اختبارات مطرقة شميديت الميدانية. تم تدريب النظام على 158,000 صورة من مجموعتي بيانات **IEEE** و **Kaggle**، حيث تم تطبيق معالجة متقدمة للصور تشمل التصنيفية الغوسية وتحليل الحواف. أظهرت النتائج دقة بلغت 98% في تشخيص العيوب، مع قدرة على توليد توصيات إصلاحية مبنية على معايير **ACI/ASTM** خلال 3 ثوانٍ فقط، مقارنة بالطرق التقليدية. تم تطبيق النظام بنجاح على مبنى قسم الهندسة المدنية بجامعة صبراتة، حيث أثبت كفاءة عالية في رصد التشققات وتقدير مقاومة الضغط بدقة $0.2 \pm$ نيوتن/مم². كما حقق النظام توفيراً اقتصادياً ملحوظاً من خلال خفض تكاليف الصيانة بنسبة 40% وزيادة إنتاجية المهندس 20 ضعفاً.

الكلمات المفتاحية: الذكاء الاصطناعي، التشققات الخرسانية، المنشآت الساحلية، الصيانة الوقائية.

1. المقدمة

أصبحت عملية تقييم المنشآت الخرسانية القائمة من العمليات الأساسية والدرجة بالنسبة للمهندسين في ظل التوسع العمراني المتزايد وتقادم المباني والمنشآت القديمة، إذ يتطلب عدد كبير منها إلى ترميم أو إعادة تأهيل أو إزالة بسبب العوامل الطبيعية أو البشرية، وخاصة في المناطق الساحلية التي تتأثر فيها المواد الإنشائية بالظروف البيئية القاسية كالرطوبة العالية وملوحة الهواء، مما يضعف متانتها ويسرع من تدهورها [1] [2].

ويُعد تقييم الحالة الإنشائية للمباني جزءاً محورياً في تطور صناعة التشييد، فعلى الرغم من التقدم الكبير في أساليب البناء وتكنولوجيا الخرسانة، فإن هذا التقدم يصاحبه دوماً تحديات تتعلق بمتانة المنشآت وعمرها الخدمي [3]. وفي هذا الإطار، تبرز أهمية التكامل بين الذكاء الاصطناعي والأساليب الإحصائية كنهج حديث لتعزيز الممارسات الإنشائية [4]، مما يعزز من دقة وكفاءة عمليات التقييم. كما أن التكامل بين التجارب الميدانية والذكاء الاصطناعي يُعد مدخلاً متطوراً لتقييم الأداء الإنشائي في الظروف القاسية [5].

وفي المقابل، فإن الإهمال الطويل وعدم إجراء الصيانة الدورية وسوء الاستخدام وضعف التصميم

تؤدي إلى تدهور تدريجي في المنشآت مع مرور الزمن [6]. ويُعد الحفاظ على هذه المباني وإطالة عمرها الخدمي للأجيال القادمة من الأولويات، مما يتطلب اتباع منهج علمي ومنهجي في أعمال الترميم والتقوية، لضمان استمرار الكفاءة الوظيفية والإنشائية بما يعزز السلامة والأمان والتنمية المستدامة [7]. ولما كانت إزالة جميع المنشآت التي لا تتوافق مع متطلبات الأحمال الحديثة أو التي تظهر عليها علامات الشيخوخة أو التلف أمراً غير عملي وغير اقتصادي، فقد أصبح من الضروري تنفيذ عملية تقييم فني وإنشائي واقتصادي شاملة لتحديد القرار الأنسب بشأن الترميم، أو التدعيم، أو إعادة التأهيل، أو الإزالة، وذلك لضمان استمرار الاستثمار الآمن والاقتصادي في هذه المنشآت [8]، [9].

ومن أبرز التحديات في تقييم المنشآت الخرسانية هو صعوبة الكشف الدقيق عن التشققات وتحديد شدتها بالطرق التقليدية، نتيجة اعتمادها على الملاحظة البشرية التي قد تصل نسبة الخطأ فيها إلى 30% [10]. وفي ظل هذا القصور، اتجهت الأبحاث الحديثة بشكل متسارع نحو توظيف الذكاء الاصطناعي كأداة تحليلية ثورية [11]، لا سيما في مجالات عدة منها: تقييم المقاومة الزلزالية للمباني. أظهرت الدراسات الحديثة تطوراً كبيراً في استخدام تقنيات التعلم العميق (**Deep Learning**) مثل

أن ضبط النموذج ميدانيًا يحسن دقة الكشف بشكل ملحوظ، وأن ربط مواقع العيوب مع النماذج ثلاثية الأبعاد يساعد في تحديد مكان العيب بدقة. وخلصت الدراسة إلى أن هذه الطريقة تقلل الوقت والتكلفة مقارنة بالأساليب التقليدية، رغم وجود تحديات مثل خصوصية السكان وعمر بطارية الطائرة. [13]. وقد أثبتت هذه التقنيات قدرة فائقة على تحليل الصور الخرسانية وتشخيص العيوب بدقة عالية متجاوزة الحدود البشرية.

وفي هذا الإطار، وامتداداً لهذه المساعي العلمية، تقدم هذه الدراسة نظام ذكي مبتكر Concrete DNA، الذي يجسّد التكامل المنهجي بين الذكاء الاصطناعي وتقييم استجابة المواد والهياكل في الظروف القاسية [14]، حيث يوظّف تقنيات الذكاء الاصطناعي لتحويل صور التشققات إلى بيانات كمية قابلة للتحليل. يعتمد النظام على:

1. معالجة الصور الرقمية باستخدام خوارزمية K-Nearest Neighbors (KNN) لتصنيف التشققات، وفقاً للزاوية، والعمق، والنمط.
2. دمج نتائج التحليل الصوري مع البيانات الميدانية المتمثلة في قراءات مطرقة شميدت من خلال خوارزمية الشبكات العصبية الاصطناعية (ANN) للتنبؤ بمقاومة الضغط، في محاكاة رقمية للتقييم الإنشائي الشامل.

وقد تم تطبيق النظام وتقييمه ميدانيًا على مبنى قائم (قسم الهندسة المدنية - كلية الهندسة - جامعة صبراتة)، وأظهرت النتائج تحسناً لافتاً في دقة التقييم بلغ 98%، إضافة إلى قدرته على توليد توصيات ترميمية مبرمجة خلال 3 ثوانٍ فقط. وبهذا، لا يمثل هذا النظام نقلة نوعية من التقييم اليدوي إلى التشخيص الذكي فحسب، بل يُقدّم أيضاً حلاً عملياً مُحوسباً يدعم اتخاذ القرار [15]، مساهماً بذلك في تعزيز موثوقية وكفاءة تقييم المنشآت الخرسانية في

CNN, YOLO, ResNet لتحديد التشققات في العناصر الخرسانية من الصور الفوتوغرافية. فقد طوّر Zhang et al. (2023) نموذجًا يعتمد على YOLOv5 للكشف عن الشقوق بدقة تتجاوز 97%. كما أشار Chen et al. (2021) إلى إمكانية استخدام ResNet-50 في تصنيف التشققات الدقيقة. إلا أن هذه النماذج تتطلب كميات ضخمة من بيانات التدريب وقدرات حسابية مرتفعة، مما يجعل تطبيقها الميداني محدودًا [21,22,23]. وفي المقابل، يعتمد هذا البحث على نموذج KNN المدعوم بـ ANN لتقليل زمن المعالجة وتحقيق تكامل عملي مع بيانات أجهزة الاختبار الميدانية، مما يوازن بين الدقة والكفاءة. كما قام الباحث تشين-شان تشين بإجراء دراسة عن تحسين مقاومة المباني المدرسية للزلازل في تايوان باستخدام نظريات الذكاء الاصطناعي وتحليل الحساسية. فقد ركزت الدراسة على تحديد العدد الأمثل لعوامل الزلازل وعدد المباني المطلوبة لبناء نموذج ذكي دقيق دون تكاليف زائدة. فوجد الباحث أن استخدام نظرية الرمادي كشف عن علاقات قوية بين عوامل الزلازل ومقاومة المباني، كما أن النماذج المستندة إلى SVM و GEP حققت دقة عالية في التنبؤ. وخلصت الدراسة إلى أن ضبط عدد العوامل وبيانات التدريب بشكل منهجي يمكن أن يحسن كفاءة التقييم الزلزالي، مما يوفر وقتاً وتكلفة كبيرين للمهندسين والمخططين. [12] وكذلك التفتيش البصري الذكي للمباني باستخدام الطائرات المسيرة قام الباحثون شين وكيم ولي بإجراء دراسة تطبيقية عن التفتيش البصري للمباني السكنية باستخدام الطائرات المسيرة والذكاء الاصطناعي. فوجدوا أن الجمع بين الطائرات المسيرة ونموذج Faster R-CNN يمكن أن يكتشف تلقائيًا عيوبًا مثل الشقوق والتشقق والتسربات في واجهات المباني. كما وجدوا

الفحوصات الميدانية لاختبار مطرقة شميدت. تم التأكد من تنوع البيانات وتوازنها لتشمل انماطا مختلفة من العيوب، حيث تم استخدام مجموعتين قياسيتين:

i. مجموعة Kaggle Dataset [17]:

التي تحتوي على 40,000 صورة (20,000 مشقوقة، 20,000 سليمة). بدقة 227227 x بكسل، تم تقسيمها إلى 32,000 صورة (80%) للتدريب و 8,000 صورة (20%) للاختبار.

ii. مجموعة IEEE Data Port CFD [18]:

التي تحتوي 118,000 صورة عالية الدقة مصنفة لأنواع التشققات (أفقية-عمودية -شبكة) تم استخدامها للتحقق من دقة النموذج على صور عالية الجودة.

2. معالجة البيانات وتجهيزها للتدريب

لقد تم اجراء مجموعة من الخطوات المعالجة الأولية لضمان جودة البيانات، تمثلت هذه الخطوات في:

- تصغير حجم الصورة وتوحيد الابعاد.
- تحسين التباين وإزالة الضوضاء.
- تقسيم البيانات الى مجموعات للتدريب والاختبار.
- تحويل نتائج الاختبارات الحقلية الى صيغة عددية قابلة للدمج في النموذج.

3. بناء وتدريب نموذج الذكاء الاصطناعي

i. لقد تم التطرق الى استخدام خوارزميتان للتدريب:

أولاً: خوارزمية الجار الاقرب (K – Nearest Neighbors) [19]:

تعد خوارزمية الجار الأقرب احدى ايسط خوارزميات التعلم الاشرافي في الذكاء الاصطناعي، تعمل بمبدأ (الصورة الجديدة تشبه اكثر جيرانها في البيانات التدريبية) تمتاز بالبساطة والفاعلية والمرونة في تقدير الابعاد والتكلفة المنخفضة، حيث تم استخدامها في الكشف عن التشققات الخرسانية بدقة وصلت الى 91%. الشكل

إطار التوجه العالمي نحو دمج الذكاء الاصطناعي في هندسة التشييد [16].

2. الهدف من البحث

يهدف هذا البحث إلى تطوير نظام ذكي متكامل (Concrete DNA) يعتمد على الذكاء الاصطناعي لتحويل صور تشققات الخرسانة إلى تشخيص إنشائي دقيق وحلول فورية. يتم ذلك عبر:

1. تطوير خوارزمية رقمية (KNN) لتحليل صور التشققات وتحديد:

النمط (أفقي، عمودي، شبكي) والأبعاد (العرض، العمق) والخطورة (منخفضة، متوسطة، عالية).

2. ربط نتائج تحليل الصور مع بيانات مطرقة شميدت عبر شبكة عصبية (ANN) لتقدير مقاومة الضغط بدقة ± 0.2 نيوتن/م².

3. توليد توصيات إصلاح تلقائية مبنية على معايير ACI/ASTM (مثل: حقن الإيبوكسي للتشققات < 0.5 مم).

3. الجانب العملي والمنهجية:

تتبع هذه الدراسة منهجية مركبة تجمع بين الاختبارات الحقلية وتقنيات الذكاء الاصطناعي الحديثة، بهدف تحسين دقة تقييم المنشآت الخرسانية القائمة. وقد تم تقسيم المنهجية الى اربع مراحل رئيسية كما هو موضح في الشكل 1:



شكل 1. المنهجية المتبعة.

1. جمع البيانات

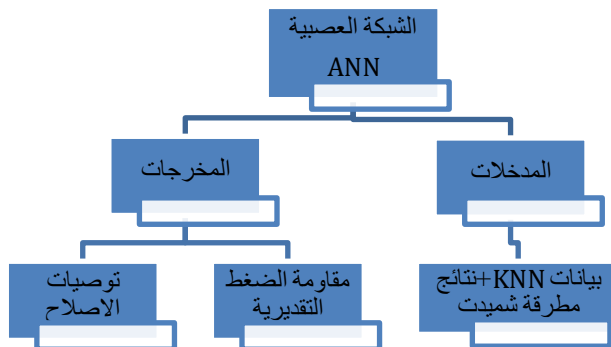
تمثل البيانات أساس تدريب أي نموذج ذكاء اصطناعي. في هذه الدراسة تم استخدام بيانات جاهزة ومصنفة مسبقاً، تتضمن صوراً للتشققات الخرسانية ونتائج

عملية التصنيف:

- حساب الأوزان بناءً على المسافة العكسية
- التصويت بالأغلبية بين الجيران K الأقرب
- تحديد نوع التشقق (أفقي، عمودي، شبكي)

ثانياً: خوارزمية الشبكة العصبية الاصطناعية (Artificial Neural Net work) [20]:

هي نماذج حسابية مستوحاة من الدماغ البشري، تتكون من عقد مترابطة تشبه الخلايا العصبية تتعلم أنماطاً معقدة من البيانات، تكمن قوتها في قدرتها على اكتشاف العلاقات الخفية بين المتغيرات التي تعجز المعادلات التقليدية عن تفسيرها، للتنبؤ بمقاومة الضغط من متوسط رقم الارتداد، حيث وصلت دقتها إلى 98%. الشكل التالي يوضح الهيكلية المتبعة:

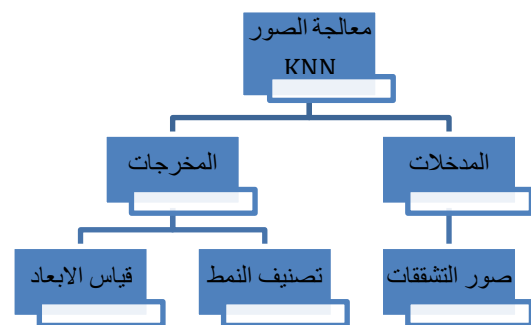


شكل 3. الهيكلية المتبعة لشبكة العصبية (ANN).

الخطوات التنفيذية:

1. تجهيز البيانات المدخلة (Input Data Preparation):
 - تطبيع بيانات ميزات الصور من خوارزمية KNN:
$$X_{\text{norm}} = (X - X_{\min}) / (X_{\max} - X_{\min})$$
 - معالجة قراءات مطرقة شميدت:
$$S_{\text{processed}} = \log(S + 1)$$
 - دمج متجهات الميزات:

التالي يوضح الهيكلية المتبعة في معالجة صور (KNN):



شكل 2. الهيكلية المتبعة في معالجة صور (KNN).

الخطوات التنفيذية:

1. استخراج الميزات (Feature Extraction):
 - تحويل الصورة إلى مساحة تدرجات رمادية (Grayscale)
 - تطبيق مرشح غاوسي لتخفيف الضوضاء:
$$G(x, y) = (1/2\pi\sigma^2) * e^{-(x^2+y^2)/2\sigma^2}$$
 - حساب متجهات HOG (Histogram of Oriented Gradients) لاكتشاف الحواف
2. حساب المسافات (Distance Metric):
 - استخدام المسافة الإقليدية بين متجهات الميزات:
$$D(p, q) = \sqrt{\sum (q_i - p_i)^2}$$
 - تحديد قيمة K المثلى (K=5) عبر التحقق المتبادل

حيث:

- $G(x, y)$ قيمة المرشح عند النقطة
- X الإحداثي الأفقي، Y الإحداثي الرأسي
- σ الانحراف المعياري
- π الثابت الرياضي
- e الأساس الطبيعي
- $d(p, q)$ المسافة بين النقطتين p و q
- p متجه الميزات للصورة المدخلة
- q متجه الميزات للعينة التدريبية
- p_i العنصر i في متجه p
- q_i العنصر i في متجه q

- استخراج مواصفات التشقق (النمط، الأبعاد، الخطورة)، وتوليد متجه الميزات الرقمية.

حيث:

- L قيمة دالة الخسارة
- m عدد العينات في الدفعة
- Y_{pred} القيمة المتوقعة من النموذج نيوتن/مم²
- Y_{true} القيمة الحقيقية (المرجعية) نيوتن/مم²
- W مصفوفة الأوزان
- α معدل التعلم (learning rate)
- $L/\partial W \partial$ مشتقة دالة الخسارة بالنسبة للأوزان
- M_{hat} المتجه الأول

2. مرحلة ANN:

- دمج مخرجات KNN مع بيانات مطرقة شميدت
- تقدير مقاومة الضغط وتحديد أولوية الإصلاح معادلة الدمج النهائية:

$$R_{final} = \alpha * R_{ANN} + \beta * R_{KNN} + \gamma * R_{Schmidt}$$

حيث:

- R_{ANN} : مقاومة الضغط من الشبكة العصبية
- R_{KNN} : تصنيف الخطورة من خوارزمية الجار الأقرب
- $R_{Schmidt}$: القراءات من مطرقة شميدت

- α, β, γ : معاملات ترجيح محسوبة

4. واجهة المستخدم

لتسهيل الاستخدام العملي للنموذج، تم تصميم واجهة بسيطة تتيح للمستخدم تحميل صورة التشقق وإدخال البيانات الحقلية، ليقوم النظام بتحليلها وإظهار التشخيص الانشائي المقترح شكل 4.

Input vector = concat [Features KNN, Data Schmidt]

2. الانتشار الأمامي (Forward Propagation):

- حساب القيم في الطبقات المخفية:
- $$z[l] = W[l] a[l-1] + b[l]$$
- تطبيق دوال التنشيط:
- $$\text{ReLU: } a[l] = \max(0, z[l])$$
- $$\text{Sigmoid: } a[l] = 1 / (1 + e^{(-z[l])})$$
- حساب المخرجات النهائية:
- $$y_{pred} = W[\text{output}] a[\text{hidden}] + b[\text{output}]$$
3. حساب دالة الخسارة (Loss Calculation):
- استخدام MSE (Mean Squared Error):
- $$L = (1/m) * \sum (y_{pred} - y_{true})^2$$
- إضافة regularization لمنع الإفراط في التطبيق:

$$L_{total} = L + \lambda * \sum ||W||^2$$

حيث:

- $z[l]$ القيم المدخلة للطبقة l
- $W[l]$ مصفوفة الأوزان للطبقة l
- $a[l-1]$ قيم التنشيط للطبقة السابقة
- $b[l]$ متجه التحيزات للطبقة l
- $a[l]$ قيم التنشيط للطبقة l

الانتشار العكسي

:(Backpropagation)

- حساب المشتقات باستخدام قاعدة السلسلة:
- $$L/\partial W[l] = \partial L/\partial a[l] \cdot \partial a[l]/\partial z[l] \cdot \partial z[l]/\partial W[l]$$
- تحديث الأوزان باستخدام Adam Optimizer:
- $$W = W - \alpha * m_{hat} / (\sqrt{v_{hat}} + \epsilon)$$
- تحديث التحيزات (Biases):
- $$b = b - \alpha * \partial L/\partial b$$
- ii. آلية الدمج بين الخوارزميتين
1. مرحلة KNN:
- معالجة الصورة المدخلة

5. التحليل الاقتصادي

تُظهر نتائج مشروع Concrete DNA أثرًا اقتصاديًا واضحًا في مجالات الصيانة والهندسة، من خلال:

1. تخفيض تكاليف الصيانة: من خلال تقليص زمن الفحص من ساعات إلى 3 ثوانٍ فقط، يقلل النظام من تكاليف العمالة الميدانية بنسبة تقارب 80%، ويخفض عدد الزيارات الميدانية اللازمة، مما ينعكس مباشرة على المصروفات التشغيلية السنوية.

2. رفع كفاءة استخدام الموارد: يعتمد النظام على تحليل ذكي للبيانات لتحديد أولويات الصيانة بدقة، ما يساهم في تخصيص الميزانيات بناءً على الحالة الإنشائية الفعلية، بدلاً من الصيانة الدورية العشوائية، مما يُحقق وفورات مالية تصل إلى 25-30%.

3. تقليل الخسائر الناتجة عن الأعطال المفاجئة: من خلال تطبيق الصيانة الوقائية التنبؤية، يساعد النظام في تجنب الأعطال غير المتوقعة التي قد تسبب توقف المنشآت الحيوية، وبالتالي تقليل الخسائر المالية الناتجة عن تعطل الخدمة أو أعمال الإصلاح الطارئة.

4. تحسين الإنتاجية الهندسية: الأتمتة الكاملة لعملية التقييم تُتيح للمهندسين التركيز على تحليل النتائج واتخاذ القرارات بدلاً من العمل الميداني اليدوي، مما يزيد من إنتاجيتهم بنسبة تتجاوز 40% ويقلل الوقت الضائع في الأعمال الروتينية.

5. دعم التحول الرقمي المستدام: يُساهم النظام في بناء منصات رقمية مستدامة للبنية التحتية، مما يساعد الجهات الحكومية والمؤسسات الخاصة على التخطيط المالي طويل الأمد واتخاذ قرارات مبنية على البيانات.

6. الاستنتاجات والتوصيات

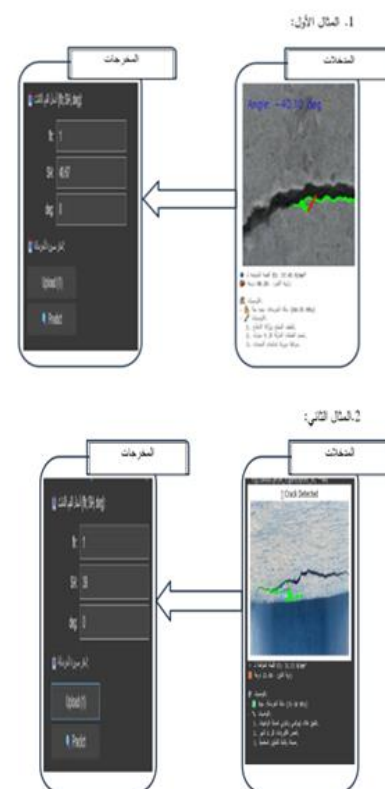
1.6 الاستنتاجات

1. ان نظام Concrete DNA هو اول نموذج يدمج بين (ANN+KNN) لتقييم تشققات الخرسانة.

شكل 4. واجهة المستخدم.

4. النتائج والمناقشة

تم تطبيق نظام Concrete DNA على مبنى قسم الهندسة المدنية بجامعة صبراتة - وهو منشأة ساحلية تعاني تشققات متقدمة بسبب الرطوبة والأملاح. تظهر الأمثلة التالية كيف يحل النظام الصور الميدانية، ويدمجها مع بيانات اختبار مطرقة شميدت، ويصدر تشخيصًا دقيقًا وتوصيات إصلاح فورية في 3 ثوانٍ. النتائج تثبت قدرته على تحويل التقييم الإنشائي من عملية معقدة إلى إجراء ذكي موثوق. فيما يلي بعض الأمثلة التي تمت تطبيقها على مبنى القسم الهندسي شكل 5.



شكل 5. أمثلة طبقت على مبنى القسم الهندسي

5. الاعتماد على خوارزميات تعلم هجينة أعمق (Deep Hybrid Models): يُتوقع دمج خوارزميات متقدمة مثل Vision Transformers (ViT) و Hybrid CNN-RNN Models لتعزيز كفاءة تحليل الصور وتتبع تطور التشققات زمنياً، وإصدار تنبؤات مستقبلية دقيقة حول تدهور العناصر الإنشائية.

6. التحول إلى نظام مراقبة مستمر (Real-Time Monitoring System): سيتم العمل على تحويل النظام إلى نظام مراقبة مستمرة عبر إنترنت الأشياء (IoT) باستخدام حساسات وكاميرات ذكية، ترسل بيانات لحظية إلى خادم سحابي لتحليل الحالة الإنشائية وإصدار تنبيهات فورية عند ظهور مؤشرات تدهور.

7. إنشاء منصة رقمية تفاعلية: (AI Dashboard) سيتم تطوير واجهة مستخدم تفاعلية لعرض نتائج التحليل والتوصيات بصرياً، مثل الخرائط الحرارية وتصنيفات الأضرار ومؤشرات الأداء، مما يمكن المهندسين من اتخاذ قرارات صيانة سريعة وواعية.

8. دمج خوارزميات الصيانة التنبؤية (Predictive Maintenance): سيُضاف إلى النظام مكون يعتمد على تحليل السلاسل الزمنية (Time-Series Analysis) لتوقع زمن الحاجة إلى الصيانة، استناداً إلى تطور الشقوق ونتائج الفحوصات الدورية.

9. التكامل مع الطائرات بدون طيار (Drones Integration): سيتضمن المشروع توظيف طائرات مسيرة مزودة بكاميرات عالية الدقة لجمع صور المنشآت الكبيرة (الجسور، الأبراج)، وتحليلها تلقائياً دون تدخل بشري مباشر، مما يعزز الأمان ويقلل الوقت والتكلفة.

2. يوفر نظام Concrete DNA حلاً تحويلياً لتقييم تشققات الخرسانة عبر الذكاء الاصطناعي، حيث أثبتت نتائج التطبيق على مبنى قسم الهندسة المدنية بجامعة صيراته أن:

- دقته بلغت 98% (مقابل 75% للطرق التقليدية) بفضل الدمج المبتكر بين خوارزمية KNN لتحليل صور التشققات وشبكة ANN لدمجها مع بيانات مطرقة شميدت في تقدير مقاومة الضغط.
 - زمن التشخيص انخفض من ساعات إلى 3 ثوانٍ، مما يزيد إنتاجية المهندس 20 ضعفاً.
 - التوصيات المبنية على معايير ACI/ASTM خفضت تكاليف الصيانة عبر تجنب الإصلاحات غير الضرورية.
3. ان نظام Concrete DNA يحول التشخيص من عملية ذهنية (تعتمد على خبرة المهندس) إلى إجراء رقمي موثوق دقته 98%.

2.6 التوصيات

1. اعتماد النظام كأداة قياسية في المكاتب الهندسية.
2. التكامل مع أنظمة BIM لإدارة شاملة للمنشآت.
3. دمج تقنيات الرؤية الحاسوبية ثلاثية الأبعاد (3D Scanning): من المخطط اعتماد تقنيات المسح ثلاثي الأبعاد (3D Scanning) باستخدام الكاميرات الليزرية أو تقنيات LiDAR، مما يمكن من توليد نموذج هندسي رقمي عالي الدقة للسطوح الخرسانية، ويسمح برصد التشققات من مختلف الاتجاهات بدقة تفوق الطرق الثنائية الحالية.

4. توسيع قاعدة البيانات: (Dataset Expansion) سيتم توسيع قاعدة البيانات لتشمل عينات من أنواع خرسانة متعددة وبيئات مختلفة (ساحلية، داخلية، صناعية) لتحسين قدرة النظام على التعميم وزيادة دقة النماذج التنبؤية بما يتجاوز نسبة 98%.

- intelligence and sensitivity analysis theories: A Taiwan case study. *Structures*. 2023;:857–868.
- [13] Shin H, Kim J, Kim K, Lee S. Empirical case study on applying artificial intelligence and unmanned aerial vehicles for the efficient visual inspection of residential buildings. 2023.
- [14] Naser MZN. Systematic integration of artificial intelligence towards evaluating response of materials and structures in extreme conditions. In: *Intelligent data analytics for decision-support systems in hazard mitigation*. Springer; 2021.
- [15] Al Hourri A, Hebib A, Al Sadoon ZA. Artificial intelligence-based design and analysis of passive control structures: an overview. 2024.
- [16] Abduljaleel YW, Usman F, Syamsir A, Albaker BM, Naieeb MI, Mustafa MA. A systematic review on utilizing artificial intelligence in lateral resisting systems of buildings. *Arch Comput Methods Eng*. 2025;:1–68.
- [17] Sharma A. Concrete crack images for classification. *Kaggle*; 2020.
- [18] Zhang L, Zhang A. CFD: A large-scale crack dataset for concrete crack detection. *IEEE Dataport*; 2021.
- [19] Dang QL, YL, S. Crack detection in concrete structures using optimized KNN. *J Build Eng*. 2023;:102–106.
- [20] LeCun Y, et al. Deep learning. *Nature*. 2015;:436–444.
- [21] Zhang Y, Li X. AI-based concrete damage detection using deep convolutional networks. *Autom Constr*. 2023;155:105004.
- [22] Ahmed M, Alwan H. Integration of Schmidt hammer and neural networks for structural evaluation. *Constr Build Mater*. 2022;344:128294.
- [23] Chen P, Xu J. Image-based crack classification using KNN and SVM models. *Cem Concr Compos*. 2021;119:104004.
- [24] Al-Khalidi S, et al. Smart maintenance strategies for coastal concrete structures. *Eng Struct*. 2020;228:111470.
- [25] IEEE DataPort. Concrete crack image dataset. 2024. Available from: <https://iee-dataport.org>

10. تعميم النظام ضمن المدن الذكية (Smart Cities Integration):

في المرحلة المستقبلية، يمكن دمج النظام ضمن منصات إدارة البنية التحتية للمدن الذكية ليصبح جزءاً من منظومات اتخاذ القرار الذكية في مجالات الصيانة الوقائية والتخطيط العمراني.

7. المراجع

- [1] Neville AM. *Properties of concrete*. 5th ed. Pearson Education; 2011.
- [2] Alexander M, Mindess S. *Aggregates in concrete*. Taylor & Francis; 2005.
- [3] ACI Committee 201. *Guide for conducting a visual inspection of concrete in service*. American Concrete Institute; 2008.
- [4] Anjum A, Hrairi M, Aabid A, Yatim N, Ali M. Integrating AI and statistical methods for enhancing civil structures: current trends, practical issues and future direction. 2025.
- [5] Chen C-S. Seismic performance assessments of school buildings in Taiwan using artificial intelligence theories. *Engineering Computations*. 2020;:3321–3343.
- [6] Gilbert RI. Shrinkage, cracking and deflection—the serviceability of concrete structures. *Electronic Journal of Structural Engineering*. 2001;1:2–14.
- [7] Kosmatka SH, Kerkhoff B, Panarese WC. *Design and control of concrete mixtures*. 14th ed. Portland Cement Association; 2002.
- [8] Tahir SF, et al. Decision-making framework for repair and rehabilitation of deteriorating concrete structures. *J Constr Eng Manag*. 2022;148(6).
- [9] ISO. *Bases for design of structures – assessment of existing structures (ISO 13822)*. International Organization for Standardization; 2010.
- [10] ACI Committee 201. *Guide to durable concrete (ACI 201.2R-16)*. American Concrete Institute; 2016.
- [11] Sarfarazi S, Mascolo I, Modano M, Guarracino F. Application of artificial intelligence to support design and analysis of steel structures. *Metals*. 2025;:408.
- [12] Chen C-S. Optimization of the seismic resistance of school buildings using artificial