مجلة جامعة طرطوس للبحوث والدراسات العلمية _ سلسلة العلوم الهندسية المجلد (10) العدد (9) 2026
Tartous University Journal for Research and Scientific Studies - engineering Sciences Series Vol. (10) No. (9) 2026

دراسة تأثير المعالجة المسبقة للصور على أداء الشبكة العصبونية التلافيفية في تصنيف صور التصدعات الخرسانية

***د. م. ماهر علي إبراهيم**

****م. جيانا جمال حسن**

(تاريخ الإيداع 2026/4/2 . قُبِل للنشر في 2026/5/12)

□ ملخّص □

تعتبر الشبكات العصبونية التلافيفية (Convolutional Neural Networks CNN) من أبرز نماذج التعلم العميق، ومن أهم المجالات التي تم العمل عليها في الآونة الأخيرة هي رصد العيوب والتصدعات في المنشآت الخرسانية، ونظراً لأهمية مرحلة التحضير الأولي للبيانات قبل مرحلة تدريب الشبكة، تهدف هذه الدراسة إلى تقييم تأثير المعالجة المسبقة للصور على أداء نموذج CNN في تصنيف صور الخرسانة.

تم استخدام مجموعة بيانات متاحة للباحثين لصور الخرسانة في المباني وإنشاء نموذج شبكة عصبونية التفافية CNN من أجل تصنيف صور الخرسانة إلى فئتين: متصدعة (Cracked C) وغير متصدعة (Un Cracked UC)، وتم تدريب النموذج على هذه البيانات بعد إخضاعها للعديد من عمليات المعالجة المسبقة.

تم تدريب الشبكة لمدة 10 epochs وتم إدخال الصور إلى الشبكة التلافيفية وفق أربعة إدخالات بشكل منفصل بحيث تم تدريب أربع نماذج سيتم تفصيلها لاحقاً، بلغت دقة الاختبار للنماذج الأربعة على التوالي (97.10%، 95%، 97.15%، 96.35%) وبينت النتائج أن تقنيات المعالجة البسيطة مثل التحويل إلى تدرجات الرمادي و التنعيم الغاوسي قدمت أفضل أداء لأنها تحافظ على السمات الأصلية للتصدعات، أما الطرق المعقدة مثل المرشح الثنائي ومعادلة المدرج التكراري التكيفي و الترشيح المتماثل أدت إلى تشويه التفاصيل الدقيقة للصدع أو تضخيم الضوضاء.

الكلمات المفتاحية: الشبكة العصبونية الالتفافية، معادلة المدرج التكراري التكيفي، المرشح الثنائي، الخرسانة، التنعيم الغاوسي، الترشيح المتماثل.

*أستاذ مساعد في قسم هندسة تكنولوجيا المعلومات–كلية هندسة تكنولوجيا المعلومات والاتصالات–جامعة طرطوس الحكومية–طرطوس–سوريا

**معيدة وماجستير في قسم هندسة تكنولوجيا المعلومات–كلية هندسة تكنولوجيا المعلومات والاتصالات–جامعة طرطوس الحكومية–طرطوس–سوريا

مجلة جامعة طرطوس للبحوث والدراسات العلمية _ سلسلة العلوم الهندسية المجلد (10) العدد (9) 2026
Tartous University Journal for Research and Scientific Studies - engineering Sciences Series Vol. (10) No. (9) 2026

Study of the effect of image preprocessing on the performance of a convolutional neural network in classifying concrete crack images

Dr. Eng. Maher Ali Ibrahrim *
Eng. Jiana Jamal Hasan **

(Received 2/4/2026. Accepted 12/5/2026)

ABSTRACT

Convolutional Neural Networks (CNNs) are among the most prominent deep learning models, and one of the most important areas of recent research is the detection of defects and cracks in concrete structures. Given the importance of the initial data preparation phase before network training, this study aims to evaluate the effect of image preprocessing on the performance of a CNN model in classifying concrete images.

A readily available dataset of concrete images from buildings was used to create a convolutional neural network (CNN) model to classify the concrete images into two categories: cracked (C) and uncracked (UC). The model was trained on this data after it underwent several preprocessing steps.

The network was trained for 10 epochs and the images were fed into the convolutional network in four separate inputs so that four models were trained, which will be detailed later. The test accuracy for the four models was (97.10%, 95%, 97.15%, 96.35%) respectively. The results showed that simple processing techniques such as grayscale conversion and Gaussian smoothing performed best because they preserved the original features of the cracks, while complex methods such as Bilateral filtering, CLAH and Homomorphic filtering led to distortion of fine crack details or noise amplification.

Keywords: Convolutional neural network, CLAH, Bilateral filtering, concrete, Gaussian smoothing, Homomorphic filtering.

*Associate professor, Department of Information Technology Engineering, Faculty of Information and Communication Technology Engineering, University of Tartous, Syria

** Teaching Assistant and Postgraduate, Department of Information Technology Engineering, Faculty of Information and Communication Technology Engineering, University of Tartous, Syria.

1- المقدمة

الخَرَسَانَة هي مادة تتكون من الإسمنت والرمل والماء مع إضافة نوع من الركام، وهي من أهم مواد البناء في العصر الحديث خصوصاً مع تدعيمها بالحديد لتصبح خرسانة مسلحة، لكن كثيرًا ما تتعرض المباني والمنشآت الخرسانية لأخطار تهدد سلامتها؛ حيث تعدّ التصدعات إحدى الإشارات الواضحة على تضررها وتدهور حالتها. فالخرسانة، رغم قوتها ومتانتها، ليست بمنأى عن تأثير العوامل البيئية والإنشائية التي قد تؤدي إلى ظهور تشققات غير مرغوب فيها. تأتي هذه الشروخ نتيجة تعرض الخرسانة لظروف بيئية قاسية كالحرارة الشديدة، والرطوبة العالية، والزلازل والأعاصير، وحتى بسبب الاستخدام غير السليم أو التصميم والتنفيذ غير الدقيقين (ASKAR et al., 2023).

في ظل التطورات التقنية المتسارعة، اكتسبت تقنيات هندسة تكنولوجيا المعلومات أهمية متزايدة في مجال سلامة المنشآت، حيث توفر أدوات رقمية متقدمة لكشف التصدعات في وقت مبكر. باستخدام التصوير الرقمي وتقنيات المعالجة الذكية، أصبحت الأنظمة الحديثة قادرة على تحليل صور الخرسانة بفعالية، مما يتيح سرعة الاستجابة للحد من الأضرار المحتملة. أسهمت هذه التقنيات بشكل كبير في إطالة عمر المنشآت، وتعزيز استدامتها، وخفض المخاطر، إلى جانب رفع كفاءة الصيانة والسلامة في الهياكل الخرسانية (BHOWMICK et al., 2020).

يقدم هذا البحث منهجاً مقترحاً للكشف عن التصدعات في صور الأسطح الخرسانية باستخدام شبكات CNN ويرّكز على دراسة تأثير عمليات المعالجة المسبقة للصور على أداء الشبكة.

1-1- أهمية البحث وأهدافه

رغم التطور الكبير في تطبيقات الذكاء الاصطناعي في كافة المجالات، فإن معظم الدراسات ركزت على تصميم النماذج أو تحسين بنيتها مع إهمال دراسة تأثير طرق معالجة البيانات المدخلة قبل التدريب على أداء هذه النماذج، ومن هنا ينطلق هذا البحث لدراسة دور المعالجة المسبقة للصور على أداء الشبكة العصبونية التلافيفية في تصنيف صور تصدعات المنشآت (الأبنية) الخرسانية حيث سيساهم في تقديم رؤية منهجية حول كيفية اختيار تقنيات المعالجة المسبقة بما يعزز دقة النماذج وكفاءتها.

يهدف البحث إلى:

- ❖ بناء شبكة عصبونية تلافيفية CNN لتقوم بمهمة التصنيف لصور الخرسانة إلى متصدعة / غير متصدعة.
- ❖ تطبيق أربع تقنيات معالجة مسبقة مختلفة على الصور ودراسة أثر كل نوع منها بشكل مستقل على أداء الشبكة وفق:
  - o نموذج A: الصور بعد تحويلها إلى تدرجات الرمادي
  - o نموذج B: الصور بعد تطبيق Bilateral + CLAHE عليها كمرحلة معالجة مسبقة
  - o نموذج C: الصور بعد معالجتها باستخدام Gaussian smoothing
  - o نموذج D: الصور بعد تطبيق Homomorphic filtering عليها كخطوة معالجة مسبقة
- ❖ مقارنة النتائج لتحديد أكثر هذه التقنيات تحسيناً في أداء الشبكة العصبونية.

2- موارد البحث وطرائقه

أنجز هذا البحث للمساهمة في كشف التصدعات من الصور الملتقطة للأسطح الخرسانية بالاعتماد على تقنيات معالجة الصورة والتعلم العميق.

2-1- الدراسات المرجعية

قامت الدراسة (BHOWMICK et al., 2020) بتقديم إطار باستخدام الرؤية الحاسوبية وخوارزميات التعلم العميق لكشف التشققات على السطح الخرساني من الصورة عن طريق إجراء تجزئة للصورة على مستوى البكسل، أي تصنيف البكسلات في صورة السطح الخرساني وما إذا كانت تنتمي إلى الشقوق أم لا، تم التنفيذ باستخدام بنية شبكة عصبونية عميقة تسمى U-Net. كما تم إجراء قياسات كثيفة للتشققات، مثل الطول والعرض والمساحة واتجاه الشق.

وفي الدراسة (LE et al., 2021) تطوير نموذج قائم على التعلم العميق للكشف عن الشقوق على الأسطح الخرسانية واعتمد النموذج المطور لتصنيف الصور على الشبكة العصبونية التلافيفية CNN، حقق النموذج أداء تصنيف ممتاز، حيث إنه حقق دقة 97.7%، لكنه لم يتمكن من اكتشاف الشقوق في بعض الحالات (صورة تحوي شقوق في الزوايا، صورة ذات دقة منخفضة، صورة شقوق صغيرة جدا).

قدمت الدراسة (ADAM & SATHESH, 2021) تقنية جديدة للكشف عن الشقوق في الجسور الخرسانية من خلال إجراء التصنيف عبر Support Vector Machine (SVM)، كما تم تنفيذ استخراج الميزات والتدريب على الشبكة باستخدام CNN، تم تنفيذ عملية استخراج الميزات وتدريب الشبكة باستخدام CNN، ثم تم دمج طريقة SVM في بنية CNN للحصول على تصنيف أفضل للصور. حققت الخوارزمية تحسيناً في الدقة حيث بلغت 92% مقارنة باستخدام مصنف CNN وحيداً والذي حقق دقة قدرها 89%.

تتضمن الدراسة (BANIMUSTAFA et al., 2023) إنشاء ثلاثة نماذج: تم بناء نموذجين باستخدام شبكات التعلم ResNet-50 و Xception وأما الثالث باستخدام بنية الشبكة العصبونية التلافيفية التسلسلية Sequential convolutional neural networks (SCNN).

حقق نموذج SCNN أفضل أداء لدقة التصنيف بنسبة 90.25%، يليه نموذج Xception الذي سجل 86.3%، ونموذج ResNet-50 الذي سجل 70%.

طبقت الدراسة (FLAH et al., 2020) ثلاث مجموعات من خوارزميات التصنيف المصنف الأول يقوم بتصنيف الصور إلى (متصدعة) أم (غير متصدعة) والمصنف الثاني يقوم بتصنيف الصور المتصدعة بناء على طريقة وجود الصدع واتجاهه في الصورة إلى أربع تصنيفات وهي: Vertical left (VL), Vertical right (VR), Horizontal Left (HL), Horizontal right (HR) أما المصنف الثالث يدمج بين الفئات الخمسة. وفر النموذج أداة قوية لتصنيف وتوطين وتجزئة وتقدير الأضرار في العناصر الهيكلية الخرسانية وكانت دقة الاختبار المسجلة 98.25%، و 97.18%، و96.17% للمصنفات الأول والثاني والثالث على التوالي. لكن هذه الدراسات لم تركز على جانب المعالجة المسبقة للصور ولم تعطه دوراً رئيسياً في التحليل.

بينما ركزت الدراسة (GOLDING et al., 2022) على مدى تأثير المعالجة المسبقة للصور على نماذج CNN المدربة مسبقا، حيث تم تقييم صور RGB التي تحوي تشققات والمعالجة مسبقًا باستخدام تقنيات IP (Image Processing) المختلفة (التدرج الرمادي، والعتبة، واكتشاف الحافة) لتقدير ما إذا كان بإمكان هذه التقنيات أن تحسن أداء تصنيف CNN في اكتشاف التشققات واكتساب رؤى قيمة حول تأثيرات مجموعات بيانات الصور المعالجة على

خوارزميات DL. وأظهرت هذه الدراسة أن اللون ليس ميزة ذات صلة في اكتشاف تشققات DL. وكان هذا واعدًا، حيث إن الصور الملونة أكبر حجمًا، كما أن تقليل حجم بيانات الصورة قد يؤدي إلى زيادة سرعة المعالجة وتقليل حجم البيانات اللازمة للتخزين.

يتضح من ذلك قلة الدراسات التي تخصص اهتماماً منهجياً لدراسة أثر تقنيات المعالجة المسبقة على أداء الشبكات العصبونية التلافيفية في تصنيف صور التصدعات، وهو ما تسعى هذه الدراسة لمعالجته.

2-2- منهجية البحث

تشمل منهجية البحث المقترحة أربع خطوات رئيسية، ويوضحها الشكل (1):

- ❖ تحضير الصور.
- ❖ إجراء عمليات المعالجة المسبقة للصور قبل إدخالها إلى الشبكة العصبونية باستخدام تقنيات مختلفة.
- ❖ تصنيف الصور إلى متصدعة أم غير متصدعة باستخدام الشبكة العصبونية الالتفافية CNN.
- ❖ مقارنة النتائج.

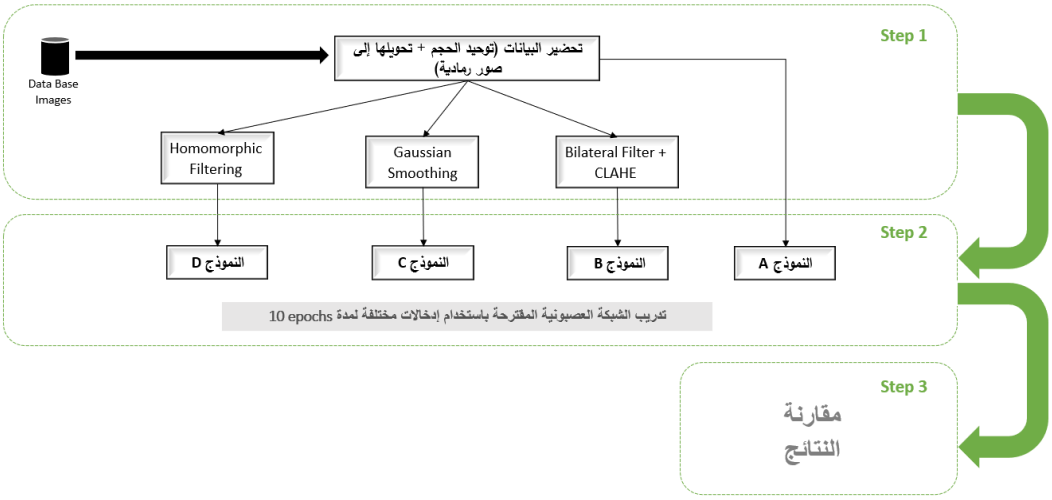
تم الحصول على الصور التي دُربت عليها الشبكة من قاعدتي بيانات Concrete Crack Images وDESNET حيث تم تقسيم الصور إلى مجموعتين Negative وتتضمن صوراً لا تحوي تصدعات والثانية Positive والتي تتضمن الصور الحاوية على تصدعات، بحيث تتكون كل مجموعة من 10000 صورة، وتم تدريب الشبكة العصبونية باستخدام لغة بايثون على منصة Google Colab.

2-2-1- تحضير البيانات

تم تنسيق البيانات من حيث تغيير الحجم وتحويل الصور إلى تدرجات الرمادي وذلك بهدف تقليل عبء الذاكرة وزيادة سرعة المعالجة:

- ❖ تغيير حجم الصور: تم توحيد حجم الصور إلى 128 × 128 وهو أمر مهم لأن الشبكات العصبونية تحتاج إلى مدخلات بالأبعاد نفسها مما يساعد على تسريع عملية التعلم وتقليل تعقيد النموذج.
- ❖ تحويل الصور إلى تدرجات الرمادي: يبسط عملية التعلم للشبكة العصبونية ويقلل عدد القنوات من ثلاث قنوات في الصور الملونة (RGB) إلى قناة واحدة، مما يقلل من تعقيد الحسابات ويوفر مساحة الذاكرة.

بعد القيام بالتحجيم والتحويل إلى الرمادي، تم تطبيق مجموعة من عمليات المعالجة الإضافية للصور قبل إدخالها إلى الشبكة العصبونية سنتحدث أولاً عن هذه العمليات ثم عن كيفية التعامل مع شبكة CNN، سيتم استخدام المرشحات التالية:



الشكل (1): خطوات منهجية البحث المقترحة

2-2-1-1 المرشح الثنائي (Bilateral Filter)

المرشح الثنائي (Bilateral Filter) هو مرشح محلي غير خطي يُستخدم للتنعيم مع الحفاظ على الحواف (WOLFRAM RESEARCH, 2010)، هذه الطريقة غير تكرارية ومحلية وبسيطة فهي تجمع مستويات الرمادي أو الألوان بناءً على تقاربها الهندسي وتشابهها الضوئي، يستخدم لتنعيم الصور وإزالة التباينات الموضعية الناتجة عادةً عن التشويش، والخشونة في الملمس، وما إلى ذلك ويُستخدم مرشح ثنائي الاتجاه غالبًا كخطوة تمهيدية قبل إجراء عمليات تحليل الصور الأخرى (TOMASI & MANDUCHI, 1998). بمعنى آخر يتجاهل البكسلات التي تختلف في شدتها بشكل كبير عن البكسل الأصلي بالتالي يحافظ على الحواف المهمة (حواف التصدعات) ويقلل الضجيج الناتج من خشونة سطح الخرسانة، يتم التنعيم عن طريق استبدال كل بكسل بمتوسط مرجّح لجيرانه، حيث تُؤخذ الأوزان من توزيع غاوسي مُعَيَّر بناءً على تشابه قيم الألوان.

يأخذ عاملين بعين الاعتبار وهما المسافة بين البكسلات والاختلاف في القيم الرمادية أو اللونية بين البكسلات، ويعرَّف رياضياً وفقاً للعلاقة (1):

$$I_{\text{filtered}}(x) = \frac{1}{W_x}\sum_{y\in\Omega} I(y)\cdot f_s(\|x-y\|)\cdot f_r(|I(x)-I(y)|) \qquad (1)$$

حيث أن I(x): قيمة البكسل في الموقع x – Ω: الجوار المحلي – f_s: دالة غاوس للمسافة المكانية المعرفة بالعلاقة (2) – f_r: دالة غاوس لاختلاف الشدة المعرفة بالعلاقة (3) – W_x: وزن التطبيع.

$$f_s(\|x-y\|) = exp\left(-\frac{\|x-y\|^2}{2\sigma_s^2}\right) \qquad (2)$$

σ_s : Spatial Sigma تحدد مدى تأثير البكسلات المتجاورة، وكلما زادت تؤثر بكسلات أبعد على التنعيم.

$$f_r(|I(x)-I(y)|) = \exp\left(-\frac{|I(x)-I(y)|^2}{2\sigma_r^2}\right) \qquad (3)$$

σ_r : Range Sigma للتحكم بحساسية الفلتر لفرق الألوان أو مستويات الرمادي، وكلما زادت يتم دمج ألوان أكثر تباعداً.

2-1-2-2 معادلة المدرج التكراري التكيفي (Contrast Limited Adaptive Histogram Equalization)

CLAHE هو نسخة محسنة من تقنيات تحسين التباين فهو يقوم بتحسين التباين على أجزاء صغيرة من الصورة tiles بدلاً من رفع تباين الصورة كاملة (MUSA et al., 2018)، الأمر الذي يجعل التصدعات أكثر وضوحاً خاصة في الصور ذات الإضاءة المنخفضة، مع وضع حد أعلى لمقدار التحسين لمنع تضخيم الضجيج، يعتمد CLAHE على دالة تحويل تعتمد على التوزيع التراكمي CDF داخل كل جزء ويعرف وفق العلاقة (4):

$$I_{out}(x) = (L-1) \cdot CDF_{tile}(I_{in}(x)) \quad (4)$$

حيث أن CDF_{tile}: هو التوزيع التراكمي المحلي – L: عدد مستويات الرمادي.

2-1-2-3 التنعيم الغاوسي (Gaussian smoothing)

هو أحد أشهر مرشحات تنعيم الصور، ويُستخدم لتقليل الضجيج عالي التردد وتحضير الصورة للمعالجة اللاحقة، يعرف وفق العلاقة (5)، تعتمد فكرة التنعيم الغاوسي على استخدام هذا التوزيع ثنائي الأبعاد كدالة "انتشار نقطي"، ويتحقق ذلك من خلال عملية الالتفاف (RICHARDS, 2003). من أهم خصائصه أنه يزيل الضجيج العالي ويحافظ على شكل الكائن بالتالي يساعد CNN عندما تكون الصور مليئة بالتغيرات المحلية غير المهمة (خشونة سطح الخرسانة)، لكنه من الممكن أن يضر بالأداء إذا كان التصدع الموجود في الصورة ضعيف التباين.

$$G_\sigma(x,y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2+y^2}{2\sigma^2}\right) \quad (5)$$

حيث σ: الانحراف المعياري (درجة التنعيم) وكلما ازدادت زاد التنعيم وطمس التفاصيل – x,y: الإزاحة عن النقطة المركزية.

2-1-2-4 الترشيح المتماثل (Homomorphic Filtering)

الترشيح المتماثل (HF) هو منهجية تفصل الصورة إلى مكونين: الإضاءة والانعكاس. من خلال معالجة هذين المكونين، يُمكن تحسين تباين المكونات منخفضة التردد بشكل ملحوظ مع الحفاظ على حواف الصورة وخصائصها الحادة (CHAVARÍN et al., 2023). حيث أنه يعزز الانعكاس (التفاصيل المهمة في الصورة) ويقمع الإضاءة (المصدر الرئيسي للضجيج)، بالتالي يناسب التعامل مع تغيرات الإضاءة القوية الموجودة في الصور الملتقطة للخرسانة كما يرفع التفاصيل الدقيقة للتصدعات، ويعرف بالعلاقة (6).

$$H(u,v) = (\gamma_H - \gamma_L)\left[1 - e^{-\frac{D(u,v)^2}{2\sigma^2}}\right] + \gamma_L \quad (6)$$

حيث أن $D(u,v)$: المسافة من مركز ترددات فوريه – $\gamma_H > 1$: تعزيز التفاصيل – $\gamma_L < 1$: قمع الإضاءة –

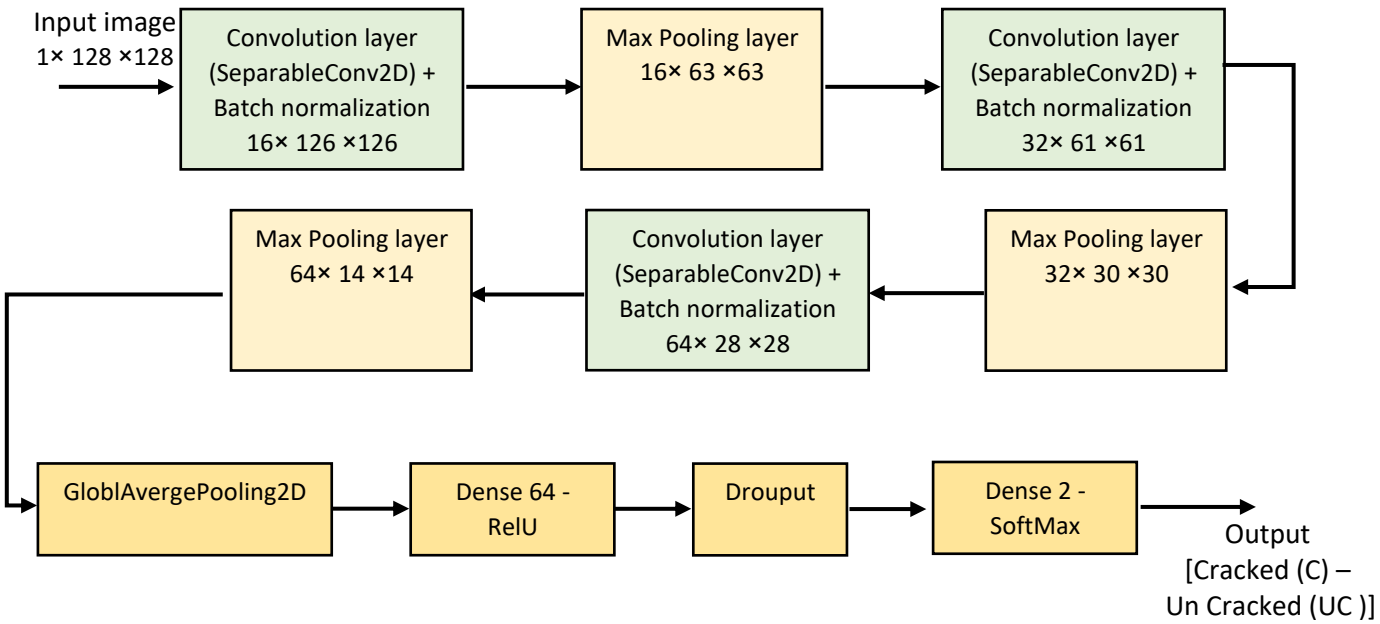
σ: يتحكم في انتقال الفلتر.

2-2-2 بنية الشبكة العصبونية التلافيفية المقترحة CNN

تتكون بنية الشبكة العصبونية المقترحة والموضحة في الشكل (2) من ثلاث طبقات تلافيفية تعتمد على خوازمية Separable Convolution، والتي تتميز بتقليل عدد المعاملات من خلال فصل عملية استخراج القنوات المكانية عن عملية دمج القنوات، وتزيد من كفاءة الحساب بشكل واضح مع الاحتفاظ بالقدرة على التقاط الأنماط الدقيقة. تبدأ الشبكة بعدد صغير من المرشحات (16)، ثم يزداد تدريجيًا إلى (32) ثم (64) كلما تعمقت الشبكة تستخدم هذه الطبقات نواة بحجم 3×3، و1 = stride و valid = padding بهدف استخلاص الميزات الدقيقة مع تقليص تدريجي للخصائص المكانية وإهمال تأثير الحواف غير المهمة في الصورة.

وبعد كل طبقة تلافيفية يتم استخدام طبقة تطبيع الدفعة (Batch Normalization) لتقليل التباين في القيم الناتجة عن الطبقات من أجل تسريع عملية التدريب وتحسن استقرار النموذج، كما تضاف طبقة التجميع (MaxPooling2D)بمرشح 2×2، و2 = stride بعد كل طبقة تلافيفية، بهدف تقليل الأبعاد المكانية حيث تقوم بتقليل حجم البيانات وعدد المعاملات مما ياسعد على تقليل الإفراط في التكيف overfitting واستخراج الميزات الأكثر أهمية في الصورة.

بعد ذلك تستخدم طبقة (Global Average Pooling) والتي تعمل على تحويل كل خريطة ميزات إلى قيمة واحدة تمثل متوسط تنشيطها، مما يعزز تعميم النموذج ويقلل حساسيته تجاه الضوضاء، ثم تمر هذه الميزات عبر طبقة كثيفة تحتوي على 64 عصبونًا مع دالة تنشيط ReLU لتحسن الأداء ومعالجة الميزات عالية المستوى، تليها طبقة Dropout بنسبة 40% للحد من الإفراط في التكيف.



الشكل (2): بنية الشبكة العصبونية التلافيفية المقترحة

2-2-3 تدريب الشبكة العصبونية التلافيفية المقترحة CNN

تم استخدام محسن Adam مع معدل تعلم ابتدائي قدره 0.0001 لتحديث الأوزان في كل خطوة، ولتفادي ثبات الأداء أو تدهوره. كذلك، يتم تعديل معدل التعلم تلقائيًا باستخدام ReduceLROnPlateauعندما لا يتحسن الأداء على بيانات التحقق لفترة معينة، كما تم ضبط النموذج لاستخدام EarlyStopping لإيقاف عملية التدريب تلقائيًا إذا لم

يتم تحسين الأداء بعد عدد محدد من الجلسات، مما يساعد على تجنب الإفراط في التكيّف، تم تدريب الشبكة باستخدام 20000 صورة، 10000 صورة لكل صنف (متصدعة C، غير متصدعة UC) حيث تم تقسيمها إلى ثلاث مجموعات 80% للتدريب و 10% للتحقق و 10% للاختبار، كما تم تدريب البنية من أجل مجموعة البيانات بعد تطبيق عدة عمليات معالجة مسبقة كل على حدى وبشكل مستقل مثل (CLAHE, Gaussian smoothing, Homomorphic filtering) بهدف مقارنة تأثير كل طريقة على قدرة النموذج في تصنيف الصور، واختيار أفضل طريقة معالجة مسبقة تدعم دقة التصنيف.

دربت الشبكة لمدة epochs 10 ومن أجل أربع إدخالات مختلفة، ويوضح الشكل (3) الصور بعد تطبيق عمليات المعالجة عليها:

الإدخال الأول Model A: دربت الشبكة على مجموعة الصور بعد تحويلها إلى تدرجات الرمادي فقط.

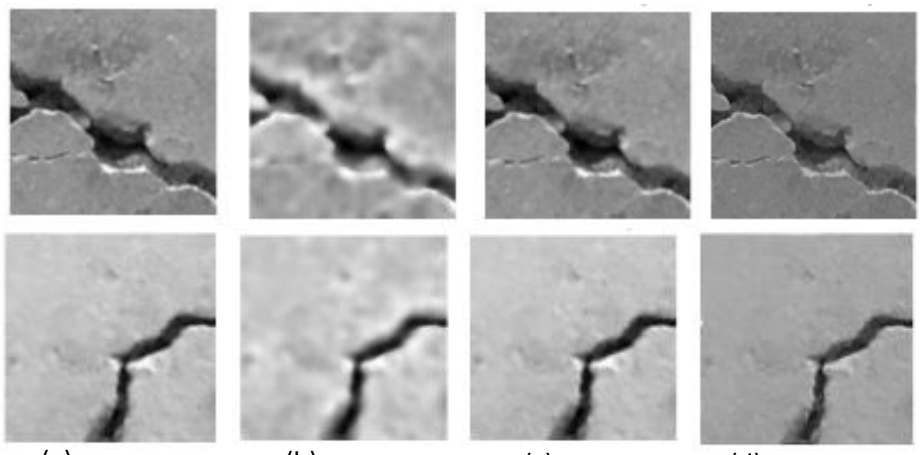
الإدخال الثاني Model B: دربت الشبكة على الصور بعد معالجتها باستخدام Bilateral Filter لقدرته على إزالة الضوضاء مع الحفاظ على الحواف ثم CLAHE بهدف تحسين تباين الصورة، وإبراز التصدعات ومعالجة المناطق غير متجانسة الإضاءة.

الإدخال الثالث Model C: دربت الشبكة على الصور بعد معالجتها باستخدام Gaussian Smoothing الذي يعمل على تخفيف الضجيج أيضاً مع الحفاظ على الحواف ويحافظ على التفاصيل الدقيقة ولا يضيف أية حواف وهمية.

الإدخال الرابع Model D: دربت الشبكة على الصور بعد معالجتها باستخدام Homomorphic Filtering والذي يقوم بإزالة تأثير الإضاءة غير المتجانسة ويحسن التباين من دون أن يولد أي ضجيج إضافي.

3- نتائج البحث ومناقشتها

سنعرض في هذا القسم نتائج التجارب التي أجريت على الشبكة العصبونية الالتفافية المدربة على أربع مجموعات مختلفة من الصور، ستتم دراسة دقة التدريب والتحقق خلال أطوار تدريب مختلفة، بالإضافة إلى مصفوفة الارتباك وأيضاً بارامترات القياس Accuracy وPrecision وRecall وF1-Score من أجل مقارنة النتائج بهدف دراسة تأثير نوع البيانات المدخلة على أداء الشبكة.



الشكل (3): (a) الصور الرمادية، (b) Bilateral + CLAHE، (c) Gaussian Smoothing، (d) Homomorphic

3-1- النتائج

النموذج A: بدأت دقة التدريب من 87.39% ووصلت إلى 97.31% في الطور العاشر، ودقة التحقق وصلت إلى 97.65% وهي قريبة من دقة التدريب، أما دقة الاختبار فبلغت 97.10% من أجل صور تدرجات الرمادي، وكانت قيمة Mean Squared Error (MSE) أو "خطأ التربيع المتوسط" MSE=0.029.

النموذج B: شهد هذا النموذج بداية بدقة تدريب من 91.22% حتى بلغت 96.76% في الطور السابع ودقة التحقق وصلت إلى 94.65% في الطور الثاني، حيث بدأت علامات عدم الاستقرار منذ الطور الثالث بدأت دقة التحقق بالانخفاض على الرغم من استمرار تحسن دقة التدريب، مما يعكس الفجوة بين البيانات التي سببتها المعالجة المسبقة، أي أن النموذج بدأت تنهار قدرته على التعميم، مما يشير إلى عدم الاستقرار، وسجلت دقة الاختبار 95.00% وقيمة MSE=0.05.

النموذج C: أظهر هذا النموذج سلوكاً متوازناً، بدأت دقة التدريب عند 86.52% وترتفع تدريجياً حتى ما يقارب 96.91%، ودقة التحقق وصلت إلى 96.70% وهي قريبة أيضاً من قيم دقة التدريب، ونلاحظ أيضاً أن منحنى التدريب والتحقق يسيران بتوازي تقريباً طوال فترة التدريب، يمثل هذا النموذج أفضل توازن بين التعلم والتدريب، بلغت دقة الاختبار 97.15% و MSE=0.029.

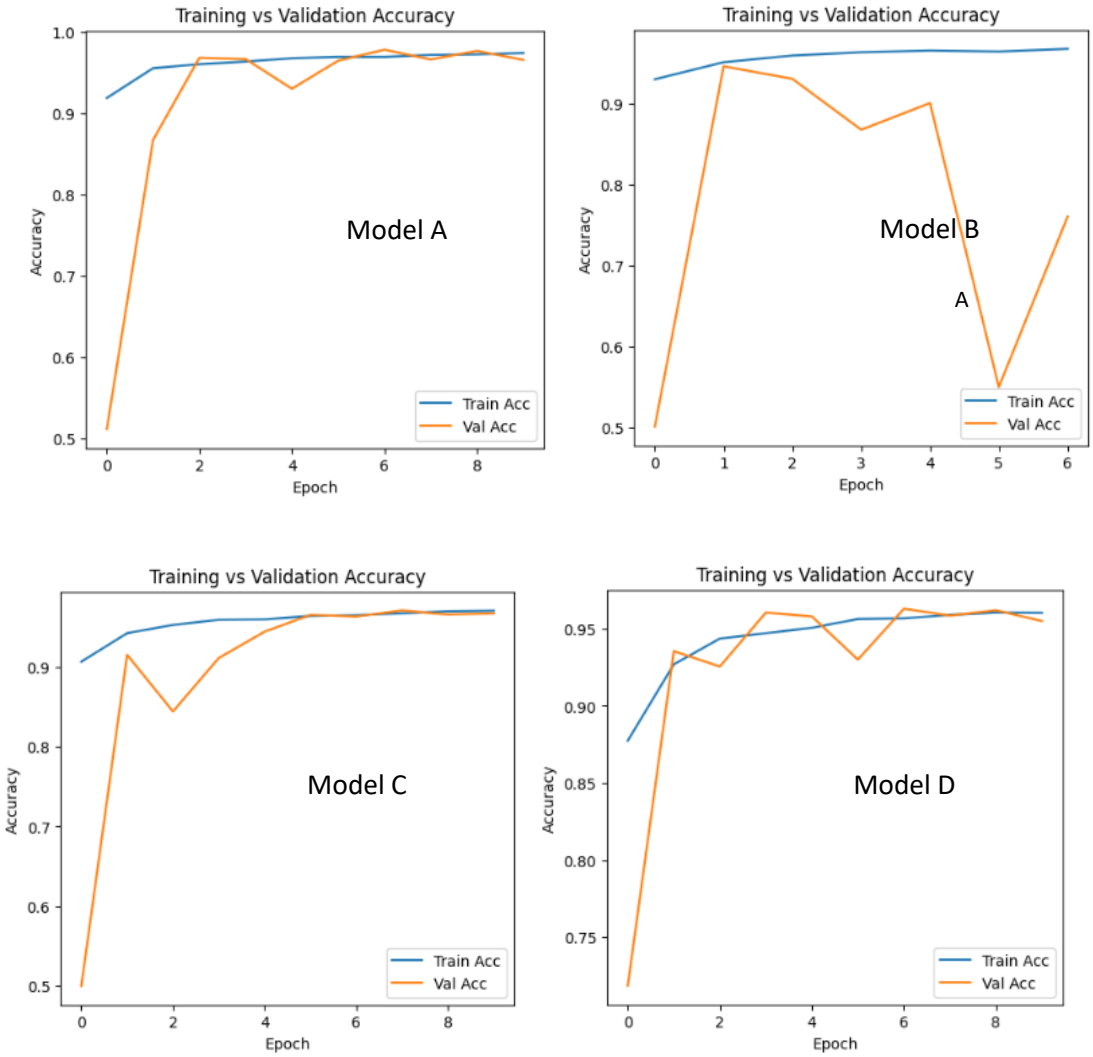
النموذج D: بدأ التدريب بقيمة مرتفعة 82.32% ثم استمر بالتحسن حتى وصلت الدقة إلى 96.06%، كما تراوحت دقة التحقق بين 71.85% في الطور الأول وقفزت بعدها حتى بلغت 95.90% في الطور الأخير، وبقيم قريبة من دقة التدريب، أظهر هذا النموذج بعض التذبذب خلال التدريب لكنه كان أكثر استقراراً من النموذج B وسجلت دقة الاختبار 96.35% و MSE=0.037.

ويوضح الشكل (4) مخططات كل من دقة التدريب والاختبار لكل نموذج من هذه النماذج الأربعة.

وبهذا يتبين لدينا أن النموذج الثالث (C) هو الأكثر استقراراً والأفضل من الناحية العلمية لأنه يزيل الضوضاء ويحافظ على التفاصيل، يليه النموذج الأول (A) وهو قريب جداً من النموذج (C) ولكنه يتذبذب قليلاً خلال التدريب، وهو مناسب في حال كانت الصور أصلاً جيدة الإضاءة ولا تحتاج إلى تعزيز، حيث أنه يحافظ على معلومات الصورة الأصلية.

أما بالنسبة للنموذج الرابع (D) فهو متوسط الاستقرار، ويمكن أن يكون مفيداً في حال وجود مشاكل في إضاءة الصور حيث أنه يضيف تحسيناً في التباين لكنه قد يخفي التفاصيل الضعيفة، ويعتبر النموذج (B) هو الأقل استقراراً لأنه ينتج توزيع بصري غير طبيعي يدمر التوازن بين التدريب والتحقق.

كما يوضح الشكل (5) مصفوفات الارتباك التي تم الحصول عليها بعد اختبار كل من النماذج الأربعة، ويوضح الجدول (1) مقاييس الأداء Accuracy و Precision و Recall و F1 score، للصنفين (C) Cracked و(UC) Uncracked.



الشكل (4): مخططات دقة التدريب والاختبار لكل من النماذج الأربعة

وفقاً لمصفوفات الارتباك ومقاييس الأداء:

أظهر النموذج (A) أداءً مرتفعاً مع دقة بلغت 97.10% مما يشير إلى أن الشبكة تعلما التمييز بين الفئتين بالاعتماد على الصور الخام من دون تعزيز، سجل هذا النموذج 8 إيجابيات خاطئة FP ضمن فئة UC و50 سلبية خاطئة ضمن فئة C.

في النموذج (B) أدى تطبيق Bilateral Filtering ومن ثم CLAHE إلى انخفاض الأداء العام إلى 95%، وهذا الانخفاض يعود إلى طبيعة هذه الفلاتر التي تحافظ على الحواف لكن قد تؤدي إلى تنعيم مبالغ به بما يتعلق بتصدعات الخرسانة كما أن CLAHE يمكن أن يسبب مبالغة في إبراز الأنماط غير المرتبطة بالتصدعات (بسبب طبيعة سطح الخرسانة الخشنة) والذي أنتج 22 إيجابية خاطئة FP و78 سلبية خاطئة FN.

في النموذج (C) حقق تطبيق Gaussian Smoothing أداءً قوياً وبلغت الدقة 97.15% وهي قيمة قريبة جداً من النموذج (A) حيث أن Gaussian أدى إلى إزالة الضوضاء عالية التردد مع الحفاظ على التفاصيل

العامة، وسجل هذا النموذج 29 إيجابية خاطئة FP و78 سلبية خاطئة FN أي أنه لم يتحيز بشكل واضح نحو أي فئة.

أما النموذج (D) حقق أداءً مقبولاً بدقة 96.35% وهو مفيد جداً في حالة الصور ذات الإضاءة المتغيرة، وسجل النموذج 11 إيجابية خاطئة FP وهي قيمة منخفضة نسبياً، لكنه سجل 78 سلبية خاطئة FN وهو ارتفاع ملحوظ في الأخطاء السلبية، أي أنه أصبح يميل لتجاهل التشققات التي تكون ضعيفة الإضاءة أو صغيرة التفاصيل.

Truth predict

	0	1
0	TN	FP
1	FN	TP

Model D

992	8	978	22	971	29	989	11
50	950	78	922	28	972	62	938

الارتباك لكل من النما
الأداء لكل من النماذ
الشكل
الجدول

Model A Model B Model C Model D

Model	Accuracy	Precision$_C$	Recall$_C$	F1 score$_C$	Precision$_{UC}$	Recall$_{UC}$	F1 score$_{UC}$
A	97.10%	99.16%	95.00%	97.04%	95.20%	99.20%	97.16%
B	95.00%	97.67%	92.20%	94.86%	92.61%	97.80%	95.14%
C	97.15%	97.10%	97.20%	97.15%	97.20%	97.10%	97.15%
D	96.35%	98.84%	93.80%	96.25%	94.10%	98.90%	96.44%

3-2- المناقشة والمقارنة مع الدراسات السابقة

تبين نتائج التجارب الأربعة الأثر الواضح لتقنيات المعالجة المسبقة على أداء الشبكة العصبونية وعلى استقرار عملية التدريب وثباتها.

في النموذج الأول (A) والذي يتضمن صور رمادية من دون أي معالجة إضافية، حقق مستوى استقرار عالٍ وأداء قوي من حيث الدقة والقدرة على التمييز بين الفئتين (المتصدعة C وغير المتصدعة UC) مع عدد منخفض من أخطاء التصنيف الإيجابية والسلبية، وبلغت قيمة F1-score 97.04% من أجل الفئة المتصدعة و97.16% من أجل الفئة غير المتصدعة، مما يعكس أن الشبكة استفادت من صور خام لم يطبق عليها أي عملية بمكن أن تؤثر على الخصائص المميزة للتصدعات، إضافة إلى ذلك كان منحني التدريب متزناً ماعدا بعض الذبذبات البسيطة في الأطوار الأولى.

أما النموذج الثاني (B) والذي يتضمن صور معالجة مسبقاً باستخدام Bilateral filter + CLAHE، فقد قدم أداءً منخفضاً بالمقارنة مع بقية النماذج، حيث انخفضت دقة الاختبار وازدادت الخسارة، كما ازدادت التصنيفات الخاطئة ولا سيما السلبيات الخاطئة FN مما يشير إلى أن النموذج أصبح يميل إلى فقدان الشقوق الحقيقية، بالتالي فإن هذه التقنيات المستخدمة أدت إلى خلل في التوازن الطبيعي بين الإضاءة وبنية السطح الخرساني، مما أفقد الشبكة بعض الملومات الدقيقة التي تعتد عليها في التعرف على التصدعات، وبلغت قيمة F1-score 94.86% من أجل الفئة المتصدعة و95.14% من أجل الفئة غير المتصدعة وبالنسبة لمرحلة التدريب فكانت أيضاً غير مستقرة حيث أظهرت المخططات تقلبات كبية في دقة التحقق وانخفاضات مفاجئة بعد الطور الثالث، وهذا يشير إلى فقدان النموذج القدرة على التعلم على الرغم من زيادة دقة التدريب، وبالتالي زيادة خطر الوقوع في مشكلة الإفراط في التعلم overfitting.

وفي النموذج الثالث (C) والذي يتضمن صور معالجة مسبقاً باستخدام Gaussian smoothing، لوحظ أداء قوي مقارب للنموذج الأول (A) من حيث دقة الاختبار، وكانت مصفوفة الارتباك متوازنة بعدد أخطاء محدود بين الفئتين كما وسجلت قيمة F1-score 97.15% من أجل كل من الفئتين المتصدعة وغير المتصدعة، وهذا يعود لكون هذه التقنية تقلل الضجيج العشوائي دون أن تُفقد الحواف الأساسية للتصدعات، وكانت مرحلة التدريب مستقرة إلى حد كبير وبشكل أفضل من النموذج (A) أي أن Gaussian قدم أفضل توازن بين إزالة الضجيج والمحافظة على التفاصيل.

أما النموذج الرابع (D) والذي استخدم صوراً معالجة مسبقاً باستخدام Homomorphic filtering فقط أظهر أداء مقبول وبدقة مقبولة، ولكن أوضحت مصفوفة الارتباك أن النموذج أصبح أكثر تحفظاً تجاه اكتشاف التصدعات، حيث أنه ينتج سلبيات كاذبة بشكل أكبر، وهذا يعود إلى الطبيعة الرياضية للمرشح الذي يفصل مكونات الإضاءة وفي صور الخرسانة، هذا يمكن أن يعزز تفاصيل سطح الخرسانة ويعيد توازن الإضاءة لكنه قد يقلل التباين الحاد بين مناطق التصدع والمناطق السليمة في بعض الحالات، وبلغت قيمة F1-score 96.25% من أجل الفئة المتصدعة و96.44% من أجل الفئة غير المتصدعة، بالنسبة للتدريب في هذا النموذج كان أكثر استقراراً من النموذج (B) لكنه يعاني من بعض الذبذبات طوال مرحلة التدريب.

بمقارنة الدراسة الحالية مع الدراسات السابقة المشابهة من حيث المنهجية، اعتمدت الدراسة (GOLDING et al., 2022) على نموذج VGG16 المدرب مسبقاً، وحققت دقة تتراوح بين 98.85% و99.43 % وخلصت إلى أن الاختلافات بين RGB والتدرج الرمادي بسيطة، أي أنه من الممكن الاعتماد على الصور الرمادية إذ أن اللون ليس مهماً في اكتشاف التصدعات، بينما أدت طريقة التعتيب باستخدام Otsu وكذلك كشف الحواف باستخدام Sobel إلى انخفاض في الأداء بسبب فقدان معلومات مهمة من الصورة.

في المقابل اعتمدت الدراسة الحالية على تدريب نموذج CNN من الصفر دون أي وزن مسبق ومع ذلك تمكنت من تحقيق دقة بلغت 97.15% وقد أظهرت نتائجها أن استخدام التنعيم الغاوسي يوفر توازناً ممتازاً بين إزالة الضوضاء والحفاظ على الحواف الدقيقة للتصدعات، وشهد استقراراً أثناء مرحلة التدريب وبشكل أفضل من استخدام الصور الرمادية بحد ذاتها، كما وتمتاز الشبكة العصبونية المقترحة في هذا البحث بإيجابية مهمة وهي انخفاض كبير في عدد المعاملات، حيث تحتوي على 7,867 معاملاً فقط، وهو ما يضعها ضمن فئة النماذج منخفضة التعقيد مقارنة بالنماذج الثقيلة مثل VGG16 التي تعتمد على أكثر من 138 مليون معامل. ورغم هذا الفارق الهائل في الحجم والقدرة الحسابية، فقد تمكنت الشبكة المقترحة من تحقيق أداء مرتفع ينافس نتائج النماذج المدربة مسبقًا وبزمن تنفيذ أقل، ويوضح الجدول (2) مقارنة هذه الدراسة مع الدراسة السابقة (GOLDING et al., 2022).

الجدول (2) مقارنة الدراسة الحالية مع الدراسات السابقة

	الدراسة الحالية	الدراسة (GOLDING et al., 2022)
الشبكة العصبونية المستخدمة	CNN مدربة من الصفر	VGG16 (كشبكة CNN مدرّبة مسبقًا)
مصدر الأوزان	أوزان VGG16 مدربة على ملايين الصور	يتم تعلمها من البيانات
عدد البارامترات (مستوى	عالي جدًا	منخفض جداً

تعقيد النموذج)	(VGG16 = ~138M parameters)	(CNN = 7867 parameters)
هدف الدراسة	تقييم تأثير 4 طرق IP أساسية على أداء VGG16	تقييم تأثير طرق معالجة متقدمة على نموذج CNN مدرَّب من الصفر
عدد النماذج التي تم تدريبها	أربع نماذج لها نفس البنية من أجل أربع إدخالات مختلفة.	أربع نماذج لها نفس البنية من أجل أربع إدخالات مختلفة.
نوع المعالجة المسبقة المطبقة على البيانات	1. التحويل إلى صور رمادية. 2. Bilateral filter + CLAHE 3. Gaussian smoothing 4. Homomorphic filtering	1. الصور الملونة RGB 2. التحويل إلى صور رمادية. 3. التعتيب بطريقة Otsu 4. كشف الحواف باستخدام Sobel
النتائج التي تم الحصول عليها	حقق التدريب باستخدام الصور الرمادية الأصلية دقة عالية وأداء ممتاز، لكن استخدام Gaussian smoothing أدى إلى استقرار التدريب وحقق أفضل توازن بين الفئتين.	كانت الاختلافات بين RGB والتدرج الرمادي بسيطة، مما يشير إلى أن اللون ليس مهمًا في اكتشاف التشققات.

4- الاستنتاجات والتوصيات

- حقق التدريب باستخدام الصور الرمادية الأصلية دقة عالية وأداء ممتاز، لكنه كان متذبذباً خلال مرحلة التدريب، ويمكن استخدامه إذا كانت الأولوية للدقة النهائية.
- استخدام Gaussian smoothing أدى إلى استقرار التدريب وحقق أفضل توازن بين الفئتين بالإضافة إلى دقة مقاربة لدقة نموذج الصور الرمادية ويمكن استخدامه إذا كانت الأولوية للاستقرار والتعميم على بيانات جديدة.
- التقنيات الخفيفة والبسيطة مثل Gaussian smoothing تحافظ على السمات الهندسية للصدع وبالتالي تحقق أداء أعلى، أما التقنيات الصارمة مثل Bilateral filter + CLAHE و Homomorphic filtering تغير التباين والإضاءة وبالتالي من الممكن أن تسبب إرباكاً للشبكة أو فقدان للميزات الهامة خصوصاً عند التعامل مع صور معقدة مثل سطح الخرسانة.
- في صور الخرسانة التقنيات التي تغير شكل الحافة والتباين المحلي للصورة أو الضوضاء الطبيعية تؤثر سلباً على نموذج التعلم.
- العامل الأهم عند الرغبة في تطبيق تقنيات معالجة مسبقة على صور مثل صور التصدعات الخرسانية هو الحفاظ على خصائص الصدع نفسه.

يمكن المتابعة في البحث من خلال:

- تحليل عينات الخطأ (False Positives) و(False Negatives) لتحديد الأسباب الأكثر شيوعاً لسوء التصنيف، واقتراح تحسينات في خطوات المعالجة المسبقة أو في بنية النموذج استناداً إليها.
- إجراء تجارب إضافية بزيادة حجم البيانات وتنوعها، من خلال جمع صور جديدة في ظروف إضاءة وزوايا تصوير مختلفة، بما يعزز من قدرة النموذج على التعميم ويقلل من حساسيته لظروف الالتقاط.
- تطبيق استراتيجيات تحسين إضافية للبيانات (Data Augmentation) كالتدوير، والتحجيم، وتعديل التباين، وإضافة الضوضاء، وذلك لزيادة تنوع العينات الاصطناعي وتحسين ثبات النموذج.
- تجريب نماذج أعمق أو مسبقة التدريب (Transfer Learning) مثل ResNet أو EfficientNet للاستفادة من الخصائص المُتعلَّمة مسبقاً وتحسين التمثيل البصري للتصدعات الدقيقة.

5- المراجع

1- ADAM, E. E. B; SATHESH, A. 2021, *Construction of accurate crack identification on concrete structure using hybrid deep learning approach*. Journal of Innovative Image Processing (JIIP), Vol.3, No.2, 85-99.
2- ASKAR, M. K; AL-KAMAKI, Y. A. M. A. N; FERHADI, R; MAJEED, H. K. 2023, *Cracks in concrete structures causes and treatments: A review*. Journal of Duhok University, Vol.26, No.2, 148-165.
3- BANIMUSTAFA, A; ABDELHALIM, R; BULKROCK, O; AL-HMOUZ, A. 2023, *Deep Learning for Assessing Severity of Cracks in Concrete Structures*. International Journal of Computers, Communications & Control, Vol.18, No.1.
4- BHOWMICK, S; NAGARAJAIAH, S; VEERARAGHAVAN, A. 2020, *Vision and deep learning-based algorithms to detect and quantify cracks on concrete surfaces from UAV videos*. Sensors, Vol.20, No.21, 6299.
5- CHAVARÍN, Á; CUEVAS, E; AVALOS, O; GÁLVEZ, J; PEREZ-CISNEROS, M. 2023, *Contrast enhancement in images by homomorphic filtering and cluster-chaotic optimization*. IEEE Access, Vol.11, 73803-73822.
6- FLAH, M; SULEIMAN, A. R; NEHDI, M. L. 2020, *Classification and quantification of cracks in concrete structures using deep learning image-based techniques*. Cement and Concrete Composites, Vol.114, 103781.
7- GOLDING, V. P; GHARINEIAT, Z; MUNAWAR, H. S; ULLAH, F. 2022, *Crack detection in concrete structures using Deep Learning*. Sustainability, Vol.14, No.13, 8117.
8- LE, T. T; NGUYEN, V. H; LE, M. V. 2021, *Development of deep learning model for the recognition of cracks on concrete surfaces*. Applied Computational Intelligence and Soft Computing, 2021, 1-10.
9- MUSA, P; AL RAFI, F; LAMSANI, M. 2018, *A Review: Contrast-Limited Adaptive Histogram Equalization (CLAHE) methods to help the application of face recognition*. Proceedings of the 2018 Third International Conference on Informatics and Computing (ICIC), IEEE, 1-6.
10- RICHARDS, J. 2003, *Gaussian smoothing*. Handbook of Image Processing and Computer Vision. Retrieved March 20, 2026, from https://homepages.inf.ed.ac.uk/rbf/HIPR2/gsmooth.html
11- TOMASI, C; MANDUCHI, R. 1998, *Bilateral filtering for gray and color images*. Proceedings of the Sixth International Conference on Computer Vision, IEEE, 839-846.
12- WOLFRAM RESEARCH. 2010, *BilateralFilter* — Wolfram Language function reference. Retrieved March 20, 2026, from https://reference.wolfram.com/language/ref/BilateralFilter.html