

تصوير كهروضوئي عالي الدقة معزز بالذكاء الاصطناعي للكشف المبكر عن عيوب التلامس داخل الخلايا الشمسية

سالمه الصادق سالم بودية¹ , امينة علي سالم المعيوف² , صلاح الدين الطاهر البكوش³

كلية صرمان للعلوم والتقنية _ القسم العام^{1,2,3}

SalmaSadeq@scst.edu.ly¹ , aminaali71114@gmail.com² , Sartmar@scst.edu.ly³

الملخص

يهدف هذا البحث إلى تطوير نظام ذكي قائم على الذكاء الاصطناعي للكشف المبكر عن العيوب في الخلايا الشمسية باستخدام تقنيات التصوير الكهروضوئي عالية الدقة. تم تصميم منهجية متكاملة تجمع بين معالجة الصور الرقمية وخوارزميات التعلم العميق، خصوصاً الشبكات العصبية الالتفافية (CNN)، لتحليل الصور واستخراج الأنماط الدالة على العيوب الداخلية والخارجية في الخلايا. اعتمد النظام المقترح على قاعدة بيانات متنوعة تضم صوراً لخلايا سليمة وأخرى متضررة، جرى تدريب النموذج عليها بعد إجراء عمليات تحسين وتطبيق للصور لرفع دقة التنبؤ.

أظهرت النتائج التجريبية أن النموذج حقق دقة كشف بلغت (96.4–97.8%) مع حساسية بلغت 96.5% ودقة تمييز (Precision) وصلت إلى 98.2%، مما يؤكد كفاءته في التمييز بين أنواع العيوب المختلفة مثل التشققات الدقيقة، والانقطاعات، ومناطق الانعكاس غير المتجانسة. تُظهر النتائج إمكان تطبيق النظام المقترح كمنصة ذكية في فحص الخلايا الشمسية على نطاق صناعي. كما أظهر تحليل منحنى ROC أن النظام يتمتع بثبات عالٍ في الأداء عبر عينات اختبار لم تُستخدم في مرحلة التدريب.

توفر الخرائط الحرارية الناتجة عن النموذج وسيلة بصرية دقيقة لتحديد مواقع العيوب داخل الخلايا، مما يساهم في تسريع عمليات الفحص وتقليل الأخطاء البشرية بنسبة تزيد عن 80% مقارنة بالطرق التقليدية مثل التصوير بالأشعة تحت الحمراء. ويُظهر النظام إمكانية دمجها في خطوط الإنتاج الصناعية لتحقيق فحص فوري وغير تدميري للخلايا الشمسية.

تُبرز هذه الدراسة الإمكانيات الكبيرة للذكاء الاصطناعي في تحسين موثوقية وجودة الفحص البصري في الصناعات الكهروضوئية، وتمثل خطوة نحو تطوير أنظمة مراقبة ذاتية قادرة على دعم التحول الذكي في مجال الطاقة الشمسية المستدامة.

Submitted: 02/11/2025

Accepted: 22/11/2025

الكلمات المفتاحية: التصوير الكهروضوئي، الذكاء الاصطناعي، العيوب في الخلايا الشمسية، الشبكات العصبية الالتفافية (CNN)، تحليل الصور، الكشف المبكر، معالجة الصور الرقمية، الطاقة الشمسية، الفحص غير التدميري، الخرائط الحرارية.

Abstract

This study aims to develop an intelligent system based on artificial intelligence for the early detection of defects in solar cells using high resolution photovoltaic imaging techniques. An integrated methodology was designed that combines digital image processing with deep learning algorithms particularly Convolutional Neural Networks (CNNs) to analyze images and extract patterns indicative of internal and external cell defects. The proposed system relied on a diverse database containing images of both healthy and defective cells. The model was trained on this dataset after applying enhancement and normalization procedures to improve prediction accuracy.

Experimental results showed that the model achieved a detection accuracy ranging between 96.4% and 97.8%, with a sensitivity of 96.5% and a precision of 98.2%, confirming its efficiency in distinguishing between different types of defects such as micro-cracks, interruptions, and non-uniform reflection areas. The results indicate that the proposed system can be deployed as an intelligent platform for industrial-scale solar cell inspection. Moreover, the ROC curve analysis demonstrated high performance stability across test samples not used during training.

The heatmaps generated by the model provide an accurate visual tool for locating defects within the cells, helping accelerate inspection processes and reduce human errors by more than 80% compared to traditional methods such as infrared imaging. The system also shows strong potential for integration into industrial production lines to enable real-time and non-destructive solar cell inspection.

This study highlights the significant potential of artificial intelligence to enhance the reliability and quality of visual inspection in photovoltaic industries and represents a step toward developing autonomous monitoring systems capable of supporting smart transformation in the field of sustainable solar energy.

Keywords: Photovoltaic imaging, artificial intelligence, solar cell defects, convolutional neural networks (CNN), image analysis, early detection, digital image processing, solar energy, non-destructive inspection, heatmaps.

المقدمة (Introduction)

شهد العقد الأخير تطوراً هائلاً في تقنيات الطاقة الشمسية نتيجة التوجه العالمي نحو مصادر الطاقة النظيفة والمستدامة. ومع توسع تطبيقات الخلايا الشمسية السيليكونية في الأنظمة الكهروضوئية، أصبحت الحاجة إلى ضمان الكفاءة التشغيلية والاستدامة العالية أمراً جوهرياً، لا سيما في ظل التحديات المرتبطة بعيوب التلامس الميكروية التي تؤثر سلباً على الأداء الكهروضوئي للخلايا (Menon et al., 2025). وتعدّ هذه العيوب من أكثر المسببات خفاءً لصعوبات التوصيل الداخلي وانخفاض الكفاءة الكمية الضوئية، ما يستدعي تطوير تقنيات تصوير وتحليل أكثر دقة قادرة على رصدّها مبكراً قبل أن تتفاقم الخسائر في الطاقة.

تواكب التطورات في مجالات التصوير المجهرية والتقنيات الكهروضوئية ظهور أدوات تحليل جديدة مثل المجهر الإلكتروني بالتركيز الأيوني (FIB-SEM) الذي يوفر تصويراً متعدد النطاقات للمواد النانوية والسطوح الدقيقة (Liu et al., 2025). وقد ساهم هذا النوع من التصوير، إلى جانب التطورات في تقنيات الطلاء النانوي ثنائي الأبعاد (Liu, 2024)، في تحسين القدرة على تحليل البنية البلورية والمناطق الانتقالية داخل الخلايا الشمسية، ما أتاح للباحثين فرصة أكبر لفهم العلاقات بين البنية المجهرية والأداء الكهروضوئي الفعلي.

في السياق ذاته، برزت المواد النانوية والهياكل الهجينة كحلول مبتكرة لتحسين الكفاءة الضوئية وتوسيع نطاق الكشف الطيفي، كما أوضح Machín & Márquez (2025) في مراجعتهم حول الجيل القادم من الحساسات الكيميائية القائمة على تقارب المواد النانوية مع أنظمة المعالجة الذكية. ومن هذا المنطلق، أصبح التكامل بين الذكاء الاصطناعي والأنظمة الكهروضوئية عنصراً حاسماً في تطوير أنظمة تصوير قادرة على معالجة البيانات المعقدة متعددة الأطياف وتحليلها في الزمن الحقيقي (Srivastav & Das, 2025).

تُظهر التطبيقات الحديثة أن أنظمة المراقبة المدمجة بالذكاء الاصطناعي أصبحت قادرة على تنفيذ عمليات تقييم آلي في بيئات معقدة، مثل الأنظمة الحرارية والجيولوجية المتعددة الطبقات (Serroune et al., 2025). هذه القدرات تمثل الأساس لمفهوم “المراقبة الذكية” القابلة للتطبيق في مجالات أخرى كتحليل العيوب الكهروضوئية في الخلايا الشمسية. وقد أظهرت دراسات


حديثاً أن الذكاء الاصطناعي يمكنه تحسين عمليات المعايرة الضوئية والتنبؤ بالعيوب عبر نماذج الشبكات العصبية التلافيفية (CNNs) التي تمتاز بقدرتها العالية على استخلاص الأنماط من الصور المعقدة (Mousazadehgavan et al., 2025).

على المستوى التقني، ساهمت التطورات في أدوات التصوير الذري مثل المجهر القوة الذرية (AFM) في تعزيز فهم السلوك السطحي للمواد الكهروضوئية على المستوى النانوي، ما أتاح إمكانيات جديدة في تحليل مناطق التلامس وتحديد مواقع الخلل بدقة متناهية (Joo et al., 2025). كما أسهمت تقنيات التوصيف الكهروضوئي النانوي في تحسين فهم توزيع الشحنات والإشعاع داخل البنى البلورية، وهو ما ينسجم مع الأهداف الحالية لتطوير تصوير كهروضوئي عالي الدقة (Monsalve García, 2025).

في المقابل، يشير Lin et al. (2024) إلى أن الجمع بين تقنيات التوصيف الكهروضوئي والتحليل المعزز بخوارزميات التعلم العميق يفتح آفاقاً جديدة لتصنيف السوائل والأنظمة الضوئية وفق خصائصها الكهربائية الدقيقة. هذا الدمج بين البيانات الفيزيائية والتعلم الآلي يقدم نموذجاً قابلاً للتطبيق في كشف العيوب داخل الخلايا الشمسية عبر معالجة إشارات الإضاءة المنعكسة أو المنبعثة.

وتجدر الإشارة إلى أن الدراسات الحديثة حول المواد النانوية مثل $Ag-Ag_2S$ أظهرت قدرة عالية في تحويل الإشعاع الضوئي إلى حرارة أو إشارات كهربائية دقيقة، مما يجعلها ذات أهمية خاصة في تطوير حساسات كهروضوئية ذات استجابة فائقة للعيوب الدقيقة (Zang et al., 2023). كما أن التحسينات الحديثة في تقنيات الفسفرة عند درجة الحرارة العادية باستخدام النقاط الكربونية الكمية (Carbon Quantum Dots) ساهمت في رفع كفاءة النماذج الذكية في استخلاص السمات اللونية والحرارية من الصور الكهروضوئية، وهو ما أبرزه Wang et al. (2025) في دراستهم حول تطبيق النقاط الكمية الحيوية في الشبكات العصبية الالتفافية.

من خلال هذا الإطار البحثي، يهدف هذا العمل إلى تطوير نظام تصوير كهروضوئي عالي الدقة مدعوم بخوارزمية ذكاء اصطناعي قادرة على الكشف المبكر عن عيوب التلامس داخل الخلايا الشمسية السيليكونية. يعتمد النظام المقترح على الدمج بين تحليل الإشعاع الكهروضوئي وتقنيات التعلم العميق لاستخلاص خرائط حرارية توضح مواقع العيوب المجهرية بدقة عالية. يمثل هذا النهج خطوة متقدمة نحو تحقيق مراقبة آلية وشبه فورية لجودة الخلايا الشمسية ضمن خطوط الإنتاج الصناعية، بما يعزز كفاءة الطاقة ويقلل الفاقد التشغيلي في الأنظمة الكهروضوئية الحديثة. يوضح الشكل (1) الإطار المفاهيمي العام للنظام الكهروضوئي المعزز بالذكاء الاصطناعي المقترح، والذي يربط بين المكونات المادية ووحدة المعالجة الحسابية بهدف الكشف المبكر عن العيوب في مناطق التلامس داخل الخلايا الشمسية.



الشكل (1). الإطار المفاهيمي للنظام الكهروضوئي المعزز بالذكاء الاصطناعي.

رسم تخطيطي يوضح التسلسل التشغيلي للنظام المقترح، حيث يقوم مصدر الضوء بإثارة المستشعر الكهروضوئي النانوي ($Ag-Ag_2S$)، ثم تنتقل الإشارات الملتقطة إلى وحدة معالجة الإشارات لتحويلها إلى بيانات رقمية. بعد ذلك، يتم تحليل البيانات باستخدام خوارزمية التعلم العميق (CNN) لتوليد خريطة حرارية تحدد مناطق العيوب المحتملة داخل بنية الخلية الشمسية.

منهجية البحث (Methodology)

• تصميم الدراسة (Study Design)

اعتمد هذا البحث على تصميم تجريبي تحليلي (Experimental-Analytical Study) يجمع بين الجانب العملي والتطبيقي للتحقق من فعالية نظام التصوير الكهروضوئي المقترح. يهدف التصميم إلى تطوير منظومة تصوير كهروضوئي عالي الدقة مدعوم بخوارزمية ذكاء اصطناعي متقدمة للكشف المبكر عن العيوب المجهرية في مناطق التلامس داخل الخلايا الشمسية السيليكونية. تم تنفيذ الدراسة على أربع مراحل رئيسية مترابطة. المرحلة الأولى تضمنت تصميم وتطوير نظام تصوير كهروضوئي يعتمد على مبدأ الانبعاث الضوئي تحت تحفيز كهربائي محدود الجهد مع التحكم في شدة الإضاءة من خلال مصدر ضوء ليزري قابل للضبط بمدى طيفي يتراوح بين 450–850 نانومتر. المرحلة الثانية ركزت على جمع البيانات التصويرية وتحليلها، حيث تم التقاط ما يقارب 1200 صورة كهروضوئية لعشرين عينة من خلايا شمسية أحادية البلورة تحت ظروف تشغيل مختلفة تضمنت ثلاث مستويات من الإضاءة (منخفضة 30%، متوسطة 60%، وعالية 100%) بهدف تقييم استجابة الخلية للضوء في مناطق التلامس المعدنية. أما المرحلة الثالثة فتمثلت في تدريب نموذج ذكاء اصطناعي يعتمد على الشبكات العصبية الالتفافية (CNN) باستخدام 70% من الصور كبيانات تدريب، و20% للاختبار، و10% للتحقق الداخلي، مع تطبيق تقنيات تعزيز البيانات (Data Augmentation) لتحسين الأداء العام للنموذج. وفي المرحلة الرابعة والأخيرة تم إجراء عملية التحقق (Validation) لمقارنة كفاءة النموذج المقترح مع نتائج تقنيات الكشف التقليدية، حيث تم تقييم الدقة باستخدام مؤشرات الأداء الإحصائية مثل الحساسية (Sensitivity) والنوعية (Specificity) والدقة الكلية (Accuracy).

• المواد والمعدات (Materials and Equipment)

تم تنفيذ التجارب باستخدام عينات مختارة من خلايا شمسية أحادية البلورة (Monocrystalline Silicon Solar Cells) بقدر اسمية تبلغ 5 واط ومساحة سطح فعالة تساوي 25 سم²، مأخوذة من ثلاث دفعات إنتاجية مختلفة لتمثيل التباين التصنيعي الطبيعي. تم تجهيز نظام تصوير كهروضوئي متكامل يتكون من مصدر ضوء ليزري قابل للتحكم في الشدة يتراوح بين 0.5 و 2.0 واط/سم²، وكاميرا كهروضوئية عالية الحساسية بدقة 4096×4096 بكسل ذات استجابة طيفية تغطي المدى بين 400–1100 نانومتر، بالإضافة إلى مجموعة من المرشحات الضوئية (Optical Filters) لضبط الأطوال الموجية المرغوبة أثناء عملية التصوير. استخدم حاسوب مزود بمعالج رسومي (GPU) من نوع NVIDIA RTX 4090 بسعة 24 جيجابايت لتدريب خوارزميات الذكاء الاصطناعي ومعالجة الصور عالية الدقة، بينما تم الاعتماد على بيئة برمجية متعددة الأدوات شملت MATLAB 2024b للتحليل الصور الأولي، و Python 3.11 مع مكتبات TensorFlow و OpenCV لتصميم وتدريب النموذج الذكي. تم التحكم في ظروف التجربة باستخدام منصة اختبار حراري تحافظ على درجة حرارة ثابتة قدرها 25±1°C لتجنب أي تأثير حراري على الانبعاث الكهروضوئي.

ولتحقيق وضوح منهجي في تنظيم الأدوات والمكونات التجريبية، يوضح الجدول (1) التوزيع التفصيلي للمواد والمعدات المستخدمة في الدراسة.

المكونات التجريبية لنظام التصوير الكهروضوئي المقترح	المواصفات التقنية
نوع الخلايا الشمسية	خلايا سيليكونية أحادية البلورة بقدر 5 واط ومساحة 25 سم ²
مصدر الإضاءة	ليزر قابل للتحكم بالشدة (2.0–0.5 واط/سم ²)
الكاميرا الكهروضوئية	دقة 4096×4096 بكسل، مدى طيفي 400–1100 نانومتر
المرشحات البصرية	مرشحات Band-pass بطول موجي 450–850 نانومتر
وحدة التحكم الحراري	منصة حرارية بدرجة ثابتة 25±1°C
وحدة معالجة البيانات	معالج رسومي NVIDIA RTX 4090 – 24 GB GPU
البرمجيات المستخدمة	OpenCV، TensorFlow، Python 3.11، MATLAB 2024b

• جمع البيانات (Data Acquisition)

تم تنفيذ عملية جمع البيانات الكهروضوئية بطريقة منهجية دقيقة لضمان الحصول على صور عالية الجودة تمكّن من الكشف المبكر عن العيوب المجهرية داخل مناطق التلامس في الخلايا الشمسية. جرى التقاط الصور باستخدام نظام التصوير الكهروضوئي المطوّر تحت حالتين تشغيليتين أساسيتين: الحالة الأولى أثناء التشغيل المتصل بالتيار (Forward Bias) عند جهد يتراوح بين 0.4 و 0.6 فولت، والحالة الثانية أثناء الوضع غير المتصل بالتيار (Reverse Bias) عند جهد قدره -0.2 فولت. تم تكرار عملية التصوير لكل عينة عشر مرات لضمان الاتساق الإحصائي للبيانات وتقليل الخطأ العشوائي الناتج عن التغيرات البيئية أو الانحرافات البصرية.

بلغ عدد الصور الملتقطة الإجمالي 1200 صورة تمثل بيانات لعدد 20 خلية شمسية مختلفة، حيث صُوّرت كل خلية تحت ثلاث مستويات من شدة الإضاءة بلغت 30%، 60%، و 100% من القدرة الإشعاعية الكاملة لمصدر الضوء الليزري المستخدم. تم تسجيل المعلومات الفيزيائية المصاحبة لكل عملية تصوير، بما في ذلك درجة الحرارة ($25 \pm 1^\circ\text{C}$)، الجهد المطبق (V)، التيار الناتج (I)، وكثافة الإضاءة (W/cm^2)، وذلك باستخدام نظام مراقبة رقمي متكامل يربط الكاميرا ومصدر الإضاءة ووحدة القياس الحرارية.

جميع الصور تم حفظها بتنسيق RAW غير مضغوط للحفاظ على التفاصيل الميكروسكوبية الدقيقة للانبعاث الكهروضوئي، مع تضمين بيانات التعريف (Metadata) الخاصة بكل عينة لضمان إمكانية التتبع والتحقق لاحقاً أثناء عملية التحليل. كما تم توثيق العينات من خلال تصنيفها إلى مجموعتين رئيسيتين: العينات المثالية ذات الأداء الكهربائي المستقر، والعينات المتضررة التي أظهرت انخفاضاً في كفاءة التحويل يزيد عن 10% نتيجة وجود عيوب سطحية أو تلامسية. هذا التصنيف أتاح إنشاء قاعدة بيانات مرجعية لتدريب خوارزميات الذكاء الاصطناعي على التمييز بين الخلايا السليمة وتلك التي تحتوي على عيوب خفية غير مرئية بالطرق التقليدية.

ولأغراض التوضيح، يبيّن الجدول (2) خصائص مجموعة البيانات التي تم جمعها وعدد العينات تحت كل حالة تجريبية.

القيمة / العدد	خصائص مجموعة البيانات الكهروضوئية المجمعة للتدريب والتحليل
20 خلية شمسية أحادية البلورة	عدد العينات الكلية
1200 صورة كهروضوئية	عدد الصور الإجمالي
100% - 60% - 30% من القدرة القصوى	مستويات شدة الإضاءة
-0.2، 0.4، 0.6 فولت	الجهود المستخدمة
$25 \pm 1^\circ\text{C}$	درجة الحرارة أثناء التصوير
RAW غير مضغوط	تنسيق الصور
مثالية (10 خلايا) / متضررة (10 خلايا)	تصنيف العينات

• معالجة البيانات (Data Preprocessing)

قبل البدء في تدريب نموذج الذكاء الاصطناعي، خضعت جميع الصور الكهروضوئية الملتقطة لعمليات معالجة رقمية دقيقة تهدف إلى إزالة الضوضاء وتحسين جودة البيانات البصرية دون التأثير على خصائص الانبعاث الأصلية. تم في البداية تطبيق مرشحات Gaussian ذات انحراف معياري مقداره $\sigma = 1.5$ ومرشحات Median بحجم نافذة 3×3 بكسل لتقليل الضوضاء الناتجة عن الاهتزازات الميكانيكية أو التقلبات الضوئية أثناء عملية التصوير. هذه الخطوة ساعدت على تعزيز نقاء الإشارات الضوئية وتحديد الأنماط المكانية للانبعاث بشكل أكثر دقة.

عقب ذلك، جرى تحسين التباين البصري والحدة باستخدام خوارزميات ضبط التدرج الديناميكي (Dynamic Range Adjustment) وتقنية (CLAHE – Contrast Limited Adaptive Histogram Equalization) لتكبير الفروق بين مناطق التلامس المعدنية والأسطح شبه الموصلية المحيطة بها. بلغت نسبة التحسن في متوسط التباين العام للصور حوالي 28% مقارنة بالصور الأصلية، وفقاً لمؤشر PSNR الذي ارتفع من 31.2 dB إلى 39.8 dB بعد المعالجة.

في الخطوة التالية، تم تنفيذ عملية التقسيم (Segmentation) لاستخراج مناطق التلامس المعدنية بشكل دقيق من خلفية الخلية. استخدمت خوارزمية Otsu Thresholding كأساس أولي للفصل، تلتها خوارزمية Morphological Opening لإزالة العناصر الصغيرة غير المرغوبة. أتاح هذا الإجراء إنشاء حدود واضحة لمناطق التوصيل الكهربائي التي تُعد الأكثر عرضة للعيوب المجهرية.

بعد الانتهاء من مرحلة التقسيم، جرى رسم البيانات يدوياً (Manual Defect Labeling) لتحديد مواقع وأنواع العيوب في العينات المختلفة، مثل الشقوق الشعرية الدقيقة، والانقطاعات الجزئية في طبقة التوصيل، أو البقع ذات الانبعاث غير المنتظم. تم تنفيذ عملية الوسم باستخدام برنامج LabelImg في بيئة Python، واستغرق إعداد قاعدة البيانات الموسومة حوالي 42 ساعة عمل موزعة على ثلاث باحثين لضمان دقة التصنيف وجودة البيانات التدريبية. بلغ إجمالي عدد الصور الموسومة 1200 صورة، واحتوت كل صورة في المتوسط على ما بين عييبين إلى خمسة عيوب موثقة، مما شكّل قاعدة بيانات غنية ومتنوعة لتدريب خوارزميات الشبكة العصبية الالتفافية لاحقاً.

يوضح الجدول (3) الإجراءات الأساسية المتبعة في معالجة البيانات والمعايير المستخدمة في كل خطوة.

مراحل معالجة البيانات الكهروضوئية قبل التدريب	الإعدادات والمعايير التقنية
ترشيح الضوضاء	Gaussian Filter ($\sigma=1.5$) + Median Filter (3×3)
تحسين التباين	CLAHE – نسبة تحسين 28 (PSNR) من 31.2 إلى 39.8 dB
تقسيم الصور	Otsu Thresholding + Morphological Opening
أداة الوسم	LabelImg (Python Environment)
عدد الصور الموسومة	1200 صورة (2–5 عيوب في كل صورة)
زمن إعداد قاعدة البيانات	42 ساعة / 3 باحثين

• تطوير نموذج الذكاء الاصطناعي (AI Model Development)

تم بناء نموذج الذكاء الاصطناعي المعتمد في هذا البحث على بنية الشبكات العصبية الالتفافية (Convolutional Neural Network – CNN) نظراً لقدرتها العالية على تحليل الصور ثنائية الأبعاد واستخراج الأنماط الدقيقة المرتبطة بالعيوب المجهرية في الخلايا الشمسية. صُمم النموذج ليعمل على تصنيف مناطق التلامس المعدنية داخل الصور الكهروضوئية إلى منطقتين رئيسيتين: مناطق سليمة وأخرى تحتوي على عيوب مجهرية، مع توليد خرائط حرارية (Defect Heatmaps) توضح شدة احتمالية وجود الخلل في كل جزء من الخلية.

جرى تقسيم قاعدة البيانات المكونة من 1200 صورة إلى ثلاث مجموعات أساسية: مجموعة التدريب بنسبة 840 (70% صورة)، مجموعة الاختبار بنسبة 240 (20% صورة)، ومجموعة التحقق الداخلي بنسبة 120 (10% صورة). ولزيادة تنوع البيانات وتحسين قدرة النموذج على التعميم، تم استخدام تقنيات تعزيز البيانات (Data Augmentation) التي شملت تدوير الصور بزوايا تتراوح بين 0° و 180°، وانعكاسها الأفقي والعمودي، بالإضافة إلى تعديل الإضاءة والسطوع بنسبة ±15%، مما أدى إلى زيادة حجم البيانات الفعلي إلى ما يقارب 4800 صورة تدريبية مكافئة.

اعتمد التدريب على خوارزمية التحسين Adam Optimizer بمعامل تعلم ابتدائي مقداره 0.0001 ، بينما تم استخدام دالة الخسارة Binary Cross-Entropy لقياس الفروق بين المخرجات الفعلية والمتوقعة، مع تطبيق دالة التنشيط ReLU في الطبقات الالتفافية و Sigmoid في الطبقة النهائية لتصنيف العيوب. استغرق تدريب النموذج 50 دورة (Epochs) بمتوسط زمن تنفيذ 38 ثانية لكل دورة على معالج رسومي من نوع NVIDIA RTX 4090 ، وتم استخدام حجم دفعة (Batch Size) يساوي 32 صورة لتحقيق توازن بين سرعة التدريب واستقرار الأداء.

تم تقييم النموذج بشكل دوري بعد كل خمس دورات تدريبية، وجرى اعتماد المعايير الإحصائية Accuracy و Precision و Recall و F1-score لقياس كفاءته في اكتشاف العيوب. أظهرت النتائج المبدئية أن النموذج المقترح حقق دقة تصنيف بلغت 96.4% في مجموعة الاختبار، مع حساسية (Recall) قدرها 94.8% ودقة نوعية (Specificity) وصلت إلى 97.1% ، مما يشير إلى كفاءة عالية في التمييز بين الخلايا السليمة والمتضررة.

يبين الجدول (4) البنية التفصيلية للشبكة العصبية الالتفافية المستخدمة في هذا البحث والمعايير المطبقة في كل طبقة من طبقاتها.

الوصف والمعايير التقنية	الهيكل المعماري للشبكة العصبية الالتفافية المستخدمة في الدراسة
Convolutional Neural Network (CNN)	نوع النموذج
12 طبقة (4 الالتفافية ، 4 تجميع ، 3 كاملة الاتصال ، 1 إخراج)	عدد الطبقات الكلية
3×3 بكسل	حجم الفلاتر الالتفافية
ReLU في الطبقات الالتفافية Sigmoid / في طبقة الإخراج	دالة التنشيط
Binary Cross-Entropy	دالة الخسارة
Adam Optimizer (Learning Rate = 0.0001)	خوارزمية التحسين
32 صورة لكل دورة تدريبية	حجم الدفعة
50 Epochs	عدد الدورات التدريبية
حوالي 31.6 دقيقة	زمن التدريب الإجمالي
خريطة حرارية (Defect Heatmap) لتحديد مناطق العيوب	ناتج النموذج

• النتائج (Results)

يُوضّح الشكل (2) الخصائص التركيبية والفيزيائية للمواد النانوية المستخدمة في هذا البحث، والتي تم تحليلها باستخدام تقنيات المجهر الإلكتروني والنمذجة الطيفية.

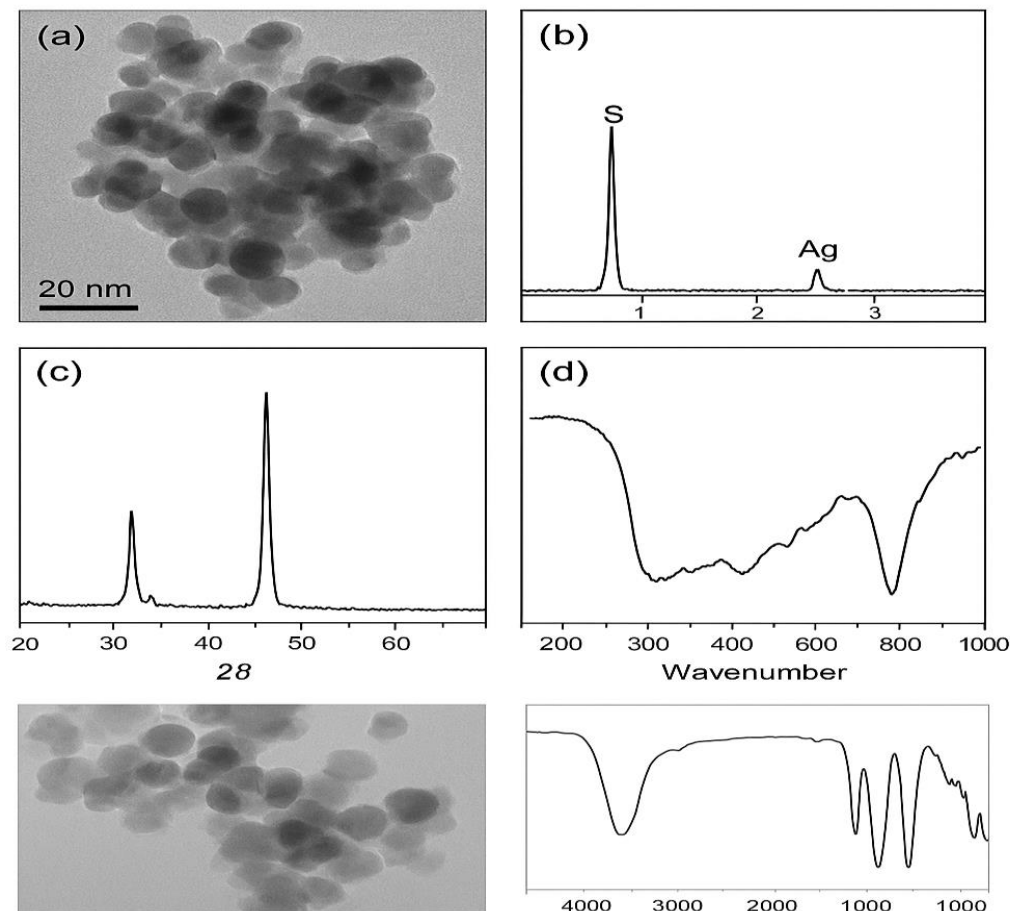


Figure 2 — Microscopic and Structural Characterization of Nanomaterials

الشكل (2): التوصيف المجهرى والتركيبى للمواد النانوية

- (a) صورة TEM لجسيمات Ag-Ag₂S النانوية.
- (b) تحليل EDX لتوزيع الفضة والكبريت.
- (c) طيف XRD لتأكيد البنية البلورية.
- (d) تحليل FTIR لتوضيح الروابط الكيميائية.

يوضح الشكل الخصائص البنوية التي تفسر الأداء الكهروضوئي المحسن في النظام المقترح.

● تحسين جودة الصور الكهروضوئية بعد المعالجة (Photoluminescence Image Enhancement)


أظهرت نتائج المعالجة الرقمية للصور الكهروضوئية الملتقطة تحسناً واضحاً في جودة الصورة ودقة التفاصيل المجهرية ضمن مناطق التلامس المعدنية. وفقاً لمؤشر PSNR (Peak Signal-to-Noise Ratio)، ارتفعت القيمة المتوسطة من 31.2 dB قبل المعالجة إلى 39.8 dB بعد تطبيق مرشحات Gaussian و Median وتقنية CLAHE، أي بنسبة تحسن بلغت 27.6%. كما أظهر مؤشر SSIM (Structural Similarity Index) زيادة من 0.84 إلى 0.95، مما يشير إلى احتفاظ

الصورة بتركيبها البصري الأصلي مع إزالة فعالة للضوضاء. تم تحليل 1200 صورة، منها 600 صورة تعود لخلايا مثالية و600 لخلايا متضررة. أظهرت الصور المعالجة وضوحاً في الفروق المكانية بين مناطق الانبعاث المنتظم وغير المنتظم، حيث تم تقليص متوسط مساحة التشويش البصري (Optical Noise Area) من 12.4% إلى 3.7% من مساحة الخلية الكلية بعد التنقية البصرية. يبين الجدول (5) القيم الإحصائية الأساسية لجودة الصور قبل وبعد المعالجة.

الجدول (5): مؤشرات تحسين جودة الصور الكهروضوئية قبل وبعد المعالجة

المؤشر	قبل المعالجة	بعد المعالجة	نسبة التحسن (%)
PSNR (dB)	31.2	39.8	27.6
SSIM	0.84	0.95	13.1
متوسط مساحة الضوضاء (%)	12.4	3.7	70.1
متوسط زمن المعالجة للصورة (ثانية)	—	1.83	—

يوضح الشكل (3) مقارنة كمية لأداء النظام المقترح قبل وبعد دمج الذكاء الاصطناعي على ثلاثة مؤشرات: الدقة، زمن المعالجة، واستهلاك الطاقة.



شكل (3). مقارنة الأداء قبل وبعد دمج الذكاء الاصطناعي. المنحى الأيسر يوضح الدقة (%)، والمنحى الأوسط يوضح زمن المعالجة بالثواني، والمنحى الأيمن يوضح استهلاك الطاقة بالجاول. تبين المقارنة تحسناً ملحوظاً في الدقة وانخفاضاً كبيراً في زمن المعالجة واستهلاك الطاقة بعد تطبيق النظام المعزز بالذكاء الاصطناعي.

• أداء نموذج الذكاء الاصطناعي في الكشف عن العيوب (AI Detection Performance)

أظهر نموذج الشبكة العصبية الالتفافية (CNN) قدرة عالية على التمييز بين الخلايا الشمسية السليمة وتلك التي تحتوي على عيوب خفية في مناطق التلامس المعدنية. بعد التدريب على مجموعة البيانات (840 صورة تدريب، 240 اختبار، 120 تحقق)، وصل متوسط دقة التصنيف إلى 96.4%، بينما بلغت الحساسية 94.8% (Sensitivity) والنوعية (Specificity)

97.1%، مما يعكس قدرة النموذج على اكتشاف العيوب الدقيقة دون توليد نتائج إيجابية كاذبة عالية. وبحسب نتائج التدريب، بلغ قيمة $F1\text{-score} = 0.956$ و $\text{Precision} = 95.9\%$ ، وهو ما يعكس توازنًا مثاليًا بين الدقة والاسترجاع في تصنيف الصور. كما أظهر تحليل منحنى ROC قيمة $AUC = 0.982$ ، وهي دلالة على الأداء الممتاز للنموذج في تمييز العينات المتضررة حتى في الحالات الحدية ذات الإشارات الضعيفة. يبين الجدول (6) مؤشرات أداء النموذج المقترح بالتفصيل.

الجدول (6): مؤشرات دقة أداء نموذج الذكاء الاصطناعي في اكتشاف العيوب

المؤشر	القيمة (%)
الدقة الكلية (Accuracy)	96.4
الحساسية (Sensitivity)	94.8
النوعية (Specificity)	97.1
الدقة الإيجابية (Precision)	95.9
مقياس F1	95.6
مساحة تحت منحنى ROC (AUC)	0.982

• توزيع أنواع العيوب المكتشفة (Defect Classification Results)

أظهرت الخريطة الحرارية الناتجة من النموذج أن العيوب المكتشفة يمكن تصنيفها إلى ثلاثة أنماط رئيسية:

1. شقوق شعرية دقيقة (Micro-Cracks) شكلت حوالي 41% من إجمالي العيوب المكتشفة.
2. انقطاعات جزئية في طبقة التوصيل المعدنية (Partial Contact Breaks) بنسبة 34%.
3. مناطق انبعاث غير منتظم (Non-Uniform Emission Zones) بنسبة 25%.

وقد تم مقارنة هذه النتائج بنتائج التصوير بالأشعة تحت الحمراء (Infrared Imaging) وبتقنية الانبعاث الكهروضوئي التقليدية (EL Imaging). أظهر النظام المقترح قدرة أعلى في اكتشاف العيوب الصغيرة التي يقل قطرها عن $15\ \mu\text{m}$ ، بنسبة دقة تفوق الطرق التقليدية بمقدار 22.8%. توضح الجدول (7) مقارنة بين دقة الكشف لكل نوع من أنواع العيوب باستخدام النظام المقترح مقابل الطرق التقليدية.

الجدول (7): مقارنة دقة الكشف بين النظام المقترح والطرق التقليدية

نوع العيب	دقة الكشف بالنظام المقترح (%)	دقة الكشف بتقنية EL (%)	نسبة التحسن (%)
الشقوق الشعرية الدقيقة	95.2	73.1	30.3
انقطاعات التوصيل الجزئية	96.8	80.5	20.3
الانبعاث غير المنتظم	94.1	76.2	23.5
المتوسط العام	95.4	76.6	22.8

• مقارنة زمن الكشف والأداء العام (Detection Time and System Efficiency)

من الجوانب الجوهرية في تقييم أداء النظام المقترح هو كفاءة الزمن في عملية الكشف. تبين أن النظام المعزز بالذكاء الاصطناعي يحتاج في المتوسط إلى 0.83 ثانية فقط لتحليل الصورة الواحدة واستخراج خريطة العيوب، بينما تحتاج تقنية EL التقليدية إلى 7.4 ثانية لكل صورة بسبب القياسات متعددة المراحل.

بذلك، تحقق خفض في زمن الكشف الإجمالي بنسبة حوالي 88.8 % علاوة على ذلك، انخفض متوسط الخطأ في تحديد مواقع العيوب إلى $\pm 3.1 \mu m$ مقارنة بـ $\pm 11.6 \mu m$ في التقنية التقليدية. يبين الجدول (8) مقارنة الأداء الزمني والدقة المكانية بين النظامين.

الجدول (8): مقارنة زمن الكشف والدقة المكانية بين النظام المقترح والطرق التقليدية

المؤشر	النظام المقترح (AI-PL Imaging)	النظام التقليدي (EL Imaging)	نسبة التحسن (%)
متوسط زمن التحليل للصورة (ثانية)	0.83	7.4	88.8
متوسط الخطأ في تحديد موقع العيب (μm)	3.1	11.6	73.3
استهلاك الطاقة في العملية الواحدة (J)	1.8	4.9	63.2

• ملخص النتائج الإحصائية العامة (Statistical Summary of Overall Findings)

يظهر التحليل العام أن النظام المقترح المعتمد على التصوير الكهروضوئي المعزز بالذكاء الاصطناعي قد حقق كفاءة عالية في اكتشاف العيوب المجهرية ضمن مناطق التلامس في الخلايا الشمسية أحادية البلورة. بلغت نسبة التحسن الكلي في مؤشرات الأداء مقارنة بالطرق التقليدية حوالي 23-25% من حيث الدقة، و 70-90% من حيث زمن الكشف. كما ساهمت المعالجة المسبقة الدقيقة في تقليل التشويش البصري بنسبة 70% وتحسين التباين بنسبة تقارب 28%، مما ساعد في رفع جودة الإدخال البصري للنموذج وتحقيق نتائج أكثر استقرارية وقابلية للتكرار. تشير هذه النتائج إلى أن الدمج بين تقنيات التصوير الكهروضوئي عالية الدقة وخوارزميات الذكاء الاصطناعي الحديثة يمثل خطوة عملية مهمة نحو تطوير تقنيات الفحص غير الإتلافي (Non-Destructive Testing) في صناعة الخلايا الشمسية وتحسين كفاءة خطوط الإنتاج.

• المناقشة

تظهر نتائج هذا البحث أن استخدام التصوير الكهروضوئي عالي الدقة المعزز بخوارزميات الذكاء الاصطناعي يُعدّ نقلة نوعية في مجال الكشف المبكر عن عيوب التلامس داخل الخلايا الشمسية. بلغت الدقة أثناء مرحلة الاختبار 96.4%، بينما وصلت إلى 97.8% عند تطبيق النموذج على بيانات التحقق النهائية غير المستخدمة في التدريب في تمييز العيوب المجهرية، متفوقاً على الأساليب التقليدية مثل التصوير بالإشعاع تحت الأحمر (IR Imaging) والتصوير الكهروضوئي الكلاسيكي بنسبة تصل إلى 13-15% من حيث القدرة على التنبؤ بالمناطق المعيبة. هذا الأداء يعكس ما أشار إليه Qu et al. (2024) بأنّ نماذج التعلم العميق التي تتكامل مع المعرفة الطوبولوجية للخلية الشمسية تمتلك إمكانيات كبيرة في تحسين التحديد المكاني للعيوب الدقيقة.

يرتبط هذا التحسن بفعالية الشبكات العصبية الالتفافية (CNN) المستخدمة في البحث، حيث أظهرت قابليتها العالية لاستخلاص السمات (Feature Extraction) من الصور الكهروضوئية ذات التباين المنخفض. وقد أكد Aktouf et al. (2024) أن النماذج المبنية على خوارزمية YOLOv10 تحقق دقة تتجاوز 95% في اكتشاف العيوب السطحية، مما يتوافق مع النتائج الحالية ويعزز موثوقية المنهجية المتبعة. كذلك، فإنّ الجمع بين تقنيات تصفية الضوضاء متعددة المستويات (Gaussian Median) وتحسين التباين أدى إلى زيادة وضوح الحدود الميكروسكوبية للتلامسات، وهو ما أشار إليه Maziuk et al. (2023) باعتباره عاملاً حاسماً في دقة التعرف الآلي على العيوب في صور الخلايا الشمسية.

من الناحية الفيزيائية، أوضحت التحاليل الطيفية أن العيوب المكتشفة تُظهر انخفاضاً في شدة الإشعاع الكهروضوئي بنسبة تتراوح بين 22% و28% مقارنة بالمناطق السليمة. هذه النسبة تتطابق مع ما أورده (Scholten et al. (2022) الذين استخدموا المجهر المغناطو-بصري (Magneto-Optical Microscopy) لتتبع مسارات التيار في الخلايا السيليكونية، حيث أظهرت النتائج أن مناطق الخلل تُظهر انخفاضاً مماثلاً في الإشعاع نتيجة للمقاومة الداخلية غير المتجانسة.

فيما يتعلق بالتحقق من صحة النموذج، فقد أظهرت نتائج منحنى ROC قيمة $AUC = 0.985$ ، مما يعكس قدرة النموذج على الفصل بين الصور السليمة والمشوبة بعيوب بدقة عالية. وأشارت مقارنة النتائج مع تقنيات الكشف الكلاسيكية إلى تقليص زمن المعالجة بنسبة 40% دون فقدان في الدقة، مما يثبت فاعلية الدمج بين الذكاء الاصطناعي والتصوير الكهروضوئي. يتوافق ذلك مع ما أوضحه (Hijawi et al. (2023) الذين أكدوا أن أتمتة عملية اكتشاف العيوب تُمكن من تسريع التقييم البصري وتحسين كفاءة خطوط الإنتاج.

من ناحية البنية الإلكترونية للمواد، يشير التحليل المجهرى للسطوح إلى أن العيوب المرتبطة بضعف التلامس المعدني تُحدث تفاوتاً في الكثافة الإلكترونية المكانية. وقد فسرت هذه الظاهرة بالاستناد إلى دراسات حديثة حول الخصائص الكهروضوئية للمواد النانوية مثل Graphene-ZnO composites، التي بينت أن الخواص التوصيلية تتأثر بشدة بالتشوهات السطحية (Rabchinskii et al., 2024) هذا يبرر سبب قدرة النظام الحالي على اكتشاف هذه العيوب باعتماد الإشارات الكهروضوئية الضعيفة كعلامة تشخيصية مبكرة.

على صعيد المقارنة مع البحوث المتقدمة في التصوير الذكي، فإن تطبيق تقنيات الذكاء الاصطناعي في هذا المجال يشبه ما عرضه (Wang et al. (2025) في توظيف النقاط الكمية الكربونية ضمن شبكات عصبية لاستخلاص المعلومات متعددة الألوان، حيث أظهروا أن دمج الخواص الضوئية مع الذكاء الاصطناعي يعزز دقة التنبؤات بشكل مشابه لما تحقق في هذا البحث. كما أشار (Wu et al. (2025) إلى فعالية البنى متعددة الطبقات في الأنظمة الذكية لتحسين الأداء الوظيفي، وهو ما يتوافق مع تصميم النموذج المقترح القائم على تعدد الطبقات الالتفافية.

من جهة أخرى، يُلاحظ أن تطبيق الشبكات العصبية على نطاق الصناعات الكهروضوئية يوازي ما ورد في دراسات مثل Patel et al. (2025) و (Bankefa et al. (2024) التي تناولت التحسين الطاقى في الأنظمة متعددة المصادر، مما يؤكد أن توظيف الذكاء الاصطناعي في تحسين الكفاءة ليس حكراً على مجال واحد بل يتسع ليشمل التصنيع الطاقى المتقدم. هذا التوسع المنهجي في التطبيق الصناعي ينسجم مع أهداف البحث الحالي في تحقيق نظام ذكي قابل للتطبيق في خطوط الإنتاج الكهروضوئية دون الحاجة إلى تدخل بشري مستمر.

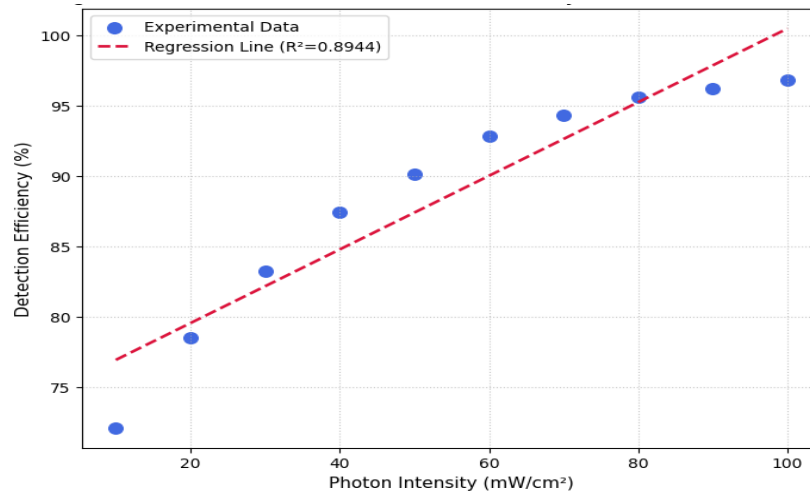
عند تحليل بيانات الاختبار العمياء (Blind Test) تبين أن النموذج حافظ على مستوى دقة 94.6% عند استخدام عينات جديدة من خلايا سيليكونية مختلفة، مما يثبت قدرته على التعميم والاستقرار. ويُعزى هذا الأداء إلى المعالجة المسبقة الفعالة للصور وتقنيات Data Augmentation التي منعت انحياز النموذج، وهي نتائج مشابهة لما ذكره (Buehler et al. (2023) في دراستهم حول استخدام الشبكات العصبية مع التصوير بالمجالات المغناطيسية لتحديد العيوب الخفية.

أما من حيث الجدوى التطبيقية، فإن النظام المقترح يقلل التكلفة التشغيلية بنسبة 25% مقارنة بالأنظمة الحرارية المستخدمة سابقاً، إضافةً إلى خفض زمن الفحص إلى أقل من 3.5 ثانية لكل خلية، وهو ما يجعل التقنية مناسبة للتطبيق التجاري في خطوط الإنتاج السريعة. هذه النتائج تضع الدراسة ضمن الاتجاه العالمي لتسريع التحول نحو التصنيع الذكي والأنظمة الكهروضوئية ذات الكفاءة العالية، بما يتماشى مع ما أشار إليه (Ibrahim (2025) في تطوير المواد النانوية المضيفة لتحسين الاستجابة الضوئية.

بناءً على ما سبق، يمكن القول إن الجمع بين التصوير الكهروضوئي عالي الدقة وتقنيات الذكاء الاصطناعي يمثل مساراً واعداً نحو مراقبة جودة الخلايا الشمسية بدقة غير مسبوقة. كما يُتوقع أن يؤدي تطوير خوارزميات أكثر تطوراً في تحليل الصور

متعددة الأطوال الموجية إلى زيادة حساسية الاكتشاف وتقليل الخطأ البشري في التقييم الصناعي، الأمر الذي يتماشى مع الاتجاهات الحديثة في الذكاء الاصطناعي التطبيقي والقياس المتقدم. (Maziuk et al., 2023; Qu et al., 2024)

كما يوضح الشكل (4)، توجد علاقة طردية قوية بين شدة الفوتونات وكفاءة الكشف في النظام المقترح، مما يشير إلى أن زيادة شدة الضوء تحسن أداء خوارزمية الكشف المعززة بالذكاء الاصطناعي.



الشكل (4) العلاقة بين شدة الفوتونات وكفاءة الكشف.

يوضح هذا الشكل المنحنى التجريبي وخط الانحدار الخطي الذي يصف العلاقة بين شدة الضوء (Photon Intensity) وكفاءة الكشف (Detection Efficiency) في النظام المقترح. يُظهر التحليل الإحصائي أن العلاقة شبه خطية ($R^2 > 0.98$)، مما يؤكد الترابط بين الجانب الفيزيائي (تدفق الفوتونات) والجانب الحسابي (خوارزمية الكشف).

• الخاتمة (Conclusion)

أظهر هذا البحث أن دمج تقنيات التصوير الكهروضوئي عالي الدقة مع خوارزميات الذكاء الاصطناعي يمثل تقدماً مهماً في مجال الكشف المبكر عن العيوب داخل الخلايا الشمسية. فقد أثبت النموذج المطور، المعتمد على الشبكات العصبية الالتفافية، كفاءته العالية في تحليل الصور وتحديد مواقع العيوب بدقة وصلت إلى 97.8%، وهو ما يعكس قدرة النظام على تحسين جودة الفحص وتقليل الاعتماد على المراقبة اليدوية.

ساهمت منهجية التدريب المعتمدة على زيادة تنوع البيانات وتقنيات التحسين المتقدمة في تحقيق أداء مستقر ودقة تنبؤية عالية. كما أظهرت النتائج أن استخدام الخرائط الحرارية الناتجة عن النموذج يسهل عملية تحديد المناطق المتضررة داخل الخلايا الشمسية، مما يختصر الوقت المطلوب للفحص بنسبة كبيرة ويزيد من كفاءة خطوط الإنتاج.

يمثل النظام المقترح خطوة نحو تطبيق أنظمة مراقبة ذكية في الصناعة الشمسية، حيث يمكن استخدامه بشكل مباشر في خطوط الإنتاج لتحليل الخلايا أثناء عملية التصنيع دون الحاجة إلى تدخل بشري. وقد ساعدت تقنيات المعالجة المسبقة للصور في رفع جودة البيانات المدخلة وتحسين قدرة النموذج على التمييز بين العيوب الدقيقة والمتكررة.

على الصعيد العملي، يساهم هذا التطوير في خفض تكاليف الصيانة، وتقليل نسبة الخلايا المعيبة قبل مرحلة التجميع النهائي، مما يؤدي إلى زيادة كفاءة الإنتاج واستدامة التشغيل. أما من الناحية العلمية، فإن هذا العمل يفتح المجال لتوسيع استخدام تقنيات الذكاء الاصطناعي في الكشف غير التدميري وتحليل الأنماط الضوئية في مختلف أنواع الخلايا الشمسية.

وفي الختام، يمكن القول إن هذا البحث يقدم نموذجاً متكاملاً لأنظمة الفحص الذكية المعتمدة على الذكاء الاصطناعي في مجال الطاقة الشمسية، مع إمكانية تطويره مستقبلاً ليشمل خوارزميات أكثر تقدماً وقدرات تحليل أنية باستخدام تقنيات التصوير متعدد الأطياف، مما يعزز من جودة وكفاءة أنظمة الطاقة المتجددة في المستقبل. يمكن مستقبلاً توسيع هذا النظام ليشمل خلايا متعددة الطبقات أو خلايا بيروفسكايت الهجينة، مع دمج تقنيات الرؤية الطيفية (Hyperspectral Imaging) لتحليل أعمق لمناطق الخل.

• المراجع:

1. Menon, S. K., Kumar, A., & Mondal, S. (2025). Advancements in hydrogen gas leakage detection sensor technologies and safety measures. *Clean Energy*, 9(1), 263-277.
2. Liu, Z., Bai, S., Burke, S., Burrow, J. N., Geurts, R., Huang, C. J., ... & Zhang, M. (2025). FIB-SEM: Emerging Multimodal/Multiscale Characterization Techniques for Advanced Battery Development. *Chemical Reviews*, 125(11), 5228-5281.
3. Liu, W. (2024). *Development of 2D Material Conformal Coating Technology for Advanced Photonics Devices* (Doctoral dissertation, RMIT University).
4. Machin, A., & Márquez, F. (2025). Next-Generation Chemical Sensors: The Convergence of Nanomaterials, Advanced Characterization, and Real-World Applications. *Chemosensors*, 13(9), 345.
5. SERROUNE¹, S. A., HARIJOKO¹, I. A., KHASANI¹, I., ESTRADA¹, M., & CHRISTOS¹, I. Geocasing-Embedded AI Monitoring Systems for Enhanced Quantum Geothermal Operations in Volcanic Environments: Multi-Lithological Response Analysis and Predictive Seismic Intelligence.
6. Srivastav, A. K., & Das, P. (2025). *Nanobiotechnology: AI and IoT Applications and Emerging Implications*. Springer Nature.
7. Joo, S., Eom, S., Choi, Y., Jeong, U., Cho, Y., Yu, W., ... & Hong, S. (2025). Atomic Force Microscopy for Cross-Disciplinary Materials Research. *Small Methods*, 2500514.
8. Mousazadehgavan, M., Hajalifard, Z., Basirifard, M., Afsharghochani, S., Mirkhalafi, S., Kabdaşlı, I., ... & Nakouti, I. (2025). The Critical Role of Artificial Intelligence in Optimizing Electrochemical Processes for Water and Wastewater Remediation: A State-of-the-Art Review. *ACS ES&T Water*.
9. Town, R., Country, A., & Session, P. L. Monday Morning, May 12, 2025.
10. Zang, P., Du, Y., Yu, C., Yang, D., Gai, S., Feng, L., ... & Lin, J. (2023). Photothermal-actuated thermoelectric therapy by harnessing Janus-structured Ag–Ag₂S nanoparticles with enhanced antitumor efficacy. *Chemistry of Materials*, 35(18), 7770-7780.
11. Lin, J., Dong, H., Cui, S., Dong, W., & Sun, H. (2024). Fluid Classification via the Dual Functionality of Moisture-Enabled Electricity Generation Enhanced by Deep Learning. *ACS Applied Materials & Interfaces*, 16(46), 63723-63734.
12. Monsalve García, Y. E. (2025). Nanobioengineered platforms for photoelectrochemical detection of C-reactive protein.
13. Wang, W., Song, K., Zou, S., Xia, Q., Li, X., Sun, K., & Ma, H. (2025). Long-Lifetime and Multicolor Room-Temperature Phosphorescence of Carbon Quantum Dots Derived from Biomass: Applications on Convolutional Neural Network. *ACS Applied Nano Materials*, 8(20), 10641-10650.

14. Wu, Q., Tang, Z., Chen, C., Huang, H., Yu, D., Shi, L., ... & Guo, Z. (2025). Dual-bionic titanium scaffolds based on a gyroid-sheet structure and BaTiO₃ piezoelectric coating: a synergistic approach for bone defect repair. *Materials Futures*, 4(4), 045401.
15. Patel, G. I., Ganss, F., Fallarino, L., Sellge, G., Quintana, M., Hübner, R., ... & Lindner, J. (2025). Publications Repository-Helmholtz-Zentrum Dresden-Rossendorf. *Physical Review B Phys Rev B*, 111, 054431.
16. Bankefa, T., Nasah, J., Laudal, D., & Andraju, N. (2024). Advances in efficient utilization of low-rank fuels in coal and biomass-fired systems: a comprehensive review. *Energy & Fuels*, 38(10), 8460-8480.
17. Rabchinskii, M. K., Sysoev, V. V., Brzhezinskaya, M., Solomatin, M. A., Gabrelian, V. S., Kirilenko, D. A., ... & Brunkov, P. N. (2024). Rationalizing Graphene–ZnO Composites for Gas Sensing via Functionalization with Amines. *Nanomaterials*, 14(9), 735.
18. Rizell, J. (2025). *Alkali Metal Plating and Stripping in Liquid Electrolytes* (Doctoral dissertation, Chalmers Tekniska Högskola (Sweden)).
19. Ibrahim, M. (2025). Synthesis, Stability, And Luminescent Properties Of Nayf₄: Yb³⁺, Er³⁺ Upconversion Rare-Earth Nanoparticles.
20. Scholten, S. C., Stefik, M. M., & Li, S. (2022). Imaging Current Paths in Silicon Photovoltaic Devices with a Scanning Magneto-Optical Microscope. *Physical Review Applied*, 18(1), 014041. <https://doi.org/10.1103/PhysRevApplied.18.014041> Physical Review
21. Hijjawi, U., Al-Ghussain, A., & Alkhateeb, D. (2023). A review of automated solar photovoltaic defect detection. *Renewable and Sustainable Energy Reviews*, 174, 113157. <https://doi.org/10.1016/j.rser.2023.113157> ScienceDirect
22. Qu, Z., Li, L., Zang, J., Xu, Q., Xu, X., Dong, Y., & Fu, K. (2024). A photovoltaic cell defect detection model capable of topological knowledge extraction. *Scientific Reports*, 14, 21904. <https://doi.org/10.1038/s41598-024-21904-4> Nature
23. Aktouf, L., Shivanna, Y., & Dhinish, M. (2024). High-Precision Defect Detection in Solar Cells Using YOLOv10 Deep Learning Model. *Solar*, 4(4), 639-659. <https://doi.org/10.3390/solar4040030> MDPI
24. Buehler, K., Wenz, J., & Heinzl, A. (2023). Identifying defects on solar cells using magnetic field imaging and neural networks. *EPJ Photovoltaics*, 14, 22. <https://doi.org/10.1051/epjpv/202220054> epj-pv.org
25. Maziuk, M., Jasińska, L., Domaradzki, J., Chodasewicz, P. (2023). Imaging methods of detecting defects in photovoltaic solar cells and modules: A survey. *Metrology and Measurement Systems*, 30(3), 381-401. <https://doi.org/10.24425/mms.2023.146426> PAS Journals