

Supporting Smart Agriculture through Crop Health Monitoring Using Deep Learning Techniques (CNN)

Aiman Ahmad ^{1*}, Hatim Almabrouk ², Kais Rhoma ³, Ahmed Brany ⁴

^{1,2,3,4} Department of Software Engineering, College of Information Technology, University of Gharyan, Gharyan, Libya

دعم الزراعة الذكية لمراقبة صحة المحاصيل باستخدام تقنيات التعلم العميق CNN

أيمن أحمد محمد أحمد ^{1*}، حاتم أحمد المبروك ²، قيس ميلود رحومه ³، أحمد علي البراني ⁴
^{4,3,2,1} قسم هندسة البرمجيات، كلية تقنية المعلومات جامعة غريان، غريان، ليبيا

*Corresponding author: aiman.ahmad@gu.edu.ly

Received: February 19, 2026

Accepted: March 25, 2026

Published: April 02, 2026



Copyright: © 2026 by the authors. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Abstract:

This study develops an intelligent plant disease diagnosis system using deep learning and transfer learning techniques within the PyTorch framework. Models were trained on 21,481 images from the PlantVillage dataset, covering 19 crop categories including grapes, peppers, potatoes, and tomatoes. Experiments included a comparison between two convolutional neural network architectures, EfficientNet-B3 and MobileNetV3-Large, to evaluate performance in terms of accuracy and computational efficiency. The results showed that the MobileNetV3-Large model achieved the best performance with an accuracy of 99.31%, fewer coefficients, and shorter training time, making it more suitable for mobile applications. The final model was integrated into a Flutter-based mobile application that provides instant plant disease diagnosis, treatment recommendations, preventative measures, and detailed disease information, making it an effective digital tool for supporting smart agriculture and enhancing agricultural productivity.

Keywords: Diagnosis of Plant Diseases, Mobilenetv3-Large, Efficientnet-B3, Transfer Learning, Flutter Smart Agriculture.

المخلص

تُطوّر هذه الدراسة نظامًا ذكيًا لتشخيص أمراض النباتات باستخدام تقنيات التعلم العميق ونقل التعلم ضمن إطار عمل PyTorch. حيث تم تدريب النماذج على 21,481 صورة من مجموعة بيانات PlantVillage، تغطي 19 فئة لمحاصيل العنب والفلل والبطاطا والطماطم. شملت التجارب مقارنة بين معماريتين من الشبكات العصبية الالتفافية هما EfficientNet-B3 و MobileNetV3-Large بهدف تقييم الأداء من حيث الدقة والكفاءة الحاسوبية. أظهرت النتائج أن نموذج MobileNetV3-Large حقق أفضل أداء بدقة تحقق بلغت 99.31% مع عدد معاملات أقل وزمن تدريب أقصر، مما يجعله أكثر ملاءمة للتطبيقات المحمولة. كما تم دمج النموذج النهائي داخل تطبيق جوال قائم على منصة Flutter والذي يوفر تشخيصًا فوريًا لأمراض النباتات، إضافة إلى توصيات علاجية وتدابير وقائية ومعلومات تفصيلية عن المرض، مما يجعله أداة رقمية فعالة لدعم الزراعة الذكية وتعزيز الإنتاجية الزراعية.

الكلمات المفتاحية: تشخيص أمراض النبات، MobileNetV3-Large، EfficientNet-B3، التعلم بالنقل، تطبيق Flutter، الزراعة الذكية.

1. المقدمة

يُعد القطاع الزراعي أحد الركائز الأساسية للأمن الغذائي العالمي، حيث تتعرض المحاصيل الزراعية لخسائر كبيرة نتيجة الإصابة بالأمراض والآفات والتي تؤثر بشكل مباشر على الإنتاجية وجودة المحصول. وتعتمد طرق التشخيص التقليدية غالبًا على الخبرة البشرية والفحص البصري من قبل المختصين أو المزارعين، مما قد يؤدي إلى تأخر في اكتشاف المرض أو حدوث أخطاء في التشخيص، خاصة في المراحل المبكرة للإصابة. لذلك أصبح استخدام التقنيات الذكية في تشخيص أمراض النباتات من الاتجاهات البحثية المهمة في مجال الزراعة الذكية. تُعد أنظمة تشخيص أمراض النباتات المعتمدة على تحليل الصور من أبرز تطبيقات الذكاء الاصطناعي في المجال الزراعي، حيث تسمح باكتشاف الإصابات مبكرًا وتقليل انتشار العدوى بين المحاصيل، مما يساهم في تقليل الخسائر الزراعية وتحسين جودة الإنتاج. وقد أظهرت الدراسات الحديثة أن الشبكات العصبية الالتفافية (Convolutional Neural Networks - CNNs) قادرة على تحليل الصور الزراعية بدقة عالية واستخراج السمات البصرية المرتبطة بالأمراض النباتية بشكل فعال مقارنة بالطرق التقليدية المعتمدة على استخراج الخصائص اليدوي [8]، [9]. ومع تطور نماذج التعلم العميق، ظهرت معماريات متقدمة مثل EfficientNet و MobileNet التي توفر توازنًا بين الدقة والكفاءة الحاسوبية، مما يجعلها مناسبة للتطبيقات العملية، خاصة في الأنظمة المحمولة والتطبيقات الزراعية الذكية [10]. لذلك يهدف هذا البحث إلى تصميم نظام ذكي لتصنيف أمراض النباتات باستخدام تقنيات التعلم العميق ونقل التعلم، مع إجراء مقارنة بين نموذجي EfficientNet-B3 و MobileNetV3 Large لتحديد النموذج الأكثر كفاءة من حيث الدقة والأداء، ومن ثم دمجها داخل تطبيق جوال لدعم عملية التشخيص السريع لأمراض النباتات.

2. الدراسات السابقة

الدراسة الأولى: تناولت دراسة Yadav وزملاؤه بعنوان: Plant Disease Identification Using Deep Learning and Transfer Learning موضوع التعرف على أمراض النباتات باستخدام تقنيات التعلم العميق ونقل التعلم، وذلك ضمن أعمال مؤتمر Seventh International Conference on Recent Trends in Image Processing and Pattern Recognition (RTIP2R-2024) [1]. هدفت الدراسة إلى تحسين دقة أنظمة تشخيص أمراض النباتات نظرًا لتأثيرها المباشر على الإنتاجية الزراعية.

اعتمد الباحثون على مجموعة بيانات Plant Village Dataset التي تضم أكثر من 21,000 صورة، واستخدموا منهجين رئيسيين:

• نموذج قائم على الشبكات العصبية الالتفافية (CNN).

• نموذج قائم على نقل التعلم باستخدام معمارية VGG19.

وأظهرت النتائج أن نموذج CNN حقق دقة بلغت 93.82%، بينما حقق نموذج VGG19 دقة بلغت 88.93%. كما ركزت الدراسة على مقارنة نتائجها مع دراسات سابقة استخدمت نفس مجموعة البيانات، وأشارت إلى تفوق النموذج المقترح من حيث الدقة [1].

الدراسة الثانية: تناولت دراسة Mishra و Pandey و Logeswari و Tamilarasi بعنوان: Deep learning-based disease detection in potato and mango leaves: a comparative study of CNN, AlexNet, ResNet, and EfficientNet موضوع الكشف المبكر عن أمراض أوراق البطاطا والمانجو باستخدام تقنيات التعلم العميق، حيث هدفت إلى تطوير نظام آلي دقيق يمكن استخدامه في الزراعة الذكية وتقليل خسائر المحاصيل [2].

اعتمد الباحثون على مجموعتي بيانات متاحيتين للعامّة:

• مجموعة Plant Village Potato Leaf Disease dataset التي تضم 2,152 صورة.

• مجموعة Kaggle Mango Leaf Disease dataset التي تضم 4,000 صورة.

تم إجراء عمليات معالجة مسبقة للصور (Preprocessing) وتوسيع للبيانات (Data Augmentation)، ثم تقسيمها بنسبة 80% للتدريب و20% للاختبار لتحسين قدرة النماذج على التعميم. أجرى الباحثون مقارنة بين أربع معماريات رئيسية:

1. نموذج CNN التقليدي - نموذج AlexNet. نموذج ResNet. نموذج EfficientNet. وأظهرت النتائج أن:

1. نموذج CNN حقق دقة اختبار بلغت 92.61%.

2. نموذج AlexNet حقق دقة تحقق بلغت 90.2%.

3. نموذج ResNet وصل إلى 96.7% دقة تحقق.

4. نموذج EfficientNet تفوق على جميع النماذج الأخرى محققاً دقة تدريب 98.2% ودقة تحقق

97.8% مع أقل نسبة فقد ($Loss \approx 0.015$) ودون ظهور مشكلة فرط التكييف (Overfitting).

وأشارت الدراسة إلى أن نموذج EfficientNet يُعد خياراً واعداً للتطبيقات الزراعية الذكية القابلة للتوسع، نظراً لقدرته العالية على التعميم والاستقرار في التصنيف [2].

الدراسة الثالثة: تناولت دراسة Zainab و Mahum بعنوان: Plant Disease Detection Using Deep Learning Techniques موضوع الكشف عن أمراض النباتات باستخدام تقنيات التعلم العميق، وهدفت إلى تطوير نموذج قادر على التمييز بين الأوراق السليمة والمصابة حتى في محاصيل وأمراض لم يتم التدريب عليها سابقاً [3].

اعتمد الباحثان على مجموعة بيانات Plant Village dataset في تدريب النموذج واختباره، وركزا على تحديد المناطق الصغيرة المصابة داخل الورقة بدلاً من الاعتماد على شكل الورقة بالكامل، كما قاموا بحساب نسبة انتشار المرض على كامل الورقة لتعزيز دقة التصنيف. استخدمت الدراسة نموذجاً قائماً على معمارية Inception ضمن إطار التعلم العميق لتحسين قدرة النموذج على استخراج السمات الدقيقة للأمراض النباتية. وأظهرت النتائج أن النموذج المقترح حقق دقة بلغت 99.75% في تصنيف أمراض النباتات، مما يدل على كفاءة النموذج في التعامل مع صور أوراق مختلفة لأنواع متعددة من المحاصيل. وأكدت الدراسة قدرة النموذج على التعميم robust generalization حتى مع محاصيل وأمراض جديدة لم يتم التدريب عليها مسبقاً [3].

الدراسة الرابعة: قدمت دراسة Lu و Tan و Jiang بعنوان *Review on Convolutional Neural Network (CNN) Applied to Plant Leaf Disease Classification* مراجعة شاملة لتطبيقات الشبكات العصبية الالتفافية (CNN) في تصنيف أمراض أوراق النباتات [8]. أوضحت الدراسة أن نماذج CNN تفوقت على الأساليب التقليدية المعتمدة على استخراج الخصائص اليدوي (Handcrafted Features)، كما بينت أن نجاح هذه النماذج يرتبط بجودة البيانات وتنوعها، إضافة إلى تناول التحديات الشائعة والحلول المقترحة والاتجاهات المستقبلية في هذا المجال [8].

الدراسة الخامسة: تناولت دراسة منشورة في مجلة (MDPI) بعنوان *Plant Leaf Disease Detection Using Deep Learning: A Multi-Dataset Approach* تطوير نماذج تشخيص أكثر قدرة على العمل في ظروف متنوعة وغير محكومة، وذلك من خلال الاعتماد على بيانات متعددة المصادر بدلاً من الاقتصار على الصور المخبرية [12]. استخدمت الدراسة مزيجاً من مجموعات بيانات مثل (Planetdom وصور من الويب)، مع تدريب/ضبط نماذج حديثة مثل EfficientNet و ResNet للوصول إلى أداء أفضل في التعميم على بيانات مختلفة، وهو ما يدعم اتجاه دمج النماذج داخل تطبيقات عملية قابلة للاستخدام ميدانياً [12]. وفيما يلي الجدول رقم 1 يعرض ملخص لنتائج الدراسات السابقة.

جدول (1) نتائج الدراسات السابقة.

Ref	Year	Model / Method	Dataset	Accuracy Reported	Precision / Recall	Confusion Matrix Analysis	Efficiency Analysis	Explainability	Limitations
1	2024	CNN + VGG19 (Transfer Learning)	PlantVillage > 21,000 images	✓	X	X	X	X	اعتمدت الدراسة على PlantVillage وركزت على الدقة والمقارنة مع دراسات سابقة، دون عرض واضح لتحليل confusion matrix أو explainability أو efficiency بشكل مستقل.
3	2026	CNN, AlexNet, ResNet, Efficient Net	PlantVillage Potato Leaf Disease (2,152) + Kaggle Mango Leaf Disease (4,000)	✓	✓	✓	✓	X	توجد صعوبة محتملة بين بعض الفئات المتشابهة بصرياً، كما أن النموذج غير تفسيري، وذكر أن XAI/Grad-CAM من الأعمال المستقبلية.
3	2025	VGG19, DenseNet 169, ResNet152, MobileNetv3	PlantVillage	✓	✓	✓	✓	X	الأداء مرتفع جداً على بيانات الدراسة، لكن التحدي يبقى في التعميم على البيانات الواقعية المختلفة وجودة الصور المتغيرة.
4	2021	Review on CNN applied to plant leaf disease classification	Review of multiple studies	X	X	X	X	X	هذه دراسة مراجعة وليست دراسة تجريبية بنموذج واحد، لذلك لا تُحسب فيها هذه المؤشرات بصيغة صح/خطأ مثل الدراسات التجريبية.
5	2025	Efficient Net-B0, Efficient Net-B3, ResNet50, DenseNet 201	PlantDoc + Web-sourced images + Combined dataset	✓	X	✓	✓	X	أبرزت الدراسة تحديات الضوضاء واختلاف البيانات ومشكلة التعميم بين datasets المختلفة، مع تركيز أكبر على robustness أكثر من explainability.

تحليل الفجوة البحثية (Research Gap)

على الرغم من أن الدراسات السابقة أظهرت نتائج واعدة من حيث دقة التصنيف، إلا أن معظمها ركز على الجانب التجريبي داخل بيئات بحثية منظمة، دون تقديم نظام تطبيقي متكامل يعمل في وضع Offline ويدعم تعدد المنصات. كما أن بعض الدراسات اعتمدت على بنى متعددة المراحل (Multi-Stage Classification)، مما يزيد من تعقيد النظام واحتمالية تراكم الخطأ بين المراحل. إضافة إلى ذلك، لا تزال هناك حاجة إلى أنظمة تتمتع بالتوازن بين الدقة العالية والكفاءة الحاسوبية وسهولة الاستخدام بالإضافة إلى قابلية التشغيل على الأجهزة المحمولة. ومن هنا تأتي هذه الدراسة لسد هذه الفجوة، من خلال تطوير نموذج تعلم عميق متقدم، مدمج داخل تطبيق متعدد المنصات يعمل دون اتصال بالإنترنت، مع تحقيق دقة تصنيف مرتفعة وكفاءة تشغيل مناسبة.

3. مشكلة البحث

تعاني المحاصيل الزراعية من خسائر كبيرة نتيجة الإصابة بالأمراض النباتية، ويعتمد تشخيص هذه الأمراض غالبًا على الفحص اليدوي والخبرة الشخصية للمزارعين أو المختصين، مما قد يؤدي إلى أخطاء في التشخيص أو تأخر في اكتشاف المرض. كما أن نقص الخبراء الزراعيين في بعض المناطق يزيد من صعوبة الحصول على تشخيص دقيق وسريع. على الرغم من توفر تقنيات الذكاء الاصطناعي، إلا أن تطبيقها في المجال الزراعي لا يزال محدودًا في البيئات المحلية، وتوجد حاجة إلى نظام ذكي قادر على تصنيف أمراض النباتات بدقة عالية وبزمن استجابة سريع لذلك تتمثل مشكلة البحث في كيفية تصميم نموذج تعلم عميق قادر على تشخيص أمراض النباتات تلقائيًا من خلال الصور، بدقة مرتفعة، مع إمكانية تفسير قراراته لدعم الثقة في نتائجه.

4. فرضيات البحث

• الفرضية الصفرية: (H0)

- لا توجد علاقة أو تأثير بين استخدام نماذج التعلم العميق المعتمدة على الشبكات العصبية الالتفافية) مثل EfficientNet-B3 و MobileNet V3-Large مع تقنية نقل التعلم في النظام ودقة تشخيص أمراض النباتات؛ بمعنى أن النظام لا يحسن من سرعة ودقة اكتشاف الأمراض مقارنة بالطرق التقليدية.
- المعالجة المسبقة للبيانات (تدوير الصور، الانعكاس، تحسين التباين) لا تؤثر على الأداء العام للنموذج.
- استخدام Grad-CAM لتفسير القرارات لا يزيد من موثوقية النظام في دعم اتخاذ القرار للمزارعين.

• الفرضية البديلة: (H1)

- يوجد تأثير إيجابي لاستخدام نماذج التعلم العميق المعتمدة على الشبكات العصبية الالتفافية مع تقنية نقل التعلم في تحسين دقة وسرعة تشخيص أمراض النباتات مقارنة بالطرق التقليدية.
- عمليات المعالجة المسبقة للبيانات تساهم في تحسين قدرة النموذج على التعميم وتقليل أخطاء التصنيف.
- استخدام Grad-CAM لتفسير قرارات النموذج يعزز موثوقية النتائج ويدعم اتخاذ القرار للمزارعين.

5. أسئلة البحث

1. هل يمكن تصميم نظام يعتمد على نماذج التعلم العميق القائمة على الشبكات العصبية الالتفافية (CNN) قادر على تشخيص أمراض النباتات بدقة عالية باستخدام صور أوراق النباتات؟

2. ما مدى تأثير تقنيات المعالجة المسبقة للصور (مثل التدوير، الانعكاس، تحسين التباين، والتطبيع) على أداء نماذج التعلم العميق في التعرف على أمراض النباتات؟
3. أي النماذج العميقة يحقق أداءً أفضل في تصنيف أمراض النباتات، مثل EfficientNet-B3 أو MobileNetV3-Large، من حيث الدقة والكفاءة الحاسوبية؟
4. هل يمكن استخدام تقنية Grad-CAM لتفسير قرارات النموذج وتحديد المناطق المصابة في الورقة النباتية بشكل موثوق؟
5. ما مدى فاعلية النظام المقترح في تسريع عملية تشخيص الأمراض النباتية مقارنة بالطرق التقليدية المعتمدة على الخبرة البشرية، وإمكانية استخدامه كأداة دعم قرار للمزارعين؟

6. أهداف البحث

1. تطوير نظام ذكي لتشخيص أمراض النباتات باستخدام تقنيات التعلم العميق ونقل التعلم.
2. تحسين دقة التعرف على أمراض النباتات من خلال المعالجة المسبقة للصور ورفع جودة البيانات المستخدمة في التدريب.
3. مقارنة أداء بعض نماذج الشبكات العصبية الالتفافية (CNN) مثل EfficientNet-B3 و MobileNetV3-Large لتحديد النموذج الأكثر كفاءة في تصنيف أمراض النباتات.
4. تمكين تفسير قرارات النموذج باستخدام تقنيات مثل Grad-CAM لتعزيز الثقة في نتائج التشخيص.
5. تقديم أداة دعم قرار عملية للمزارعين من خلال دمج النموذج الأفضل أداءً داخل تطبيق جوال، بهدف تقليل الخسائر الزراعية وتحسين الإنتاجية.

7. أهمية البحث

1. **علمياً:** يساهم البحث في توظيف تقنيات التعلم العميق ونقل التعلم في المجال الزراعي، كما يقدم مقارنة بين بعض معماريات الشبكات العصبية الالتفافية مثل EfficientNet-B3 و MobileNetV3-Large في تصنيف أمراض النباتات بدقة عالية.
2. **عملياً:** يوفر نظاماً ذكياً يمكن استخدامه من قبل المزارعين والمختصين وكذلك ومزارعين وأصحاب النباتات المنزلية لتشخيص أمراض النباتات بسرعة ودقة، مما يساعد على تقليل الأخطاء البشرية والحد من الخسائر الزراعية وتحسين الإنتاجية.
3. **تكنولوجياً:** يبرز البحث إمكانية دمج نماذج التعلم العميق داخل تطبيقات الهواتف الذكية، إضافة إلى إبراز دور تقنيات تفسير النماذج مثل Grad-CAM في تعزيز الثقة بنتائج الأنظمة الذكية وتطبيقاتها في الزراعة الدقيقة.

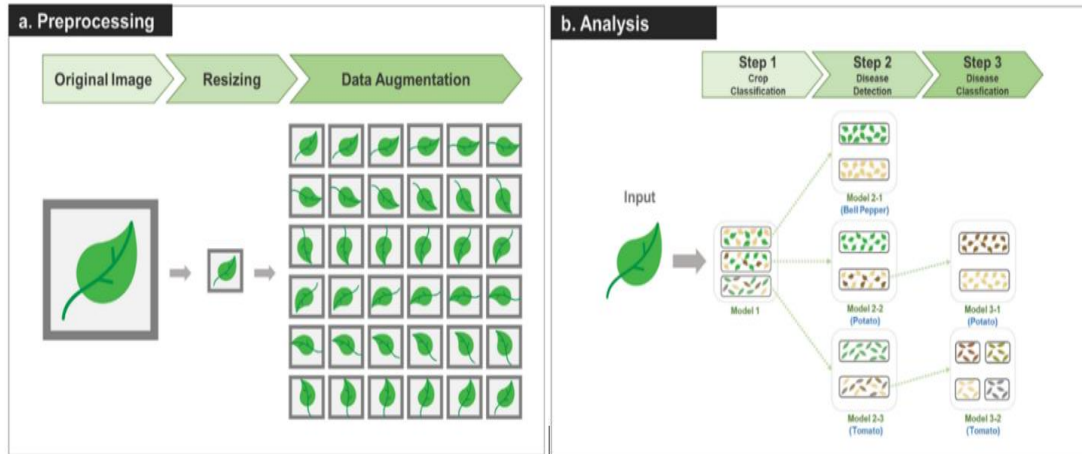
8. منهجية البحث

تم اعتماد المنهج التجريبي في هذا البحث بهدف دراسة أثر نماذج التعلم العميق على دقة وسرعة تشخيص أمراض النباتات من خلال صور الأوراق. يتيح هذا المنهج التحكم في المتغيرات المستقلة مثل المعالجة المسبقة للصور (التدوير، الانعكاس، تحسين التباين والتطبيع) ونماذج الشبكات العصبية الالتفافية المستخدمة في التجربة مثل EfficientNet-B3 و MobileNetV3-Large، وملاحظة تأثيرها على المتغيرات التابعة، وهي دقة التصنيف ووقت استجابة النظام. بالإضافة إلى ذلك، استخدم البحث المنهج الوصفي التحليلي لدراسة وتحليل الأدبيات السابقة ذات العلاقة، بما في ذلك استخدام قاعدة بيانات Plant Village وتقنيات نقل التعلم (Transfer Learning) في الزراعة الذكية، وذلك لاستخلاص الفجوات البحثية وتحديد أفضل الأساليب لتصميم النظام المقترح.

وقد تم اتباع الخطوات التالية:

1. تحديد مشكلة البحث والمتغيرات: تعريف مشكلة التشخيص اليدوي للأمراض النباتية وصعوبة اكتشافها بدقة وسرعة، مع تحديد المتغيرات المستقلة والتابعة.
2. صياغة الفرضيات: وضع الفرضية الصفرية (H0) والفرضية البديلة (H1) لتوضيح العلاقة بين استخدام نماذج التعلم العميق والتقنيات المختلفة ودقة النظام.

3. تصميم التجربة: إعداد بيانات التدريب والتحقق من قاعدة بيانات Plant Village، وتحضير النماذج المستخدمة وتجهيز عمليات المعالجة المسبقة للصور.



شكل 1: إعداد بيانات التدريب

4. إجراء التجربة: تدريب النماذج على منصة Kaggle باستخدام معالج الرسومات Tesla P100 GPU ومراقبة الأداء خلال خمس دورات تدريبية (Epochs).
5. تحليل النتائج: قياس دقة النماذج وزمن الاستجابة، وإنشاء مصفوفة الالتباس (Confusion Matrix)، وتحليل توزيع الثقة، إضافة إلى تفسير قرارات النموذج باستخدام تقنية Grad-CAM.
6. استخلاص النتائج: مقارنة أداء النماذج المختلفة لتحديد النموذج الأكثر كفاءة في تشخيص أمراض النباتات، ثم تقييم مدى توافق النتائج مع الفرضية البديلة واستخلاص توصيات للتطبيق العملي للنظام.

9. حدود البحث

1. **حدود موضوعية:** يقتصر البحث على تشخيص أمراض النباتات التي تتعلق بمحاصيل العنب، الفلفل، البطاطا، والطماطم باستخدام صور الأوراق فقط، دون النظر إلى أجزاء النبات الأخرى مثل الجذور أو الثمار.
2. **حدود مكانية:** تم استخدام قاعدة بيانات Plant Village التي تضم صورًا مأخوذة من مصادر مختلفة، دون تنفيذ الاختبارات على الحقول الزراعية الحقيقية، مما قد يؤدي إلى اختلاف الأداء عند تطبيق النظام في البيئات الزراعية الواقعية.
3. **حدود زمنية:** يقتصر البحث على فترة التدريب والتحقق المحددة في التجارب، والتي شملت خمس دورات تدريبية (Epochs) فقط.
4. **حدود منهجية:** يعتمد البحث على تقنيات التعلم العميق ونقل التعلم من خلال مقارنة نموذجين من الشبكات العصبية الالتفافية وهما EfficientNet-B3 و MobileNetV3-Large، دون التوسع في مقارنة عدد أكبر من المعماريات الأخرى.
5. **حدود تقنية:** تم إجراء التدريب على منصة Kaggle باستخدام معالج الرسومات Tesla P100 GPU، مما قد يؤدي إلى اختلاف الأداء عند استخدام موارد حوسبية أقل أو بيئات تشغيل مختلفة.

10. وصف النظام المقترح

يهدف النظام المقترح إلى تصميم وتطوير نموذج ذكي متكامل لتشخيص أمراض النباتات باستخدام تقنيات التعلم العميق (Deep Learning) ونقل التعلم (Transfer Learning) حيث يعتمد النظام على تحليل وتصنيف صور أوراق المحاصيل الزراعية (العنب، الفلفل، البطاطا، والطماطم) إلى 19 فئة تشمل الحالات المرضية والصحية، وذلك باستخدام نماذج الشبكات العصبية الالتفافية (CNN) في هذا البحث تم اختبار أكثر من معمارية من نماذج التعلم العميق، مثل EfficientNet-B3 و MobileNetV3-Large، بهدف مقارنة أدائها من حيث الدقة والكفاءة الحاسوبية. وقد أظهرت النتائج أن نموذج MobileNetV3-

Large يوفر توازنًا جيدًا بين الدقة وسرعة التنفيذ، مما يجعله مناسبًا للتطبيقات المحمولة. يعتمد النظام على بناء نموذج برمجي عالي الدقة يتم تدريبه ومعالجته مسبقًا لضمان سرعة الاستجابة وكفاءة التشخيص عند تطبيقه في البيئات الزراعية، مما يساهم في الاكتشاف المبكر للأمراض النباتية والحد من الخسائر الاقتصادية للمزارعين، تم اختيار نموذج MobileNetV3-Large ليكون النموذج النهائي المستخدم في التطبيق بسبب توازنه بين الدقة العالية والكفاءة الحاسوبية، مما يجعله مناسبًا للتطبيقات المحمولة. كما تم تصميم نموذج النظام المقترح ليعمل كدورة حياة متكاملة تبدأ من جلب البيانات الخام وتنتهي بنموذج جاهز للتطبيق. يعتمد التصميم على هيكلية برمجية متسلسلة تضمن معالجة الصور واستخلاص الميزات بدقة عالية. يتمثل مخطط النظام في الربط بين قاعدة البيانات، ومنصة المعالجة السحابية (Kaggle)، وإطار العمل (PyTorch) لإنتاج النموذج النهائي القابل للاستخدام في التطبيقات المحمولة. يعتمد النظام على نماذج الشبكات العصبية الالتفافية (CNN) التي أثبتت فعاليتها في تحليل الصور الزراعية وتشخيص أمراض النباتات بدقة عالية [8]، [11].

ثانياً: الأدوات والتقنيات المستخدمة

1. **قاعدة البيانات: (PlantVillage)** تمثل المصدر الأساسي للبيانات في هذا البحث، pde تحتوي على صور مصنفة لأوراق النباتات السليمة والمصابة، [5]

2. **إطار العمل: (PyTorch)** تم استخدام مكتبة PyTorch كبنية برمجية رئيسية لبناء الشبكات العصبية الالتفافية وتدريب النماذج باستخدام تقنيات التعلم العميق ونقل التعلم. [6]

3. **المعالج الرسومي: (NVIDIA Tesla P100)** تم استخدام معالج الرسومات المتوفر عبر منصة Kaggle لتوفير القدرة الحوسبية اللازمة لتدريب نماذج التعلم العميق بكفاءة عالية وتسريع عمليات التدريب.

4. **مكتبة: Torch vision** استخدمت لتطبيق عمليات التحويل والمعالجة المسبقة للصور مثل تغيير الحجم والتدوير والتطبيع، مما يساعد على تحسين جودة البيانات وزيادة قدرة النموذج على التعميم. [8]

ثالثاً: مراحل تنفيذ النظام المقترح

1. مرحلة تجهيز البيانات (Data Preparation)

في هذه المرحلة يتم استدعاء البيانات من قاعدة Plant Village وتنظيمها ومعالجتها قبل إدخالها إلى نموذج التعلم العميق. تم تقسيم البيانات إلى مجموعتين رئيسيتين هما مجموعة التدريب (Training Set) ومجموعة التحقق (Validation Set) لضمان تقييم أداء النموذج بشكل صحيح. كما تم تحديد 19 فئة (Class) تمثل الحالات المختلفة للأمراض النباتية والحالات الصحية للمحاصيل المستهدفة (العنب، الفلفل، البطاطا، والطماطم)، حيث تساعد هذه الفئات في تدريب النموذج على التمييز بين أنواع الأمراض المختلفة بدقة عالية.

الكلمات المستخدمة:

- Grape__Black_rot
- Grape__Esca_(Black_Measles)
- Grape__leaf_blight_(Isariopsis_Leaf_Spot)
- Grape__healthy
- Pepper__bell__Bacterial_spot
- Pepper__bell__healthy
- Potato__early_blight
- Potato__late_blight
- Potato__healthy
- Tomato__Bacterial_spot
- Tomato__early_blight
- Tomato__late_blight
- Tomato__Leaf_Mold
- Tomato__Septoria_leaf_spot
- Tomato__Spider_mites_Two-spotted_spider_mite
- Tomato__Target_Spot
- Tomato__Tomato_Yellow_Leaf_Curl_Virus
- Tomato__Tomato_mosaic_virus
- Tomato__healthy

عدد الكلمات: 19

شكل 2 : تحديد 19 كلاس (Class) تشمل المحاصيل المستهدفة

2. مرحلة المعالجة المسبقة (Preprocessing)

لضمان قدرة النموذج على التعميم والتعامل مع اختلاف ظروف التصوير، تم استخدام تقنيات تعزيز البيانات (Data Augmentation) مثل التدوير العشوائي بزواوية تصل إلى 15 درجة، وتعديل السطوح والتباين، إضافة إلى تطبيع قيم الألوان (Normalization) تساعد هذه العمليات على زيادة تنوع البيانات وتحسين أداء نماذج التعلم العميق في تصنيف الصور الزراعية [8][11].

3. مرحلة بناء وتحميل النموذج (Model Architecture)

تم استخدام نماذج الشبكات العصبية الالتفافية المبنية مسبقاً مع تقنية نقل التعلم (Transfer Learning)، حيث تم اختبار معماريتين هما EfficientNet-B3 و MobileNetV3-Large تم تحميل الأوزان المدربة مسبقاً للنماذج ("weights="DEFAULT")، ثم تعديل الطبقة التصنيفية الأخيرة لتناسب مع عدد الفئات المستخدمة في النظام، والبالغ 19 فئة. تساعد هذه الطريقة على تسريع عملية التدريب وتحقيق دقة تصنيف مرتفعة باستخدام بيانات محدودة نسبياً [4]. [10].

4. مرحلة التدريب والتحقق (Training & Validation)

تم إجراء عملية التدريب لعدد 5 دورات تدريبية (Epochs) مع مراقبة دالة الفقد (Loss) ودقة التنبؤ (Accuracy) أثناء التدريب. كما تم استخدام خوارزمية Adam Optimizer لتحديث أوزان النموذج بشكل تدريجي بهدف تحسين أداء التصنيف وتقليل الخطأ أثناء عملية التعلم.

5. مرحلة التقييم والاختبار (Testing & Evaluation)

بعد انتهاء التدريب، تم تقييم أداء النماذج باستخدام مجموعة التحقق من خلال حساب دقة التصنيف وتحليل النتائج باستخدام (Confusion Matrix)، والتي تساعد على قياس قدرة النظام على التمييز بين الفئات المختلفة للأمراض النباتية وتحديد الحالات التي قد يحدث فيها التباس بين الأمراض المتقاربة. [2]

6. مرحلة حفظ وتصدير النظام

تمثل هذه المرحلة الخطوة النهائية في بناء النظام، حيث يتم حفظ النموذج المدرب بصيغة (.pth). ليكون جاهزاً للاستخدام لاحقاً. بعد ذلك يمكن دمج النموذج داخل التطبيق المحمول لتوفير نظام تشخيص سريع يعتمد على تحليل صور أوراق النباتات.

التجارب العملية ومناقشة النتائج

تم إجراء مجموعة من التجارب والاختبارات البرمجية على النظام المقترح بهدف تقييم قدرته على تشخيص أمراض النباتات بدقة وكفاءة. شملت هذه التجارب تدريب نماذج التعلم العميق باستخدام قاعدة بيانات PlantVillage، مع إجراء مقارنة بين معماريتين من الشبكات العصبية الالتفافية CNN وهما EfficientNet-B3 و MobileNetV3-Large. تم تنفيذ التجارب على منصة Kaggle باستخدام معالج الرسوميات Tesla P100 GPU لضمان سرعة التدريب وكفاءة الأداء. وقد تم تدريب النماذج لعدد 5 دورات تدريبية (Epochs) مع استخدام مقاييس تقييم متعددة مثل Accuracy ودالة الفقد (Loss) ومصفوفة الالتباس (Confusion Matrix) لتقييم أداء النظام.

أولاً: اختبار كفاءة التدريب والاستجابة


عند بدء عملية التدريب، تم تقسيم البيانات إلى دفعات (Batches) بحجم 32 صورة لكل دفعة، مما ساعد على تحسين استقرار التدريب وتسريع عملية التعلم. كما ساهم استخدام المعالج الرسومي Tesla P100 في تقليل زمن التدريب وتحسين كفاءة المعالجة.



شكل 2: عينات عشوائية من تنبؤات النموذج على صور الاختبار مع توضيح نسبة الثقة لكل حالة.

أظهرت النتائج تحسناً سريعاً في دقة التحقق منذ بداية التدريب، حيث ارتفعت دقة النموذج من حوالي 81% في الدورة التدريبية الأولى إلى أكثر من 99% بعد خمس دورات تدريبية. ويعكس هذا التحسن قدرة نماذج التعلم العميق على تعلم الأنماط البصرية المرتبطة بالأمراض النباتية بسرعة وكفاءة. كما أظهرت نتائج المقارنة أن نموذج MobileNetV3-Large حقق أفضل أداء بدقة تحقق بلغت 99.31% مقارنة بـ 99.01% لنموذج EfficientNet-B3، بالإضافة إلى زمن تدريب أقل وعدد معاملات أصغر، مما يجعله أكثر ملاءمة للتطبيقات المحمولة.

يوضح الشكل (4) تطور أداء النموذجين أثناء عملية التدريب، حيث يبين الرسم الأول تغير دقة التحقق (Validation Accuracy) عبر الدورات التدريبية، بينما يوضح الرسم الثاني تغير قيمة الفقد (Validation Loss). نلاحظ أن كلا النموذجين حققا تحسناً تدريجياً في الدقة مع زيادة عدد الدورات التدريبية، مع انخفاض مستمر في قيمة الفقد، مما يدل على استقرار عملية التعلم. كما يتضح أن نموذج MobileNetV3-Large حقق دقة تحقق أعلى قليلاً في نهاية التدريب بلغت حوالي 99.31% مقارنة بنموذج EfficientNet-B3 الذي حقق 99.01%. وفي المقابل، أظهر نموذج EfficientNet-B3 قيمة فقد أقل في بعض المراحل، إلا أن الأداء الكلي من حيث الدقة كان لصالح نموذج MobileNetV3-Large، مما يدعم اختياره كنموذج نهائي للتطبيق المحمول.



شكل 3 : مقارنة دقة التحقق (Validation Accuracy) وقيمة الفقد (Validation Loss) بين نموذجي EfficientNet-B3 و MobileNetV3-Large خلال خمس دورات تدريبية.

ثانياً: اختبار دقة التصنيف لكل فئة (Class Accuracy):

يوضح الجدول رقم (2) نتائج أداء نموذجي EfficientNet-B3 و MobileNetV3-Large في تصنيف أمراض النباتات

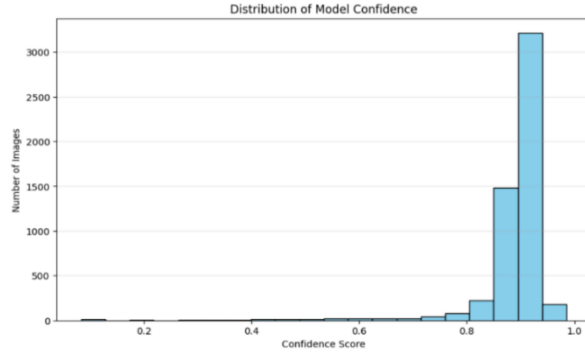
جدول 2 : نتائج أداء نموذج ntNet-B3 و MobileNetV3-Large في تصنيف الأمراض النباتية المختلفة

Class	Precision		Recall		F1-score		Support	
Grape Black rot	0.975	0.992	1.000	1.000	0.987	0.996	236	236
Grape Esca	1.000	1.000	0.982	0.993	0.991	0.996	276	276
Grape Leaf blight	1.000	1.000	1.000	1.000	1.000	1.000	215	215
Grape Healthy	1.000	0.988	1.000	1.000	1.000	0.994	84	84
Pepper Bacterial spot	1.000	0.995	1.000	0.995	1.000	0.995	200	200
Pepper Healthy	0.993	0.997	1.000	1.000	0.997	0.998	295	295
Potato Early blight	0.922	1.000	1.000	1.000	0.959	1.000	200	200
Potato Late blight	0.990	0.995	0.990	0.990	0.990	0.993	200	200
Potato Healthy	0.967	1.000	0.936	1.000	0.951	1.000	31	31
Tomato Bacterial spot	1.000	0.998	0.998	0.998	0.999	0.998	425	425
Tomato Early blight	0.976	0.926	0.995	0.995	0.985	0.959	200	200
Tomato Late blight	0.997	0.992	0.937	0.966	0.966	0.979	382	382
Tomato Leaf mold	0.995	1.000	0.995	0.989	0.995	0.995	191	191
Tomato Septoria leaf spot	0.994	0.989	0.992	0.986	0.993	0.987	354	354
Tomato Spider mites	0.991	0.991	0.982	0.997	0.987	0.994	335	335
Tomato Target spot	0.972	0.989	0.979	0.972	0.975	0.980	281	281
Tomato Yellow leaf curl virus	0.999	1.000	0.999	0.999	0.999	0.999	1071	1071
Tomato Mosaic virus	0.987	1.000	0.987	1.000	0.987	1.000	74	74
Tomato Healthy	0.991	0.997	1.000	1.000	0.995	0.998	318	318

باستخدام مقاييس Precision و Recall و F1-score لكل فئة. أظهرت النتائج أن كلا النموذجين حققا دقة مرتفعة جداً في تصنيف الأمراض النباتية، حيث بلغت الدقة الكلية 99.01% لنموذج EfficientNet-B3 و 99.31% لنموذج MobileNetV3-Large على مجموعة الاختبار التي تضم 5368 صورة. كما يتضح من النتائج أن العديد من الفئات حققت أداءً شبه مثالي، مثل Grape Leaf Blight و Pepper و Tomato Yellow Leaf Curl Virus و Healthy، حيث وصلت قيم Precision و Recall و F1-score إلى 1.00 تقريباً، مما يدل على قدرة النموذج على التعرف على هذه الأمراض بدقة عالية، خاصة عند توفر عدد كافٍ من الصور التدريبية. في المقابل، سجلت بعض الفئات قيماً أقل نسبياً، مثل Tomato Early Blight و Tomato Late Blight، حيث بلغ F1-score حوالي 0.96، وقد يرجع ذلك إلى التشابه البصري بين هذه الأمراض أو اختلاف ظروف الإضاءة والتصوير في بعض الصور. بشكل عام، أظهرت المقارنة أن نموذج MobileNetV3-Large تفوق بشكل طفيف على نموذج EfficientNet-B3 من حيث الدقة النهائية، إضافة إلى كفاءته الحاسوبية الأعلى، حيث يتطلب عدد معاملات أقل 4.2

رابعاً: اختبار الموثوقية وتوزيع الثقة (Confidence Distribution):

تم تحليل مستوى الثقة في تنبؤات النظام عند اختبار صور جديدة، وذلك من خلال حساب احتمالية التنبؤ لكل فئة باستخدام دالة Softmax. يوضح تحليل توزيع الثقة أن معظم تنبؤات النموذج كانت بمستوى ثقة مرتفع يتجاوز 95% في أغلب الحالات، مما يشير إلى قدرة النموذج على اتخاذ قرارات تصنيف دقيقة وثابتة. كما يدل ذلك على موثوقية النظام المقترح وإمكانية استخدامه كأداة دعم قرار لمساعدة المزارعين في الكشف المبكر عن أمراض النباتات واتخاذ الإجراءات المناسبة في الوقت المناسب.



شكل 6 : توزيع Confidence Score.

11. اختبار عينات طبيعية


أجريت عدة تجارب باستخدام الصور الموجودة في مجموعة التحقق (Validation Set)، وتم تسجيل البيانات الناتجة وتحليلها تحت ظروف مختلفة.

- في حالات الإصابة الواضحة، قدم النظام تشخيصاً فورياً بدقة كاملة.
- في حالات الإصابة المبكرة (بقع صغيرة)، نجح النموذج بفضل معمارية MobileNetV3-Large في رصد الأنماط الدقيقة التي قد تخفى على العين البشرية غير الخبيرة.

Original: Potato__Early_blight



Grad-CAM: Potato__Early_blight



شكل 7 : استخدام تقنية Grad-CAM لتفسير قرار النموذج بصرياً وتحديد مناطق الإصابة في ورقة البطاطا

أظهرت التجارب العملية أن النظام المقترح يعمل بكفاءة عالية في Real-time عند تحليل صور أوراق النباتات، حيث تم الحصول على النتائج التالية:

1. **الدقة العامة:** حقق نموذج MobileNetV3-Large أفضل أداء بدقة تصنيف بلغت 99.31% على مجموعة بيانات التحقق التي تضم 5368 صورة، مقارنة بدقة 99.01% لنموذج EfficientNet-B3.
2. **كفاءة التعلم:** أظهر النظام استقراراً واضحاً أثناء التدريب، حيث ارتفعت دقة التحقق من حوالي 81% في الدورة التدريبية الأولى إلى أكثر من 99% بعد خمس دورات تدريبية (Epochs).
3. **توزيع الثقة:** أظهر تحليل توزيع الثقة أن معظم تنبؤات النموذج كانت بمستوى ثقة يتجاوز 95%، مما يعزز موثوقية النظام كأداة دعم قرار للمزارعين.

4. **التطبيق العملي:** تم دمج النموذج النهائي MobileNetV3-Large داخل تطبيق محمول يحمل اسم Plant Doctor باستخدام إطار العمل Flutter لتوفير تشخيص فوري للأمراض النباتية.
5. **النشر والتوافر:** تم نشر التطبيق على منصات التوزيع مثل Google Play و Akure ليكون متاحًا للاستخدام العملي من قبل المزارعين والمهتمين بالزراعة.
- جدول 3: الإحصائيات النهائية للنموذج

Metric	Value
Accuracy	99.31%
Precision	99%
Recall	99%
F1-Score	99%
Model	MobileNetV3-Large

12. الاستنتاجات والتوصيات

من خلال تحليل نتائج التجارب وتقييم أداء النظام المقترح يمكن استخلاص ما يلي:

- تحقق الفرضية البحثية:** أثبتت النتائج أن استخدام تقنيات التعلم العميق ونقل التعلم في تحليل صور أوراق النباتات يساهم بشكل كبير في تحسين دقة وسرعة تشخيص الأمراض النباتية مقارنة بالطرق التقليدية.
 - تفوق MobileNetV3-Large:** أظهرت نتائج المقارنة أن نموذج MobileNetV3-Large حقق أفضل توازن بين الدقة والكفاءة الحاسوبية مقارنة بنموذج EfficientNet-B3، مما يجعله مناسبًا للتطبيقات المحمولة.
 - أهمية المعالجة المسبقة:** ساهمت تقنيات Data Augmentation في تحسين قدرة النموذج على التعميم وتقليل أخطاء التصنيف.
 - كفاءة التطبيق المحمول:** أثبت استخدام إطار العمل Flutter إمكانية دمج نماذج التعلم العميق داخل تطبيقات الهاتف المحمول وتوفير نظام تشخيص سريع وسهل الاستخدام.
- بناءً على نتائج البحث والتطبيق العملي لنظام Plant Doctor، يوصى بما يلي:

- تحسين جودة البيانات:** تدريب النماذج على صور حقيقية مأخوذة من الحقول الزراعية بدلاً من الاعتماد فقط على صور المختبرات.
- توسيع نطاق المحاصيل:** إضافة محاصيل جديدة وتوسيع قاعدة بيانات الأمراض لتشمل إصابات الجذور والثمار بالإضافة إلى الأوراق.
- إضافة تقنيات الكشف:** دمج تقنيات Object Detection لتحديد الأوراق المصابة تلقائيًا داخل صورة الحقل بالكامل.
- التنبؤات الزراعية الذكية:** تطوير نظام تنبيهات يعتمد على البيانات المجمعة من المستخدمين لإبلاغ المزارعين بانتشار أمراض معينة في مناطقهم الجغرافية.

المراجع

- [1] R. Yadav, A. Seth, A. Sharma, and M. Oza, "Plant Disease Identification Using Deep Learning and Transfer Learning," in Proceedings of the Seventh International Conference on Recent Trends in Image Processing and Pattern Recognition (RTIP2R-2024), Elsevier B.V., 2024.

- [2] U. Mishra, A. Pandey, L. G., and T. K., “Deep learning-based disease detection in potato and mango leaves: a comparative study of CNN, AlexNet, ResNet, and EfficientNet,” *Scientific Reports*, vol. 16, 2026.
- [3] Z. Zainab and R. Mahum, “Plant Disease Detection Using Deep Learning Techniques,” *ICCK Journal of Image Analysis and Processing*, vol. 1, no. 1, pp. 36–44, 2025.
- [4] M. Tan and Q. Le, “EfficientNet: Rethinking model scaling for convolutional neural networks,” in *Proceedings of the 36th International Conference on Machine Learning (ICML)*, vol. 97, pp. 6105–6114, 2019.
- [5] D. P. Hughes and M. Salathé, “An open access repository of images on plant health to enable the development of mobile disease diagnostics,” *arXiv preprint arXiv:1511.08060*, 2015.
- [6] A. Paszke et al., “PyTorch: An imperative style, high-performance deep learning library,” in *Advances in Neural Information Processing Systems*, vol. 32, pp. 8024–8035, 2019.
- [7] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, “Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization,” in *Proc. IEEE Int. Conf. on Computer Vision (ICCV)*, pp. 618–626, 2017.
- [8] J. Lu, L. Tan, and H. Jiang, “Review on Convolutional Neural Network (CNN) Applied to Plant Leaf Disease Classification,” *Agriculture*, vol. 11, no. 8, p. 707, 2021.
- [9] B. Tugrul, E. Elfatimi, and R. Eryigit, “Convolutional Neural Networks in Detection of Plant Leaf Diseases: A Review,” *Agriculture*, vol. 12, no. 8, p. 1192, 2022.
- [10] U. Atila, M. Uçar, K. Akyol, and E. Uçar, “Plant leaf disease classification using EfficientNet deep learning model,” *Ecological Informatics*, vol. 61, p. 101182, 2021.
- [11] T. D. Salka, M. B. Hanafi, S. M. S. A. Abdul Rahman, D. B. M. Zulperi, and Z. Omar, “Plant leaf disease detection and classification using convolution neural networks model: a review,” *Artificial Intelligence Review*, vol. 58, Art. no. 322, 2025.
- [12] M. S. Krishna, P. Machado, R. I. Otuka, S. W. Yahaya, F. Neves dos Santos, and I. K. Ihianle, “Plant Leaf Disease Detection Using Deep Learning: A Multi-Dataset Approach,” *J*, vol. 8, no. 1, p. 4, 2025, doi: 10.3390/j8010004.

Disclaimer/Publisher’s Note: The statements, opinions, and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of **JSHD** and/or the editor(s). **JSHD** and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions, or products referred to in the content.