

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

| | | |
|-----------|------------|-----------------------------|
| Received | 2026/05/01 | تم استلام الورقة العلمية في |
| Accepted | 2026/05/23 | تم قبول الورقة العلمية في |
| Published | 2026/05/24 | تم نشر الورقة العلمية في |

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

¹راضية سعيد العباسي، ²منصور محمد منصور

1- قسم الحاسب الآلي، كلية العلوم، جامعة طرابلس، ليبيا

2- قسم علوم الحاسب، كلية تقنية المعلومات، جامعة الزيتونة، ليبيا

Email: rad.alabassi@uot.edu.ly, m.mansur@azu.edu.ly

الملخص

يمكن ان تؤثر أمراض النبات بشكل كبير على الإنتاجية الزراعية إذا لم يتم تشخيصها مبكراً، وغالباً ما تكون الطرق التقليدية لتشخيص هذه الأمراض غير مجدية، وفي هذا الإطار تهدف هذه الدراسة لمعالجة التحديات وسد الفجوات البحثية من خلال اقتراح نهج فعال لكشف وتصنيف أمراض النبات قائم على الشبكات العصبية الالتفافية، تستكشف الدراسة أداء النموذج المدرب مسبقاً EfficientNet-B3 في مهمة كشف وتصنيف أمراض النباتات متعددة الفئات (38) فئة لصور أوراق نباتات سليمة ومصابة بأمراض مختلفة باستخدام New Plant Diseases Dataset المتحصل عليها من Kaggle. تقدم هذه الدراسة منهجية صارمة مبنية على دمج نموذج (EfficientNet-B3) واستراتيجية الضبط الدقيق التدريجي وخوارزمية التحسين AdamW وتقنيات التنظيم. ولتقييم هذه المنهجية EfficientNet-B3 استخدمت مقاييس التقييم المعيارية مثل Accuracy، F1 Score، Recall، Precision. أظهرت النتائج تفوق نموذج EfficientNetB3 على نماذج الدراسات السابقة والاساليب التقليدية محققاً دقة (99.92%) تصنيف شبه مثالي على بيانات التدريب والتحقق، وتشير النتائج إلى ان استراتيجية الضبط الدقيق التدريجي وخوارزمية التحسين AdamW وتقنيات التنظيم تحسن دقة النموذج وأدائه.

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجيات الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

الكلمات المفتاحية: أمراض النبات، الضبط الدقيق التدريجي، تقنيات التنظيم، تدريب النموذج.

Detection and classification of plant diseases using EfficientNet-B3 and Gradual Fine-Tuning strategy

Radhia S. A Labassi¹, Mansur M. Mansur²

1- Faculty of Science, University of Tripoli, Libya

2- Faculty of Information Technology, Al-Zaytuna University, Libya

Email: rad.alabassi@uot.edu.ly, m.mansur@azu.edu.ly

Abstract

Plant diseases pose a significant threat to agricultural productivity and the health of green plants if not accurately diagnosed at an early stage. Traditional disease detection methods are often time-consuming, costly, and insufficiently effective. Therefore, there is a growing need for advanced intelligent approaches capable of improving the accuracy and efficiency of plant disease diagnosis. In this context, this study addresses the challenges and research gaps in plant disease detection and classification using deep learning techniques, particularly Convolutional Neural Networks (CNNs). The study proposes an EfficientNet-B3-based model for multiclass plant disease detection and classification involving 38 categories of healthy and diseased plant leaves. The model was trained and evaluated using a publicly available plant disease dataset obtained from Kaggle. The proposed framework integrates the EfficientNet-B3 architecture with gradual fine-tuning strategies, the AdamW optimization algorithm, and regularization techniques to enhance classification performance and reduce overfitting. The performance of the proposed model was evaluated using several standard metrics, including Accuracy, Precision, Recall, F1-Score, and ROC-AUC Score. Experimental results demonstrated that the EfficientNet-B3 model achieved outstanding performance, attaining an accuracy of 99.92% on the training and validation datasets. The findings indicate that the combination of transfer learning, gradual fine-tuning, AdamW optimization, and regularization methods

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

significantly improves the robustness and effectiveness of the model compared with traditional approaches and previously reported studies.

Keywords: AdamW, Efficient Net B3, Gradual Fine Tuning, plant diseases.

1. المقدمة

شهدت السنوات الأخيرة تغير في المناخ وتفاقم تلوث الهواء مما أدى إلى ازدياد ظهور الأمراض النباتية مما يؤثر سلباً على الإنتاجية الزراعية ويهدد الأمن الغذائي، قد مكنت التطورات الحديثة في مجال التعلم العميق من التعرف الآلي على أمراض النباتات من خلال منهجيات متقدمة لتصنيف الصور. "وقد أظهرت بنى التعلم العميق وخاصة الشبكات العصبية الالتفافية (CNNs) كفاءة ملحوظة في تمييز الأنماط المعقدة داخل البيانات المرئية مما يجعلها فعالة للغاية في تصنيف أمراض النبات" [1]. ومن النماذج المتقدمة المبنية على الشبكات العصبية الالتفافية (CNNs) برزت عائلة Efficient Net التي تهدف إلى تحقيق توازن مثالي بين دقة النموذج وكفاءته الحسابية، ويُعد نموذج (EfficientNet-B3) أحد النماذج الفعالة التي تعتمد على مبدأ التحجيم المركب مما يجعله مناسباً لتطبيقات الرؤية الحاسوبية الزراعية. تسعى هذه الدراسة إلى توظيف هذا النموذج مدعوماً بتقنيات التنظيم واستراتيجية الضبط الدقيق التدريجي وخوارزمية التحسين AdamW لتطوير نظام ذكي قادر على كشف وتصنيف أمراض النباتات بدقة عالية.

2. مشكلة الدراسة:

لا تزال أمراض النباتات تشكل مصدر قلق للأمن الغذائي العالمي والاستدامة الزراعية إذ تُسهم في خسائر اقتصادية فادحة وتهدد غلة المحاصيل في جميع أنحاء العالم، ويُعدّ التشخيص المبكر والدقيق لأمراض أوراق النباتات أمراً بالغ الأهمية لمنع تفشيها على نطاق واسع والحد من الأضرار وتنفيذ التدخلات في الوقت المناسب.

مع التطور السريع في تقنيات الذكاء الاصطناعي والتعلم العميق أصبح من الممكن تطوير أنظمة آلية ذكية قادرة على التعرف على أمراض النباتات بدقة وسرعة من خلال تحليل

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

الصور الرقمية، إلا أن التحدي يكمن في اختيار وتطوير خوارزميات فعالة يمكنها التعامل مع تنوع الصور الزراعية والاختلاف في الإضاءة والبيئة وجودة الصور إضافة إلى الحاجة إلى نماذج تتميز بالدقة العالية والقدرة على التعميم.

ومن هنا تتمحور مشكلة هذه الدراسة حول السؤال الرئيسي الآتي:

✓ كيف يمكن بناء نموذج ذكي يعتمد على الشبكات العصبية الالتفافية (CNN) قادر على كشف وتصنيف أمراض النباتات بدقة عالية باستخدام الصور الرقمية مع تقليل مشكلة الإفراط في التكيف وتحسين عملية التدريب باستخدام خوارزميات التحسين الحديثة مثل (AdamW) وتقنيات واستراتيجيات لم تستخدم مسبقاً في هذا المجال؟.

3. أهمية الدراسة: تتجلى أهمية هذه الدراسة في الجوانب التالية:

- توظيف تقنيات التعلم العميق الحديثة في المجال الزراعي.
- دمج نموذج Efficient NET-B3 مع استراتيجية الضبط الدقيق التدريجي وخوارزمية التحسين AdamW لتحسين أداء النموذج.
- دراسة تأثير استراتيجية الضبط الدقيق التدريجي وخوارزمية التحسين AdamW وتقنيات التنظيم.

4. أهداف الدراسة:

تهدف هذه الدراسة إلى تحقيق الأهداف التالية:

- تصميم نظام فعال يعتمد على (Efficient NET-B3) لكشف وتصنيف أمراض النباتات.
- تطبيق استراتيجية الضبط الدقيق التدريجي لتحسين قدرة النموذج على التعميم.
- استخدام خوارزمية التحسين (AdamW) لتحسين استقرار عملية التدريب.
- مقارنة نتائج هذا النموذج بنتائج الدراسات السابقة.

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

5. حدود الدراسة:

تقتصر هذه الدراسة على:

- استخدام صور رقمية لأوراق بعض النباتات فقط.
- مجموعة محددة من أمراض النباتات وفقاً لبيانات التدريب المتاحة.
- التقييم ضمن بيئة تجريبية محددة من حيث العتاد والبرمجيات.

6. الدراسات السابقة:

انخرط العديد من الباحثين في استكشاف الكشف عن أمراض النباتات وتصنيفها باستخدام بنى التعلم العميق واساليبه لإثبات فعاليته ويهدف الباحثون في المساهمة في تطوير هذه الأساليب للكشف السريع والفوري عن أمراض النباتات وتصنيفها، مما قد يؤدي إلى تحسين الإنتاجية الزراعية. قدّم Chowdhury وآخرون في سنة 2023 دراسة حول اكتشاف أمراض أوراق النبات وتصنيفها باستخدام التعلم العميق بحيث اقترح نموذجاً تقليدياً للكشف عن أمراض النبات، تم تدريب النموذج على مجموعة بيانات لأوراق النبات المتاحة على Kaggle، والتي تضم 17,430 صورة لأوراق النباتات مصنفة ل 14 فئة (سليمة ومصابة)، استخدم شبكة CNN التقليدية للتدريب على كشف أمراض النباتات وتصنيفها وتم تقييم أداء النموذج باستخدام مقاييس الأداء العالمية بحيث حقق النموذج دقة بلغت (85.31%) بعد 150 دورة تدريبية [2]. وأجرى Guo في سنة 2023 دراسة حول الكشف عن أمراض أوراق النباتات استكشفت هذه الدراسة طريقة للكشف عن أمراض الأوراق من خلال تدريب نموذج الشبكات العصبية الالتفافية (CNNs) على مجموعة بيانات مفتوحة المصدر، تم الحصول عليها من Kaggle تم تغذية بيانات التدريب وبيانات الاختبار إلى بنية الشبكة العصبية التلافيفية (CNNs) للتدريب بعد 30 دورة تدريبية، حقق النموذج دقة بلغت 92.23% مع خسارة نهائية قدرها 0.2683 [3]. وقدّم Damasevicius وآخرون في سنة 2024 دراسة حول أداء تقنيات التعلم العميق في الكشف عن أمراض الأوراق، استخدمت الدراسة أربعة نماذج مُدرّبة مسبقاً تعتمد على الشبكات العصبية الالتفافية (CNNs): الشبكة العصبية الالتفافية (CNN)،

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

Inception-V3، DenseNet-121، VGG-16، مجموعة البيانات المستخدمة في هذه الدراسة متاحة للعموم ومأخوذة من منصة Kaggle1، استُخدمت الدراسة مقاييس الأداء لتقييم النماذج الأربعة (CNN و DenseNet-121 و VGG-16 و Inception-V3) على أربعة مصنفات البكتيريا والفطريات والفيروسات وأوراق النباتات السليمة، ظهرت النتائج الاجمالية أداء أفضل لنموذج Inception V3 بدقة بلغت 95.5%، بالإضافة إلى أداء Dense Net121 بدقة بلغت 94.4%، كما كان أداء VGG16 بدقة 93.3%، وحقت CNN التقليدية دقة بلغت 91.9% [4]. كما اقترح Rabbi وآخرون في سنة 2025 إطار عمل جديد قائماً على التعلم العميق للكشف الآلي عن أمراض أوراق النبات وتصنيفها باستخدام بنى شبكات عصبية التلافيفية مخصصة (Custom CNN) استخدمت مجموعات البيانات هما Plant Village و Plant Doc تشمل 61486 صورة لأوراق النباتات السليمة والمصابة تضم عدد فئات 39 فئة من الأمراض النباتية، قدمت الدراسة إطار عمل متقدم للتعلم العميق لتحديد أمراض النباتات آلياً باستخدام بنى شبكات عصبية تلافيفية مخصصة، حقق النموذج المقترح أداءً استثنائياً بدقة 96% [5]. كما اقترحت princy وآخرون في سنة 2025 دراسة عن نظام تصنيف أمراض النبات باستخدام تقنيات التعلم العميق قدمت هذه الدراسة نظاماً لتصنيف أمراض النبات قائماً على الشبكات العصبية التلافيفية (CNN) معتمدة على نموذج مُدرَّب مسبقاً ResNet50 مدرب على مجموعة بيانات Plant Village، تضمنت 54300 صورة لعينات سليمة ومصابة لأوراق النباتات خضعت الصور للمعالجة المسبقة تم تقسيم مجموعة البيانات بنسبة إلى 70% للتدريب و30% للاختبار، استخدمت خوارزمية التحسين Adam لتحسين أداء النموذج، خضع نموذج (ResNet50) للتدريب لمدة 15 دورة تدريبية مع تقنية الإيقاف المبكر تم تقييم الأداء باستخدام مصفوفة الارتباك ومقاييس التقييم حقق النموذج دقة بلغت 95%، مما يُظهر فعاليته في الكشف الآلي عن أمراض النبات [1]. قاموا الباحثون بعرض انظمة الكشف عن أمراض النبات المختلفة وقاموا بتقييم دقتها، كما ناقشوا أوجه القصور والتحديات التي واجهتها هذه الأنظمة وبناءً لقصور الدراسات السابقة والتحديات التي واجهتها، تقترح الدراسة الحالية منهجية فعالة وصارمة

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

مبنية على نموذج EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي وخوارزمية التحسين AdamW إضافة إلى تقنيات التنظيم حلا لهذه التحديات.

7. المنهجية:

1.7. مفاهيم المنهجية:

1.1.7. **التعلم بالنقل (Transfer Learning):** يُعدّ التعلّم بالنقل منهجًا متعدد الاستخدامات في التعلّم العميق، فهو يطبّق المعرفة من مجال مصدر غنيّ بالبيانات الموثّقة وكذلك فعّال من حيث استغلال الموارد إذ يوفّر الوقت والجهد اللذين كانا سيُبدلان في جمع البيانات وتصنيفها في مجال الهدف [6].

2.1.7. **مفهوم Efficient Net-B3:** هو احد اصدارات عائلة Efficient Net التي طورتها Google Research، تستخدم شبكة Efficient Net تقنية متطورة لتوسيع نطاق نموذج الشبكة العصبية الالتفافية (CNN). يعتمد نموذج Efficient Net-B3 على تقنية مُبتكرة تسمى التحجيم المُركب Compound Scaling والتي تعمل على موازنة ثلاثة ابعاد أساسية للشبكة العصبية العمق (Depth) عدد الطبقات، العرض (Width) عدد المرشحات في كل طبقة ودقة الصورة المدخلة (Resolution)، يحتوي هذا النموذج على عدد كبير من المرشحات لكل طبقة ودقة مكانية أعلى لخرائط الميزات ولذلك يستطيع النموذج النقاط تفاصيل أدق في الصور المدخلة، يستخدم Efficient Net B3 الالتفافات القابلة للفصل العميق لتقليل التعقيد الحسابي [7].

3.1.7. استراتيجية الضبط الدقيق والضبط الدقيق التدريجي:

يشير الضبط الدقيق إلى إعادة تدريب بعض طبقات النموذج المدرب مسبقًا ليتناسب مع المهمة الجديدة مع الحفاظ على المعرفة المكتسبة سابقًا، في الضبط الدقيق التدريجي يتم فك تجميد الطبقات تدريجيًا واستخدام معدل تعلم منخفض وتحسين استقرار التدريب وتقليل الافراط في التكيّف [8].

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

4.1.7. خوارزمية التحسين AdamW: هي نسخة محسنة من Adam حيث تفصل بين تحديث الأوزان و Weight Decay مما يؤدي إلى تحسين التعميم واستقرار التدريب [9].

5.1.7. المقاييس المعيارية لتقييم أداء النموذج:

لتقييم كفاءة النموذج المقترح تم اعتماد مجموعة من مقاييس الأداء الشائعة والمعتمدة في مجال التعلم العميق:

- **Accuracy** الدقة: نسبة الحالات المصنفة بشكل صحيح من قبل النموذج إلى إجمالي عدد التنبؤات، يمكن استخدامها لاستخلاص مقياس الدقة.
 - **Recall الاستدعاء**: هو نسبة العناصر الإيجابية الحقيقية مقسومة على إجمالي عدد الوحدات المصنفة إيجابياً (مجموع الصفوف للعناصر الإيجابية الفعلية). أما العناصر السلبية الخاطئة فهي تلك التي صنفتها النموذج على أنها سلبية، بينما هي في الواقع إيجابية.
 - **Precision ضبط الدقة**: هي مقياس إحصائي يعكس نسبة التحديدات الإيجابية الحقيقية إلى إجمالي التحديدات الإيجابية المُبلغ عنها.
 - **F1 Score**: يقوم مقياس F1 بتقييم أداء نموذج التصنيف انطلاقاً من مصفوفة الارتباك، حيث يجمع بين مقياسي الدقة والاستدعاء تحت مفهوم المتوسط التوافقي.
- [10]

2.7. بنية EfficientNet-B3:

1. طبقة الإدخال: حجم إدخال الصورة 300×300 بكسل، وأبعادها تساوي 3.
2. طبقة Conv2D أولية: مرشحات 32 ونواة 3×3 و Stride بقيمة 3 تليها تطبيع دفعي و ReLU.
3. كتل MBConv مكررة (26 كتلة التفاف)، طبقة التفاف مع تنشيط التطبيع الدفعي بعد كل التفاف.
4. pooling طبقة تجميع تأخذ متوسط كل خريطة ميزات عبر الأبعاد المكانية.
5. Dropout (نسبة التسرب = 0.3) ، تستخدم لتقليل الإفراط في التكيّف عن طريق

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

حذف الخلايا العصبية عشوائياً أثناء التدريب بمعدل 0.3.

6. طبقة التصنيف Fully Connected للإخراج النهائي.

عدد الوحدات = عدد الفئات حسب الفئة [11]

3.7. وصف مجموعة البيانات Data Set:

تم استخدام مجموعة بيانات New plant Diseases Data Set، وهي مجموعة بيانات من معيارية ضخمة تم الحصول عليها من Kaggle، تحتوي على 87860 صورة مصنفة إلى 38 فئة تشمل (14) نوع من النباتات سليمة ومصابة بأمراض مختلفة مثل (جرب التفاح، اللبحة المبكرة للطماطم والبطاطا، فيروس تجعد الأوراق الصفراء في الطماطم و.....).

4.7. تقسيم مجموعة البيانات:

تم تقسيم البيانات إلى مجموعات تدريب وتحقق واختبار باستخدام دالة train test split، هنا تم استخدام 80% للتدريب و20% بين التحقق والاختبار، جميع الصور في مجموعة البيانات بأبعاد $3 \times 256 \times 256$ مما يعني أن عرض كل صورة وارتفاعها 256 بثلاث قنوات تمثل تنسيق (RGP)، ثم تم تغيير حجم هذه الصور وفقاً لمتطلبات الشبكة، تم عرض الصور النموذجية المتاحة لكل نوع من النباتات في شكل (1).



شكل (1) صور عينات لأنواع من النباتات

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي


<http://www.doi.org/10.62341/istj-vol38-2-rm24>

8. المعالجة المسبقة للبيانات (Data Pre Processing):

تم تحديد مسار مجموعتي التدريب والتحقق لمجموعة بيانات أمراض النباتات والتحقق من سلامة تنظيمها قبل تدريب النموذج، حيث تم استخراج أسماء الفئات من كلا المجلدين والتأكد بشكل صارم من تطابقها باستخدام عبارة تحقق (assert)، تم حساب عدد الصور لكل فئة في مجموعتي التدريب والتحقق وعدد الفئات المستخدمة. ثم التوزيع العددي للفئات داخل مجموعة البيانات وذلك بترتيب الفئات ترتيب تنازلي حسب عدد الصور، يساعد فهم توزيع البيانات في ضبط استراتيجية التدريب واختيار تقنيات التنظيم المناسبة لتحسين القدرة التعميمية للنموذج كما في الشكل (2). من خلال الشكل 2 نلاحظ البيانات الموجودة في التدريب تعتبر في نفس النطاق وكذلك بيانات التحقق وهنا لا يوجد تحيز في البيانات فكل البيانات في نطاق واحد وهذا ما يجعل النموذج يتعلم على كل البيانات دون تحيز لأي نوع من البيانات. بعد تحديد مسارات مجلدات التدريب والتحقق لمجموعة بيانات أمراض النباتات، تم تنظيم الصور داخل مجلدات فرعية تمثل الفئات التصنيفية وما يتوافق مع آلية التحميل المعتمدة في مكتبة torch vision. dataset. Image Folder. بعد ذلك تم تحديد حجم الصورة (IMAGE – SIZE = 300) بما يتوافق مع متطلبات الإدخال لنموذج (EfficientNET-B3)، إذ يعتمد هذا النموذج على صور بدقة (300×300) بكسل لتحقيق التوازن بين الدقة والتكلفة الحسابية.

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>



شكل (2) التوزيع العددي للفئات

كما تم تحديد حجم الدفعة (BATCH SIZE=32) للتحكم في عدد العينات التي تعالج في كل خطوة تدريبية، بالإضافة إلى ذلك تم تحديد حجم مجموعة الاختبار (TEST SPLIT SIZE= 5700) لضمان تخصيص عدد ثابت من الصور لعملية التقييم النهائي، فيما يخص بيئة التنفيذ، تم التحقق من توفر وحدة معالجة الرسومات (GPU) واختيارها تلقائياً في حال توفرها، أو الاعتماد على (CPU) في حال عدم توفر (GPU) ويسهم هذا التحديد الديناميكي للجهاز في تحسين الكفاءة الزمنية للتدريب. كم تم ضبط معلمات إضافية مثل (pin-memory ، persistent، num- workers) لتحسين سرعة تحميل البيانات عند استخدام (GPU)، وذلك من خلال تسريع نقل البيانات من الذاكرة الرئيسية إلى ذاكرة (GPU) وتنفيذ عمليات التحميل بشكل متوازٍ. ثم تم تعريف قاموس (data-transforms) الذي يحتوي على عمليات المعالجة المسبقة لكل من بيانات التدريب وبيانات التقييم، في مرحلة التدريب تطبق عمليات إعادة تحجيم الصور (Resizing) إلى الحجم المطلوب، إلى جانب تطبيق تقنيات زيادة البيانات مثل

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

التدوير (Rotation) بزواوية (15 درجة) والتقليب (Flipping) قلب الصور أفقياً بشكل عشوائي بنسبة 50%، وذلك بهدف تعزيز التنوع داخل البيانات وتقليل فرط التكيف أما في مرحلة التقييم تم الاكتفاء بإعادة التحجيم والتطبيع دون زيادة بيانات، لضمان تقييم أداء النموذج على صور غير معدلة، وفي كلتا الحالتين، تم تحويل الصور إلى تمثيل عددي (Tensor) وتطبيقها باستخدام احصائيات مجموعة (Image NET)، بما يضمن توافق البيانات مع الأوزان المدربة مسبقاً لنموذج (EfficientNET-B3)، ثم تم تنظيم عملية تحميل البيانات على شكل دفعات وتم في هذه المرحلة التحقق من جاهزية خط أنابيب البيانات قبل البدء في تدريب نموذج (EfficientNET-B3) كما في جدول (1).

جدول 1 يوضح تنظيم عملية تحميل البيانات على شكل دفعات

| مجموعة البيانات | عدد البيانات | الدفعات (32) |
|-----------------|--------------|--------------|
| التدريب | 70295 | 2197 |
| التحقق | 11872 | 371 |
| الاختبار | 5700 | 179 |

يسهم هذا العرض في تقدير الزمن الحسابي لكل دورة تدريبية وضمان سلامة تقسيم البيانات، كما تم استخراج أسماء الفئات وخريطة الربط بين الفئات والمعرفات الرقمية (Class to index Mapping) والتي يعتمد عليها النموذج أثناء عملية التصنيف، مما يضمن الاتساق بين التدريب والتقييم ويُسهل توثيق البنية النهائية لمجموعة البيانات المستخدمة.

9. دالة الخسارة (Loss Function): ضمن إطار إعداد عملية التدريب للنموذج المقترح، تم اعتماد دالة الخسارة من نوع (Cross Entropy Loss)، وذلك من خلال التعريف البرمجي للدالة:

$$\text{criterion} = \text{nn. (CrossEntropyLoss)}$$

والتي تُعد من أكثر دوال الخسارة استخداماً في مهام التصنيف متعدد الفئات.

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

10. تدريب النموذج (Training Function):

تم في هذه الدراسة تصميم دالة مخصصة لتدريب النموذج العميق وإدارته عبر عدد الدورات التدريبية، مع تضمين آليات متقدمة مثل التحقق المتقاطع (Cross Validation)، وجدول معدل التعلم (Learning Rate Scheduler) والإيقاف المبكر ومعدل التعلم وذلك لضمان تحقيق أفضل أداء ممكن مع الحد من ظاهرة الإفراط في التكيف، تحمل هذه الدالة اسم `train_model`، وتعد المحور الأساسي لمرحلة التدريب التجريبي للنموذج.

✓ استراتيجية الضبط الدقيق التدريجي لتدريب النموذج:

اعتمدت هذه الدراسة منهجية الضبط الدقيق التدريجي في تدريب نموذج EfficientNet-B3 بهدف تحقيق توازن فعال بين الاستفادة من المعرفة المسبقة للنموذج المدرب على ImageNet وتكييفه تدريجياً مع طبيعة البيانات الخاصة بمشكلة الدراسة، وقد تم تنفيذ عملية التدريب على ثلاث مراحل متتابعة لكل مرحلة هدف تدريبي ومعدل تعلم مختلف بما يضمن استقرار عملية التعلم وتحسين قابلية التعميم.

✓ المرحلة الأولى: استخلاص الخصائص (Feature Extraction – Head Only)

في هذه المرحلة تم اعتماد أسلوب استخلاص الخصائص فقط حيث تم تجميد جميع أوزان النموذج الأساسية لمنع تحديثها أثناء التدريب والاكتماء بتدريب طبقة التصنيف النهائية (Classifier) فقط، وذلك لأن الطبقات الالتفافية العميقة في EfficientNet-B3 تكون قد تعلمت بالفعل خصائص عامة قوية مثل الحواف والقوام والأشكال الأساسية ولا حاجة لتعديلها في هذه المرحلة المبكرة ثم بعد ذلك إتاحة التعلم لطبقة التصنيف النهائية فقط باعتبارها طبقة مضافة حديثاً ولم تخضع للتدريب المسبق، ولتسريع عملية تعلم هذه الطبقة تم استخدام خوارزمية AdamW بمعدل تعلم مرتفع نسبياً بقيمة $(1e-3)$ مما يسمح للنموذج بالتكيف السريع مع عدد الفئات الخاصة بالدراسة، استخدمت هذه المرحلة لعدد محدود من الدورات التدريبية مع تفعيل آلية الإيقاف المبكر وذلك لتجنب الإفراط في التدريب على طبقة التصنيف وحدها، وتمثل نتائج هذه المرحلة نقطة انطلاق أساسية للمراحل اللاحقة من الضبط التدريجي.

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

✓ المرحلة الثانية: الضبط الدقيق للطبقات العليا (Fine-Tuning Top Layers)

بعد استقرار طبقة التصنيف انتقلت عملية التدريب إلى المرحلة الثانية والتي تهدف إلى تكيف الخصائص عالية المستوى للنموذج مع طبيعة البيانات المدروسة، في هذه المرحلة فك تجميد آخر كتلتين التفاضليتين (5 و6) من نموذج EfficientNet-B3 وهما الكتل الأقرب إلى طبقة الإخراج والتي تكون مسؤولة عن استخلاص الخصائص المتقدمة والمجردة المرتبطة مباشرة بمهمة التصنيف، تم تدريب هذه الأجزاء المفكوكة حديثاً باستخدام معدل تعلم اقل من المرحلة الأولى بقيمة $(1e-4)$ وذلك للحفاظ على المعرفة المكتسبة مسبقاً ومنع التغييرات الجذرية في الأوزان، كما تم استخدام جدول معدل التعلم من نوع ReduceLRonPlateau والذي يقوم بتقليل معدل التعلم تلقائياً عند ثبات أو تدهور أداء التحقق مما يساعد النموذج على الوصول إلى نقطة تقارب أفضل، ومن الجدير بالذكر أنه تم تمرير أفضل قيمة خسارة تحقق من المرحلة الأولى إلى هذه المرحلة بهدف ضمان التحسين التراكمي للأداء وعدم فقدان أفضل حالة للنموذج أثناء الانتقال بين المراحل.

✓ المرحلة الثالثة: الضبط الشامل للنموذج (Fine-Tuning All Layers)

في المرحلة الثالثة والأخيرة تم فك تجميد جميع طبقات النموذج بما في ذلك الطبقات الالتفافية الدنيا ليصبح النموذج بأكمله قابلاً للتحديث، وتهدف هذه المرحلة إلى إجراء ضبط دقيق شامل يسمح بتكيف الخصائص العامة والخاصة معاً بما يتلاءم بدقة مع طبيعة البيانات المستهدفة نظراً لحساسية هذه المرحلة واحتمالية فقدان المعرفة المسبقة تم اعتماد معدل تعلم منخفض جداً بقيمة $(1e-5)$ مما يضمن تحديث الأوزان بشكل تدريجي ومحسوب كما تم الاستمرار باستخدام جدول معدل التعلم وآلية الإيقاف المبكر لضمان استقرار عملية التدريب ومنع الإفراط في التكيّف، و تم تمرير أفضل قيمة خسارة تحقق من المرحلة الثانية إلى هذه المرحلة بما يضمن استمرارية التحسين والوصول إلى أفضل نسخة ممكنة من النموذج النهائي.

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

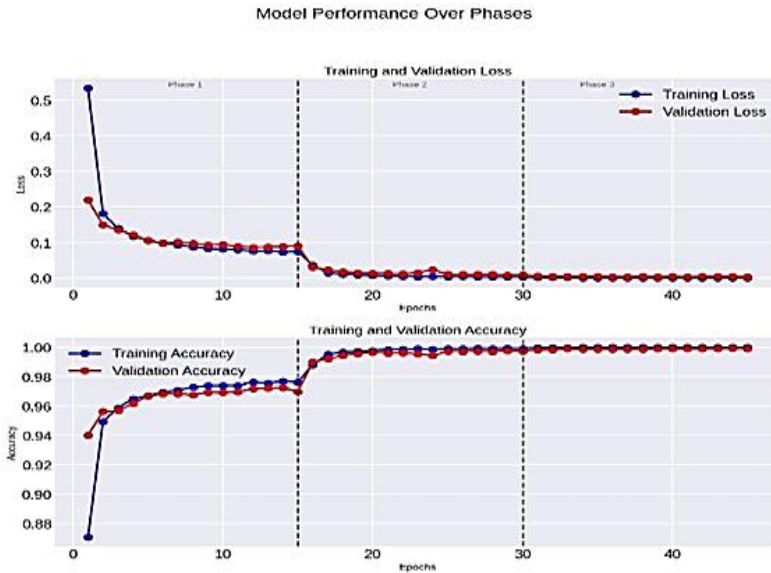
<http://www.doi.org/10.62341/istj-vol38-2-rm24>

11. مرحلة التحقق (Validation Phase):

عقب الانتهاء من مرحلة التدريب لكل دورة يتم تحويل النموذج إلى وضع التقييم لتعطيل الطبقات التي تؤثر على السلوك الاحتمالي للنموذج، ثم أجريت عملية التحقق باستخدام مجموعة البيانات المخصصة لذلك دون حساب التدرجات مما يقلل من استهلاك الذاكرة ويسرع العملية خلال مرحلة التحقق تم حساب خسارة التحقق ودقة التصنيف بنفس الآلية المستخدمة في التدريب ولكن دون تحديث اوزان النموذج وتمثل هذه القيم مؤشراً موضوعياً على قدرة النموذج على التعميم على بيانات غير مرئية.

12. النتائج والمناقشات:

✓ تتبع أداء النموذج عبر مراحل التدريب: يوضح الشكل (3) التطور الزمني لأداء النموذج المقترح من حيث الخسارة (Loss) والدقة (Accuracy) لكل من بيانات التدريب وبيانات التحقق وذلك عبر الدورات التدريبية المختلفة وضمن إطار منهجية التدريب متعددة المراحل المعتمدة في هذه الدراسة.



شكل (3) تتبع أداء النموذج عبر مراحل التدريب

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

نلاحظ في المرحلة الأولى (Phase 1) والتي تم فيها تدريب طبقات التصنيف فقط مع تجميد الطبقات الالتفافية الأساسية انخفاضاً تدريجياً في خسارة التدريب يقابله تحسن ملحوظ في الدقة مع تقارب واضح بين منحنيي التدريب والتحقق، ويشير هذا السلوك إلى أن النموذج استطاع الاستفادة من الميزات المستخرجة مسبقاً دون الوقوع في مشكلة فرط التكيف مما يؤكد ملاءمة هذه المرحلة كخطوة تهيئة أولية للنموذج.

عند الانتقال إلى المرحلة الثانية (Phase 2) حيث تم فك تجميد عدد محدود من الطبقات العليا وتطبيق الضبط الدقيق التدريجي يُلاحظ تحسن إضافي في الأداء يتجلى في انخفاض أكبر في خسارة التحقق وارتفاع متزامن في الدقة، يعكس هذا التحسن قدرة النموذج على تكيف الميزات العميقة مع خصائص بيانات الدراسة والحفاظ على استقرار عملية التعلم مع عدم حدوث تقلبات حادة في المنحنيات.

أما في المرحلة الثالثة (Phase 3) والتي شملت الضبط الدقيق الكامل للنموذج فتُظهر المنحنيات استقراراً عاماً في الأداء مع تحسن طفيف ومحدود، يُفسر ذلك بأن النموذج قد بلغ حالة شبه تقارب (Convergence) حيث أصبحت التحسينات اللاحقة هامشية وهو مؤشر إيجابي على نضج عملية التعلم وعدم الإفراط في تعديل الأوزان.

من خلال مقارنة منحنيات التدريب والتحقق عبر المراحل الثلاث يُلاحظ عدم وجود فجوة كبيرة بينهما الأمر الذي يدل على القدرة الجيدة للنموذج على التعميم و يؤكد فاعلية تقنيات التنظيم المستخدمة أثناء التدريب، كما تبرز أهمية تقسيم عملية التدريب إلى مراحل واضحة إذ أتاح ذلك تحكماً أفضل في عملية التعلم وقلل من مخاطر عدم الاستقرار التي قد تنتج عن الضبط الدقيق الكامل المبكر، أظهرت نتائج المراحل التدريبية الثلاث فاعلية واضحة للاستراتيجية المعتمدة في تحسين أداء النموذج وتعزيز قدرته على التعميم مع الحد من ظاهرة الإفراط في التكيف.


✓ مصفوفة الارتباك (Confusion Matrix):

نلاحظ في الشكل (4) لمصفوفة الارتباك أداءً استثنائياً للنموذج على 38 فئة مختلفة من النباتات السليمة والمصابة، كما نلاحظ الأرقام في المربعات الزرقاء متقاربة (تتراوح 133 إلى 164) مما يدل على أن بيانات مجموعة الاختبار متوازنة (Balanced)

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

(Dataset)، و تشير مصفوفة الارتباك إلى أن النموذج يتمتع بمعدل إيجابيات كاذبة FPR منخفض جداً يقترب من الصفر مما يدل على الموثوقية التنبؤية Precision تصل إلى 99.9% نادراً ما يفشل النموذج في رصد المرض حيث حقق Recall نسبة 99.8% ومعدل خطأ Error rate أقل بكثير من 0.01 مما يدل على أن النموذج قادر على التمييز بين أنواع النباتات المختلفة السليمة والمصابة بدقة متناهية مع عدم وجود تحيز (bias) لفئة معينة .



شكل 4 تتبع أداء النموذج عبر مراحل التدريب

✓ نتائج التقييم لكل فئة (Metrics Per class):

تم حساب مقاييس الأداء لكل فئة والتي تشمل Precision و Recall و F1 score بالإضافة الى قيم الدعم (Support) والتي تمثل عدد العينات الفعلية لكل فئة داخل مجموعة التحقق لتقييم قدرة النموذج على التمييز بين الامراض المختلفة ، و تشير النتائج

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

إلى أن النموذج حقق أداءً متوازناً عبر معظم الفئات حيث سجل قيم مرتفعة لمقياس F1score مما يعكس قدرة النموذج الفعالة على التمييز بين الأمراض المختلفة، كما تُظهر قيم Recall المرتفعة قدرة النموذج على اكتشاف الحالات المرضية بشكل دقيق، في حين تعكس قيم Precision انخفاض معدل التصنيفات الخاطئة و نظراً لأن مجموعة البيانات المستخدمة في هذه الدراسة تم موازنتها نسبياً من حيث عدد العينات لكل فئة فقد كانت قيم Macro Average و Weighted Average متطابقة و يشير ذلك إلى أن أداء النموذج متوازن عبر جميع الفئات دون تحيز لفئة معينة أي أن النموذج حقق أداءً مرتفعاً جداً على جميع الفئات بشكل عادل.

| | precision | recall | f1-score | support |
|-----------------------------------|-----------|--------|----------|---------|
| Apple__Apple_scab | 1.00 | 1.00 | 1.00 | 164 |
| Apple__Black_rot | 1.00 | 1.00 | 1.00 | 161 |
| Apple__Cedar_apple_rust | 1.00 | 1.00 | 1.00 | 143 |
| Apple__healthy | 1.00 | 1.00 | 1.00 | 163 |
| Blueberry__healthy | 1.00 | 1.00 | 1.00 | 147 |
| __Powdery_mildew | 1.00 | 1.00 | 1.00 | 137 |
| Cherry_including_sour_healthy | 1.00 | 1.00 | 1.00 | 148 |
| Gray_leaf_spot | 0.99 | 1.00 | 1.00 | 133 |
| Corn_(maize)__Common_rust | 1.00 | 1.00 | 1.00 | 155 |
| Corn_(maize) Northern_Leaf_Blight | 1.00 | 0.99 | 1.00 | 155 |
| Corn_(maize)__healthy | 1.00 | 1.00 | 1.00 | 151 |
| Grape__Black_rot | 1.00 | 1.00 | 1.00 | 153 |
| Grape_Esca (Black_Measles) | 1.00 | 1.00 | 1.00 | 156 |
| Grape_Leaf_blight_Leaf_Spot) | 1.00 | 1.00 | 1.00 | 140 |
| Grape__healthy | 1.00 | 1.00 | 1.00 | 137 |
| Orange_(Citrus_greening) | 1.00 | 1.00 | 1.00 | 163 |
| Peach__Bacterial_spot | 1.00 | 1.00 | 1.00 | 149 |
| Peach__healthy | 1.00 | 1.00 | 1.00 | 140 |
| Pepper,_bell__Bacterial_spot | 1.00 | 1.00 | 1.00 | 155 |
| Pepper,_bell__healthy | 0.99 | 1.00 | 1.00 | 161 |
| Potato__Early_blight | 1.00 | 1.00 | 1.00 | 157 |

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق
التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

| | | | | |
|-----------------------------|------|------|------|------|
| Potato__Late_blight | 1.00 | 1.00 | 1.00 | 157 |
| Potato__healthy | 1.00 | 1.00 | 1.00 | 148 |
| Raspberry__healthy | 1.00 | 1.00 | 1.00 | 144 |
| Soybean__healthy | 1.00 | 1.00 | 1.00 | 164 |
| Squash__Powdery_mildew | 1.00 | 1.00 | 1.00 | 141 |
| Strawberry__Leaf_scorch | 1.00 | 1.00 | 1.00 | 144 |
| Strawberry__healthy | 1.00 | 1.00 | 1.00 | 148 |
| Tomato__Bacterial_spot | 1.00 | 1.00 | 1.00 | 138 |
| Tomato__Early_blight | 1.00 | 1.00 | 1.00 | 156 |
| Tomato__Late_blight | 1.00 | 0.99 | 0.99 | 150 |
| Tomato__Leaf_Mold | 1.00 | 1.00 | 1.00 | 152 |
| Tomato__Septoria_leaf_spot | 1.00 | 1.00 | 1.00 | 141 |
| Two-spotted_spider_mite | 1.00 | 1.00 | 1.00 | 141 |
| Tomato__Target_Spot | 1.00 | 1.00 | 1.00 | 148 |
| Tomato_Yellow_Leaf | 1.00 | 1.00 | 1.00 | 159 |
| Tomato__Tomato_mosaic_virus | 1.00 | 1.00 | 1.00 | 145 |
| Tomato__healthy | 0.99 | 1.00 | 1.00 | 156 |
| accuracy | | | 1.00 | 5700 |
| macro avg | 1.00 | 1.00 | 1.00 | 5700 |
| weighted avg | 1.00 | 1.00 | 1.00 | 5700 |

13. التنبؤ باستخدام بيانات اختبار خارجية:

يمثل هذا الجزء من العمل المرحلة النهائية لتقييم النموذج المقترح، حيث تم اختبار النموذج المدرب على مجموعة اختبار خارجية من مجلد خارجي ضمن مجلدات مجموعة البيانات (New Plant Diseases Dataset) تحتوي مجموعة الاختبار الخارجية على 33 صورة عشوائية غير مرتبة بتنسيق RGP لأوراق بعض النباتات السليمة والمصابة مصنفة إلى فئات متعددة تم استخدامها لغرض اختبار قدرة النموذج على التعميم.

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

14. نتائج المقاييس المعيارية:

جدول 3 نتائج المقاييس المعيارية

| المقياس Metrics | الوصف Description | القيمة Value |
|-----------------|--|--------------|
| accuracy | تصنيف مثالي على بيانات التدريب والتحقق | 99.92% |
| Test accuracy | نجاح تام على البيانات الخارجية | 100% |
| Precision | نادراً ما يعطي النموذج إنذاراً خاطئاً | 99.9% |
| Recall | نادراً ما يفشل النموذج في رصد المرض | 99.8% |
| F1 Score | الأداء الكلي المتوازن | 99.85 |
| ROC-AUC | القدرة على التمييز بين الفئات | 1.0000 |

نلاحظ في الجدول (3) قيم مرتفعة جداً لنموذج EfficientNet-B3 مما يدل على أن النموذج تعلم الميزات البصرية للأمراض بدقة متناهية وتحيز منعدم تقريباً، أي أن النموذج حقق دقة شبه متكاملة على مجموعة البيانات New plant Diseases في مهمة كشف وتصنيف أمراض النبات، ورغم أن النموذج شبه مثالي إلا أن تبين في مصفوفة الارتباك حالات نادرة جداً من الارتباك النوعي (Confusion) مثل تداخل بسيط جداً بين فئتي Tomato_healthy و Tomato_Late_blight، هذه الأخطاء تحدث بسبب التشابه البصري في المراحل المبكرة للمرض.

15. مقارنة بين الدراسة الحالية والدراسات السابقة:

هذه الدراسة استخدمت مجموعة بيانات تحتوي على صور بظروف تصوير غير مضبوطة وتباين أعلى في الخلفيات والإضاءة وزوايا الالتقاط مقارنة بالدراسات السابقة التي استخدمت Plant village تحتوي على صور بظروف تصوير مضبوطة بخلفيات نظيفة وإضاءة ثابتة.

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

جدول 3 نستعرض المقارنة بين النموذج المقترح القائم على EfficientNet-B3

| أهم النتائج "الدقة" | المنهجية المستخدمة | عدد الفئات | مجموعة البيانات | الدراسة |
|------------------------|-----------------------|---------------|---------------------------------|--|
| %85.31 | CNN التقليدية | 14 | Plant village | الكشف عن أمراض أوراق النبات وتصنيفها باستخدام التعلم العميق، 2023 |
| %92.23 | CNN التقليدية | 39 | مجموعات بيانات متنوعة | الكشف عن أمراض أوراق النباتات باستخدام CNN، 2023 |
| %95.5 | Inception -V3 | 4 | Plant community | أداء تقنيات التعلم العميق في الكشف عن أمراض الأوراق، 2024 |
| %96 | Custom CNN | 39 | Plant Doc & Plant village | أمراض أوراق النباتات وتصنيفها باستخدام بنى شبكات عصبية مخصصة، 2024 |
| %95 | ResNet5 0 | 14 | Plant village | نظام تصنيف أمراض النبات باستخدام تقنيات التعلم العميق، 2025 |
| %99.92 | EfficientN et- B3 | 38 | New plant Diseases | كشف وتصنيف أمراض النبات باستخدام الشبكات العصبية الالتفافية وتقنيات التنظيم والتحسين، 2026 |

16. دراسة تحليلية لإثبات جدوى استراتيجية الضبط الدقيق التدريجي:

في الاعداد الأساسي تم فك جميع طبقات النموذج المدرب مسبقاً في بداية التدريب مما يسمح بتحديث جميع المعلمات بشكل متزامن في المقابل تعتمد استراتيجية الضبط الدقيق التدريجي المقترحة في هذه الدراسة على أسلوب تدريجي يتم فيه فك تجميد الطبقات تدريجياً على مراحل متتابعة، أي أن الطبقات العميقة في النماذج المدربة مسبقاً تتعلم ميزات عامة منخفضة المستوى يجب الحفاظ عليها في المراحل الأولى من التدريب بينما

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

يتم تكيف الميزات عالية المستوى تدريجياً لتناسب خصائص البيانات المستهدفة، تشير النتائج إلى أن استراتيجية الضبط الدقيق التدريجي وفرت آلية تدريب أكثر استقراراً مقارنة بفك جميع الطبقات دفعة واحدة فمن خلال الانتقال التدريجي من الطبقات المتخصصة إلى كل طبقات النموذج تمكنت الشبكة من التكيف مع البيانات دون فقد الميزات العامة المهمة المكتسبة من التدريب المسبق، كما ساهمت هذه الاستراتيجية في تقليل مشكلة إفراط التكيف ولوحظ أن منحنيات التدريب كانت أكثر استقراراً مع انخفاض التذبذب في خسارة التحقق مما يعكس سلوك التقارب، أي أن استراتيجية الضبط الدقيق التدريجي تقلل من ظاهرة نسيان المعرفة السابقة و تمنع التحديات العشوائية الكبيرة في المراحل الأولى من التدريب مما يسمح بتعلم أكثر استقراراً و تمثيل أكثر دقة لخصائص الفئات المستهدفة، هذه الاستراتيجية اثبتت مساهمتها في تحسين قدرة النموذج على التعميم وتعزيز استقرار التدريب وتقليل مشكلة الإفراط في التكيف وتحسين قدرة النموذج على تعلم بيانات جديدة غير مستخدمة في التدريب، مما أدى إلى تحقيق نتائج أفضل على بيانات الاختبار الخارجية التي لم تستخدم أثناء عملية التدريب.

17. دراسة تحليلية لإثبات جدوى خوارزمية التحسين AdamW :

اعتمدت هذه الدراسة على خوارزمية AdamW كخوارزمية تحسين رئيسية أثناء تدريب النموذج، وذلك بهدف تحسين استقرار عملية التعلم وتقليل مشكلة الإفراط في التكيف أثناء تصنيف أمراض النباتات، تُعد خوارزمية AdamW تطويراً لخوارزمية Adam التقليدية، حيث تعتمد على فصل عملية تنظيم الأوزان عن تحديث معاملات النموذج، في خوارزمية Adam التقليدية يتم دمج تنظيم الأوزان ضمن تحديثات التدرج مما يؤدي إلى تأثير غير مستقر على الأوزان، أما في AdamW فصل عملية تنظيم الأوزان يسمح بتحكم أفضل في عملية التنظيم وتحسين القدرة على التعميم، أظهرت النتائج أن خوارزمية التحسين AdamW ساهمت في تحقيق عملية تدريب أكثر استقراراً، حيث وفرت الخوارزمية آلية تكيفية لتحديث معدلات التعلم لكل معامل داخل النموذج مما أدت لتسريع التقارب وتقليل التذبذب أثناء التدريب وتحسين استقرار منحنيات الخسارة والدقة، ونظراً لأن الدراسة تعتمد على بيانات

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

متعددة الفئات وذات تباين بصري مرتفع فقد ساعد الفصل المستقل لعملية تنظيم الأوزان على منع النموذج من الاعتماد المفرط على الأنماط الخاصة في بيانات التدريب مما أدى إلى تحسين الأداء على بيانات التحقق والاختبار، كما ساهم استخدام معدلات تعلم تدريجية عبر مراحل استراتيجية الضبط الدقيق التدريجي في تعزيز فعالية استخدام خوارزمية AdamW ، بحيث استخدم معدل تعلم مرتفع نسبياً عند طبقة التصنيف ثم استخدم معدل تعلم منخفض جداً أثناء Fine Tuning الكامل وهذا التدرج سمح لخوارزمية AdamW بإجراء تحديثات دقيقة ومستقرة دون تأثير سلبي على الأوزان المكتسبة مسبقاً، كما ساهمت هذه الخوارزمية في تحسين قدرة النموذج على التعميم حيث حافظ النموذج على أداء مرتفع ليس فقط على بيانات التحقق بل أيضاً على بيانات الاختبار الخارجية المأخوذة من الانترنت، مما يدل على أن الخوارزمية ساعدت النموذج على تعلم ميزات أكثر عمومية بدلاً من حفظ الأنماط الخاصة ببيانات التدريب فقط.

18. دراسة تحليلية لإثبات جدوى تقنيات التنظيم:

أولاً: تأثير تقنيات زيادة البيانات Data Augmentation :

تم استخدام تقنيات زيادة البيانات بهدف انشاء تنوع اصطناعي داخل مجموعة بيانات التدريب دون الحاجة إلى جمع صور إضافية، وشملت عمليات التوسيع تحولات مختلفة على الصور مثل تدوير الصور وتقليب أفقي عشوائي وغيرهم من العمليات التي ساهمت في تعريف النموذج لأنماط بصرية متعددة لنفس الفئة المرضية ، مما أدى إلى تحسين قدرة النموذج على التعميم وتقليل الاعتماد على خصائص محددة داخل بيانات التدريب وزيادة مقاومة النموذج لاختلاف ظروف التصوير ، كما تشير النتائج إلى أن استخدام تقنيات زيادة البيانات أدت إلى تحسين استقرار تدريب النموذج وتقليل الفجوة بين أداء التدريب والتحقق ورفع دقة النموذج على البيانات غير المرئية مما يفسر بأن النموذج أصبح أكثر قدرة على تعلم الميزات العامة للأمراض النباتية بدلاً من حفظ أنماط محددة مرتبطة ببيانات التدريب فقط .

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

ثانياً: تأثير تقنية Dropout:

تم استخدام تقنية Dropout كآلية تنظيم داخل الشبكة العصبية حيث يتم تعطيل نسبة 30% من الخلايا العصبية عشوائياً أثناء التدريب لتقليل الاعتماد المفرط بين الخلايا العصبية وتحسين تعميم النموذج، مما يساعد في تقليل الإفراط في التكييف ومنع النموذج من حفظ بيانات التدريب وتحسين قدرة النموذج على التعامل مع بيانات جديدة، كما أظهرت النتائج أن استخدام تقنية Dropout أثناء كل دورة تدريبية ساهمت في تحسين الأداء على بيانات التحقق والاختبار وتقليل التذبذب في منحنيات التدريب وتعزيز استقرار النموذج أثناء الضبط الدقيق الكامل.

19. المعاملات الفائقة المستخدمة في الدراسة (Hyperparameters):

باستخدام مجموعة من المعاملات الفائقة التي تم EfficientNet-B3 تم تدريب نموذج اختيارها بعناية لتحقيق التوازن بين سرعة التعلم واستقرار التدريب وتقليل مشكلة الإفراط في التكييف.

يوضح جدول 4 أهم المعاملات المستخدمة أثناء تدريب النموذج:

| المعامل الفائق | القيمة |
|--|---------------------|
| طريقة الضبط | Gradual Fine-Tuning |
| Gradual Fine-Tuning عدد مراحل | 3 مراحل |
| معدل التعلم في المرحلة الأولى | 1e-3 |
| معدل التعلم في المرحلة الثانية | 1e-4 |
| معدل التعلم في المرحلة الثالثة | 1e-5 |
| عدد Epochs | 50 |
| في المرحلة الأولى Early Stopping Patience | 3 |
| في المرحلة الثانية Early Stopping Patience | 4 |
| في المرحلة الثالثة Early Stopping Patience | 5 |
| مجدول معدل التعلم | ReduceLRonPlateau |
| معياري scheduler | Validation Loss |
| دالة الخسارة | Cross-Entropy Loss |

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

| المعامل الفائق | القيمة |
|-------------------|--------------|
| تقنية التنظيم | Dropout |
| Dropout Rate | 0.3 |
| حجم الدفعة | 32 |
| حجم الصور المدخلة | بكسل 300×300 |
| تدوير عشوائي | درجة 15 |
| تقليب أفقي عشوائي | 50% |
| عدد الفئات | 38 |

20. بيئة التنفيذ:

1. تم تنفيذ النموذج باستخدام لغة (Python 3.11)
2. جهاز دعم التشغيل على (GPU) أو (CPU)
3. مكتبات: PyTorch ، torchvision ، timm ، numpy ، pillow

21. الإضافات: بالإضافة العلمية في هذه الدراسة تطبيق منهجية متكاملة لبناء نموذج قوي وفعال معتمد على الشبكات العصبية الالتفافية (CNN) متمثل في دمج التقنيات الأربع (نموذج Efficient Net B3 واستراتيجية الضبط الدقيق التدريجي وخوارزمية التحسين AdamW وتقنيات التنظيم) فهذه بالإضافة العلمية لا تقتصر على مجرد تحسين في الدقة بل تمتد لتشمل تحقيق توازن متقدم بين الأداء والتعميم ، كما إن دمج منهجية الدراسة مع أدوات تحسين إضافية مثل جدولة معدل التعلم لضمان استقرار التدريب و الوصول إلى نقطة تقارب أفضل تُظهر قابلية التطبيق في بيانات متنوعة باستخدام هذه المنهجية Efficient Net B3 التي صممت لتكون ذات كفاءة عالية (توازن ممتاز بين الدقة والكفاءة الحسابية) مما يؤدي إلى امكانية استخدام النموذج في التطبيقات الزراعية ، تؤكد هذه الدراسة أن دمج الذكاء الاصطناعي في المجال الزراعي يمثل خطوة محورية نحو تحقيق مفهوم الزراعة الذكية لما يوفره من دقة وسرعة في التشخيص وتقليل الاعتماد

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

على الخبرة البشرية المحدودة، كما تمثل النتائج المتحصل عليها أساسًا علميًا يمكن البناء عليه في دراسات مستقبلية أكثر توسعًا.

22. التوصيات والأعمال المستقبلية: تركيز الأبحاث المستقبلية على اختبار النموذج على بيانات محلية لأمراض النباتات ودمج تقنيات Attention Mechanisms وتوسيع الدراسة لتشمل عدة أمراض لنباتات أخرى من محاصيل مختلفة.

23. الخلاصة:

تناولت هذه الدراسة التطبيقية لاستخدام تقنيات التعلم العميق في مجال كشف وتصنيف أمراض النباتات، من خلال تصميم وتنفيذ نموذج ذكي قائم على EfficientNet-B3 ومنهجية التعلم بالنقل والضبط الدقيق التدريجي. وقد أظهرت النتائج أن النموذج المقترح يتمتع بأداء رقمي مرتفع وقابلية واضحة للتطبيق العملي بحيث توصلت هذه الدراسة إلى مجموعة من الاستنتاجات، من أهمها:

- ✓ فعالية الشبكات العصبية الالتفافية CNN في مجال كشف وتصنيف أمراض النباتات.
- ✓ كفاءة نموذج EfficientNet-B3 في تحقيق دقة عالية مع تكلفة حسابية منخفضة.
- ✓ أهمية استراتيجية الضبط الدقيق التدريجي في تحسين أداء النموذج.
- ✓ تفوق خوارزمية AdamW في تحسين استقرار التدريب والتعميم.

المراجع:

- [1] P. S., P. Shanmugapriya, A. Dhanush, S. Dinesh Kumar, and S. Kathir, "Plant Disease Classification System Using Deep Learning Techniques," International Journal of Research and Technical Innovation (IJRTI), Apr. 2025.
- [2] M. J. U. Chowdhury, Z. I. Mou, R. Afrin, and S. Kibria, "Plant Leaf Disease Detection and Classification Using Deep Learning: A Review and a Proposed System on Bangladesh's

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

- Perspective,” arXiv preprint arXiv, 2023. Doi: 10.32604/csse.2024.050359.
- [3] S. Guo, “Leaf Disease Detection by Convolutional Neural Network (CNN),” Highlights in Science, Engineering and Technology, 2023. [Online]. Available: ResearchGate Publication
- [4] R. Damasevicius, F. Mahmood, and Y. Zaman, “Performance of Deep Learning Techniques in Leaf Disease Detection,” Computer Systems Science and Engineering, Jan. 2024. Doi: 10.32604/csse.2024.050359.
- [5] S. F. Rabbi, M. R. Hasan, and M. Hasan, “Advanced Plant Disease Identification and Recognition: Deep Learning Based Detection and Classification of Plant Leaf Diseases Using Custom CNN Architectures,” SSRN Electronic Journal, Jun. 2025. Doi: 10.2139/ssrn.5295906.
- [6] A. Davila, J. Colan, and Y. Hasegawa, “Comparison of Fine-Tuning Strategies for Transfer Learning in Medical Image Classification,” Image and Vision Computing, vol. 146, p. 105012, 2024. Doi: 10.1016/j.imavis.2024.105012
- [7] A. Batool and Y. Byun, “Lightweight EfficientNetB3 Model Based on Depthwise Separable Convolutions for Enhancing Classification of Leukemia White Blood Cell Images,” IEEE Access, vol. PP, pp. 1–1, 2023. Doi: 10.1109/ACCESS.2023.3266511.
- [8] Y. X. Wang, D. Ramanan, and M. Hebert, “Growing a brain: Fine-tuning by increasing model capacity,” in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017, pp. 2471–2480.
- [9] خديجة أبوبكر خشيبية، مجدي محمد بالتمر، وصفية المبروك الشامس، “تفعيل الدوال الرياضية في الشبكات العصبية” ، مجلة العلوم الشاملة، المجلد 9، العدد

كشف وتصنيف أمراض النبات باستخدام EfficientNet-B3 واستراتيجية الضبط الدقيق
التدريجي

<http://www.doi.org/10.62341/istj-vol38-2-rm24>

36، ص ص. 1781-1786، 2025. [متاح على الإنترنت]: مجلة العلوم

الشاملة - المقالة العلمية

- [10] M. Grandini, E. Bagli, and G. Visani, "Metrics for Multi-Class Classification: An Overview," arXiv preprint arXiv:2008.05756, 2020.
- [11] A. A. Abd El-Aziz, M. A. Mahmood, and S. A. El-Ghany, "EfficientNet-B3-Based Automated Deep Learning Framework for Multiclass Endoscopic Bladder Tissue Classification," *Diagnostics*, vol. 15, no. 19, p. 2515, 2025. Doi: 10.3390/diagnostics15192515.