



## اكتشاف وتصنيف آفات وأمراض أوراق أشجار الزيتون باستخدام أمثل تقنيات التعلم العميق

علي الروياتي<sup>a\*</sup>، ياسر سويب<sup>b</sup>، محمد بلتو<sup>b</sup>

<sup>a</sup> كلية التقنية الصناعية، مصراتة، ليبيا.

<sup>b</sup> كلية تقنية المعلومات، جامعة مصراتة، ليبيا.

### الكلمات المفتاحية:

آفات أشجار الزيتون.  
أمراض أشجار الزيتون.  
التعلم العميق.  
الذكاء الاصطناعي.  
الشبكات العصبية الالتفافية.

### الملخص

شهد عالم البحوث الزراعية تقدماً هائلاً في مجال استخدام التكنولوجيا والذكاء الاصطناعي لتحسين إنتاجية الزراعة ومكافحة الأمراض. يعد تصنيف أمراض وآفات أشجار الزيتون بالطرق التقليدية من أبرز المشاكل التي تواجهها البحوث الزراعية، حيث إنه من الصعب على الفلاحين التعرف على هذه الأمراض والآفات يدوياً واتخاذ الإجراءات اللازمة في الوقت المناسب، وحتى خبراء الآفات الزراعية يحتاجون إلى وقت وجهد لتحديد هذه الآفات والأمراض وتصنيفها. ومن هنا تقدم هذه الدراسة تجارب على مجموعة بيانات محلية تتكون من 4170 عينة من أوراق الزيتون والتي تتضمن آفة ذبابة الزيتون وآفة فراشة الياسمين وهي آفات شائعة في نبات الزيتون في ليبيا، وتتضمن أيضاً أوراقاً سليمة. كما تقدم هذه الدراسة تجارب على مجموعة بيانات متاحة في منصة (GitHub) والتي تحتوي على 6961 عينة من أوراق أشجار الزيتون والتي تتضمن آفة عث الصدأ ومرض عين الطاووس وتتضمن أيضاً أوراقاً سليمة. تم في هذه الدراسة استخدام إحدى تقنيات الذكاء الاصطناعي المبتكرة والتي أثبتت جدارتها وتمثله في الشبكات العصبية الالتفافية (CNN)، استخدمت هذه الدراسة التجريبية اثنين من نماذج الشبكة العصبية الالتفافية (CNN)، والمقارنة بين النماذج المدربة مسبقاً مع النماذج غير المدربة. في النماذج المدربة مسبقاً كانت أعلى دقة للنموذج (Xception) مع البيانات المحلية بدقة بلغت 99%، بينما النموذج المقترح غير المدرب كانت نتيجته أعلى دقة مع البيانات المحلية أيضاً بنسبة 95%. بالإضافة إلى ذلك تطرقت هذه الدراسة إلى تأثير خوارزميات التحسين (Adam) و (SGD) على أداء النماذج المستخدمة في الدراسة. أظهرت نتيجة الدراسة أن خوارزمية التحسين (Adam) حققت نتائج أفضل مع البيانات المحلية والبيانات المتاحة في منصة (GitHub) من حيث دقة النتائج.

## Detecting and Classifying Olive Leaf Pests and Diseases Using Optimal Deep Learning Techniques

Ali Elrowayati<sup>a\*</sup>, Yasir Swayeb<sup>b</sup>, and Mohammed Baltu<sup>b</sup>

<sup>a</sup> Department of Electronic Engineering, College of Industrial Technology, Misurata, Libya.

<sup>b</sup> Faculty of Information Technology, Misurata University, Misurata, Libya.

### Keywords:

Olive Tree Pests.  
Olive Tree Diseases.  
Deep Learning.  
Artificial intelligence.  
Artificial Convolutional Networks.

### ABSTRACT

Agricultural advancements in technology and AI are transforming disease and pest control, boosting crop productivity. Classifying olive tree ailments is a challenge. Traditional methods are insufficient, requiring farmers and even experts to invest significant time and effort in manual identification. This paper explores CNNs for olive disease and pest classification. We experimented on two datasets: a local one from Libya with healthy leaves, olive fly, and jasmine moth (4,170 samples) and a public GitHub dataset with healthy leaves, rust mite blight, and peacock eye disease (6,961 samples). We compared pre-trained and untrained CNN models, finding the pre-trained Xception model achieved the highest local data accuracy (99%). Interestingly, the best-untrained model also excelled on local data (95%). The study further explored the impact of optimization algorithms (Adam and SGD), with Adam consistently achieving superior accuracy on both datasets.

\*Corresponding author.

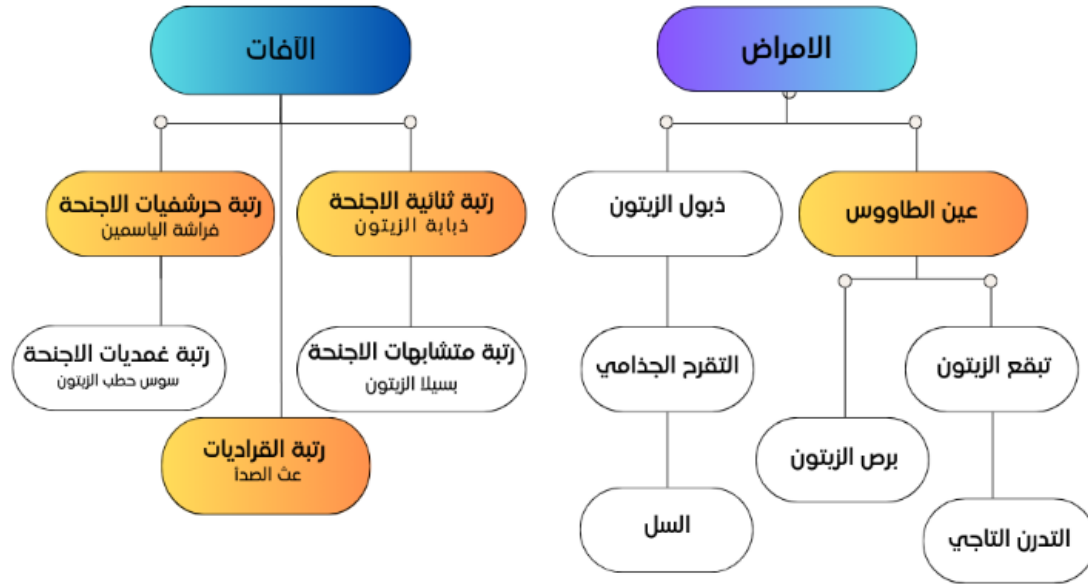
E-mail addresses: [elrowayati@yahoo.com](mailto:elrowayati@yahoo.com), (Y. M. Swayeb) [m09181086@it.misuratau.edu.ly](mailto:m09181086@it.misuratau.edu.ly), (M. A. Baltu) [m09181064@it.misuratau.edu.ly](mailto:m09181064@it.misuratau.edu.ly)

Article History : Received 30 June 2024 - Received in revised form 03 December 2024 - Accepted 05 December 2024

## 1. المقدمة

في معظم الحالات، تتم الاستعانة بخبراء الزراعة والغابات للتعرف على هذه الأمراض والآفات، أو يقوم المزارعون بتحديد الأمراض والآفات بناءً على الخبرة. هذه الطريقة ليست ذاتية فحسب، بل إنها تستغرق أيضاً وقتاً طويلاً وتعتبر عملية شاقة وغير فعالة.

تتعرض شجرة الزيتون لهجوم من أنواع متعددة من مسببات الأمراض والآفات منها العوامل الحية مثل الفطريات والبكتيريا والفيروسات، وهناك أيضاً العوامل البيئية مثل سوء الأحوال الجوية واحتراق المواد الكيميائية [1]. ووفقاً للمجلس الدولي للزيتون فإن الأنواع الرئيسية المسببة للأمراض والآفات تم تقسيمها إلى مجموعتين [2]، كما سيتم توضيحها في الشكل (1).



شكل 1: أنواع الأمراض والآفات في أشجار الزيتون


- دراسة مدى تأثير خوارزميات التحسين (Adam) و (SGD) على دقة أداء النماذج.
- تقييم دقة النماذج المستخدمة باستخدام مقاييس الدقة المختلفة ومقارنتها مع الدراسات السابقة.
- ويمكن تسليط الضوء على الإسهامات العلمية التالية لهذه الدراسة، والمتمثلة في:
  - تساهم هذه الدراسة في سد فجوة المعرفة في مجال تصنيف أمراض النبات باستخدام الذكاء الاصطناعي باللغة العربية، مما يجعلها مرجعاً قيماً للباحثين والطلاب العرب في هذا المجال.
  - تقدم الدراسة شروحاً مبسطاً باللغة العربية لتقنيات التعلم العميق المستخدمة، مما يسهل على غير المتخصصين فهم هذه التقنيات وتطبيقها.
  - استخدمت الدراسة مجموعة بيانات محلية جمعت خصيصاً لهذا الغرض، مما يزيد من قابلية تطبيق النموذج على الظروف المحلية، كما تم استخدام مجموعة بيانات دولية للتأكد من فعالية النموذج المقترح.
  - قامت الدراسة بمقارنة أداء نماذج الشبكات العصبية التلافيفية المختلفة (CNN) لتحديد النموذج الأمثل لهذه المهمة.
  - قامت الدراسة بتقييم تأثير خوارزميات التحسين المختلفة على أداء النماذج، مما يساعد في اختيار الخوارزمية المناسبة.
  - حققت الدراسة دقة تصنيف عالية جداً، مما يشير إلى فعالية النظام المقترح.

2. آفات وامراض أشجار الزيتون Pests and Diseases of Olive Trees تتميز شجرة الزيتون بجذع أسطواني الشكل، وأوراقها الخضراء ذات البنية

- وقد يخطئ المزارعون الذين هم أقل خبرة في الحكم على هذه الأمراض والآفات. لمواجهة هذه التحديات، أصبح من الضروري وجود خطوات تعمل على المساعدة والتقليل من هذه الأضرار، ولا شك أن الطرق التقنية الحديثة والزراعة الذكية إحدى هذه الخطوات، كما أن استخدام أنظمة الكشف عن طريق الذكاء الاصطناعي والتعلم العميق واحدة من هذه الطرق التي بإمكانها المساعدة في بناء نظم وتطبيقات تساعد في التغلب على هذه الأمراض، خصوصاً بعد إثبات فعاليتها في العديد من المجالات الموجودة في الوقت الحاضر في مختلف جوانب الحياة اليومية وفي المجال المهني [3,4].
- وبناء على ذلك فإن الغرض العام من هذه الدراسة هو الاكتشاف والتصنيف الآلي للأمراض والآفات التي تصيب أشجار الزيتون باستخدام تقنيات التعلم العميق، وللوصول إلى هذا الغرض تم وضع عدد من الأهداف الحقيقية، المحددة، القابلة للقياس، والمتوفرة:
- تصنيف واكتشاف أمراض وآفات أشجار الزيتون، واستخدام أدوات وأساليب التعلم العميق في المساهمة والمساعدة على تصنيف هذه الأمراض والآفات التي تصيب شجرة الزيتون.
  - إنشاء وتوثيق مجموعة بيانات جديدة محلية واستخدام مجموعة بيانات متاحة على منصة (GitHub) وبها مجموعة من صور أمراض وآفات أشجار الزيتون.
  - تصميم وتنفيذ لنماذج تعلم عميق جديدة لتصنيف الأمراض والآفات التي تصيب أشجار الزيتون.
  - تدريب واختبار دقة نماذج تعلم عميق مدربة مسبقاً لتصنيف الأمراض والآفات التي تصيب أشجار الزيتون.

الخدمة المختلفة وانتخاب الأصناف الملائمة فقط بل لا بد من أن يصاحبها فهم وإدراك تام بمكافحة الآفات التي يتعرض لها الزيتون حيث تسبب الإصابة نقصاً كبيراً في المحصول كماً ونوعاً، وتدهوراً شديداً في عمر الأشجار وفي ظل عدم العناية والتركيز على برامج الوقاية من جهة والتراخي في تطبيق نظام حجر زراعي فعال من جهة أخرى، مما يؤدي ذلك إلى انتشار كثير من الآفات على أشجار الزيتون في الوطن العربي حيث تختلف أضرارها بحسب الدول والمناطق [7].

ومن هنا تعتبر مشكلة الآفات والأمراض التي تصيب أشجار الزيتون أحد التحديات الرئيسية التي تواجه الزراعة بشكل عام والمزارعين والمهتمين بشكل خاص، فالآفات والأمراض قد تتسبب في تدهور صحة الأشجار وتقليل إنتاجيتها، وبالتالي يمكن أن يؤدي إلى موتها في أسوأ الأحوال. حيث يوجد العديد من الآفات والأمراض المتنوعة التي تصيب أشجار الزيتون، ومن أشهرها والأكثر شيوعاً والذي تم الاهتمام بدراسته في هذه الورقة الأنواع الموضحة بالشكل (2).



شكل 2: أنواع الأمراض والآفات المقترحة في هذه الدراسة

البييض: شكل شبه إهليلجي، مسطح، مشبك رفيع في السطح، لونه يميل إلى الأبيض [2].

البرقة: ست أطوار برقية. بعد التفقيس، يميل لون البرقة إلى الأصفر ويكون قياسها 1,4 \* 0,25 ملم. مع تطورها، يتحول لونها إلى الأخضر الغامق قليلاً وعند نهاية النمو، تحيك البرقة المسنة (طولها 15-25 ملم) شرنقة من الحرير بين الأوراق، حيث تتحول إلى عذاري [2].

إنّ الأعراض والأضرار التي تسببها البرقات في البراعم الطرية وفي الأوراق لا تكتسي أهمية في الغرسات البالغة. وفي المقابل، يمكن أن يكون لها أثر اقتصادي في المشاتل (المنابت) والغرسات الفتية، وبالأخص عندما تفتك البرقات بالثمار [2].

#### ج- مرض بقعة عين الطاووس Peacock Spot

إنّ المسبب هو فطر *Spilocaea oleagina*، ينمو ويشكل مستعمرات تحت البشرة العليا للورقة. تتطور هذه المستعمرات بموازاة سطح الورقة من خلال حبات رقيقة جدا تخرج منها أبواغ كونيدية تكون عادة ثنائيتة الخلية. [2]. الأعراض والأضرار الناجمة عن هذا المرض تتمثل عادة في تقرحات على الأوراق

الدائمة، وتنمو بشكل مقبول في المناطق ذات الأمطار القليلة. ويتغير شكل الشجرة حسب الظروف المناخية ومكان زراعتها، وغالباً ما تأخذ الشكل الهرمي عندما تنمو بمفردها. قد تصل الأشجار المعمرة منها إلى طول 15-20 متر وقطر جذعها 1.5-2 متر [5].

أما تركيبة أوراق الزيتون فتكون فيها الأوراق مستديمة الخضرة، وتعيش حوالي ثلاث سنوات، ويكون لها لون أخضر قاتم يكسو وجهها السفلي. في الغالب تختلف أشكال أوراق الزيتون، وأبعادها، باختلاف الأصناف، والعمر، والظروف البيئية، ولو أنها تبدو متشابهة ويبلغ طولها وسطياً 5-6 سم، وعرضها في الوسط 1-1.5 سم [6].

تتعرض شجرة الزيتون للإصابة بعدد من الآفات الحشرية والمرضية، وتعتبر مكافحة الصحيحة لهذه الآفات من العمليات الاقتصادية الهامة التي تؤثر على زراعة أشجار الزيتون حيث يتجه مزارعو الزيتون في أنحاء كثيرة من العالم إلى زيادة الدخل عن طريق الزيادة الرأسية في وحدة المساحة. وهذه الزيادة لا تتحقق فقط عن طريق استخدام الأساليب الزراعية الحديثة من عمليات

#### أ- ذبابة أوراق الزيتون Olive Leaf Gall Midge

ويمكن وصف هذه الذبابة كالتالي:

الطور البالغ: طول من 2,25 الى 2,50 ملم، لون اصفر وبطن يميل إلى الأحمر عند الأنثى العمر قصير. خصوبة الأنثى: مئة بيضة.

البيض: متطاوول، أسطواناني قليلاً، لونه أصفر فاتح ثم أحمر في القطبين [2]. البرقة: صفراء وطرفها الخلفي من اللون البني الغامق.

الشرنقة: لونها أحمر يميل إلى البرتقالي [2].

الأعراض والأضرار الناجمة عن الإصابة بهذه الذبابة تتمثل في ظهور العفص في الأوراق والنورات وكذلك تشوّه في الأوراق والنورات وسقوط عناقيد الزهر [2].

#### ب- فراشة الياسمين Jasmine Moth

ويمكن وصف هذه الفراشة كالتالي:

الطور البالغ: فراشة يصل امتداد جناحها الى 30 ملم، لونها أبيض ساتاني، تنشط أساساً في الليل [2].

الشائعة الاستخدام والتي تعتمد في أسلوب عملها على الشبكات العصبية الالتفافية:

#### 4.1. نماذج الشبكات العصبية الالتفافية الشائعة

هناك العديد من نماذج الشبكات العصبية الالتفافية الشائعة. ويرد أدناه وصف لأبنية الشبكات العصبية الالتفافية المستخدمة في هذه الدراسة.

##### 4.1.1. نموذج التسلسل Sequential Model

نموذج التسلسل (Sequential Model) في التعلم العميق هو نوع من النماذج التي تكون فيها الطبقات المختلفة مرتبة ترتيباً تسلسلياً. يُعتمد عليه على نطاق واسع في بناء الشبكات العصبية، حيث تتبع البيانات مساراً واحداً إلى الأمام، مروراً بطبقات المعالجة واحدة تلو الأخرى.

فيما يتعلق بالشبكات العصبية الالتفافية، يشيع استخدام نموذج التسلسل لبناء تلك الشبكات التي تُستخدم بشكل أساسي في مجالات رؤية الحاسوب، مثل التعرف على الصور والتصنيف. في هذا النموذج، تكون الطبقات الالتفافية (Convolutional Layers)، طبقات تليين الملعلمات (Pooling Layers)، وطبقات الارتباط (Fully Connected Layers) مرتبة بصورة تسلسلية. يبدأ بطبقات الالتفاف حيث يتم استخراج السمات من الصور، تلمها عمليات التليين التي تقلل الأبعاد وتتبعها طبقات الارتباط التي تساعد في التصنيف النهائي. نموذج التسلسل يسهل بناء وتدريب الشبكة العصبية الالتفافية بطريقة منظمة وواضحة [9].

##### 4.1.2. نموذج Xception Model

هي شبكة عصبية التفافية تكتسب شعبية متزايدة بسبب كفاءتها وفعاليتها، حيث تحتوي بنية Xception على 36 طبقة التفافية تشكل قاعدة استخراج الميزات للشبكة، يختلف هيكل هذه الشبكة العصبية عن الشبكات العصبية التلافيفية القياسية الأخرى، حيث إنها عبارة عن مكس خطي من طبقات الالتفاف القابلة للفصل بعمق مع الاتصالات المتبقية، مما يقلل بشكل كبير من المتطلبات الحسابية وبصمة الذاكرة للشبكة، وهذا يجعل من السهل جداً تعريف البنية وتعديلها [10].

##### 4.1.3. نموذج VGG16 Model

هو نموذج شبكة عصبية التفافية يتألف من 16 طبقة، وتم اقتراحه من قبل الباحثين Simonyan و Zisserman من جامعة أكسفورد ونُشر في ورقة بحثية بعنوان "الشبكات الالتفافية العميقة جداً للتعرف على الصور على نطاق واسع"، وهو نموذج معروف أيضاً باسم VGGNet. كان إنجازها الرئيسي هو إظهار أن عمق النظام يمكن أن يكون عاملاً أساسياً للأداء الجيد. كانت آخر شبكة أكثر كفاءة تحتوي على 16 طبقة CONV/FC إجمالاً، وتتميز بشكل جذاب ببنية موحدة للغاية تؤدي فقط 3\*3 وتجميع 2\*2 من البداية إلى النهاية [8].

#### 5. الدراسات السابقة

شهد مجال تصنيف أمراض أوراق الزيتون باستخدام تقنيات التعلم العميق تطوراً ملحوظاً في السنوات الأخيرة. تسعى العديد من الدراسات إلى تطوير نماذج قادرة على تشخيص الأمراض بدقة عالية، مما يساهم في تحسين الإنتاج الزراعي وحماية المحاصيل. هناك العديد من الدراسات والأبحاث القائمة على تقنيات التعلم العميق التي تناولت تصنيف أمراض النباتات بشكل عام ولكن تظل الدراسات التي تناولت تصنيف أمراض وأفات الزيتون

وأعناق الأوراق وسويقات الثمار والثمار. تظهر الأعراض على الوجه الأعلى للأوراق في شكل بقع دائرية وسطها رمادي أو بني وقطرها من 5 إلى 10 ملم، تشبه عين الطاووس. تظهر الأضرار واضحة وبشكل مميز على الأوراق وتسبب تساقطها كلياً تقريباً، تصبح الفروع عارية تماماً مما يؤدي إلى ضعف الأشجار [2].

#### د- عث الصدأ (Aculus Olearius)

هو نوع من أنواع قراديات الأريوفيد لديه حجم مجهري (بين 100 و 350 ملم)، وجسم حلقي دودي الشكل، له جزآن، وأربع أرجل. جميع القراديات المسببة للعفص هي ضارة بالنبات، وذات تخصصية مرتفعة، وبإمكان بعض الأنواع نقل أمراض فيروسية. بالإمكان القول إن معظم قراديات الأريوفيد لها نفس السلوك: تتطور بارتباط وثيق مع تطور ظواهر النبتة، إذ تفتك تباعاً بالأعضاء الأكثر طراوة؛ أولاً بالبراعم والوريقات، ثم بعناقيد الأزهار وأخيراً بالثمار اليافعة. الأعراض والأضرار: تسبب هذه القراديات أضراراً كبيرة تؤثر على نمو الشجرة، وعلى كمية وجوده الزيتون وزيته، وتكون هذه الأضرار أشد خطراً في المشاتل، إذ تؤثر على نموها وتساهم في انتشار القراديات في البساتين الجديدة تتمثل هذه الأضرار في تشوه وتقلب في الأنسجة بسبب عضات القراديات في الأوراق والبراعم والفروع [2].

#### 3. التعلم العميق

هو أحد ميزات الذكاء الاصطناعي التي تعنى بمحاكاة نهج التعلم الذي يستخدمه البشر للحصول على أنواع معينة من المعرفة، كما يمكن اعتباره وسيلة لأتمتة التحليلات التنبؤية.

التعلم العميق هو تطور لأحد تقنيات تعلم الآلة وهي الشبكة العصبية الالتفافية، وهو مجال يقوم فيه النظام الآلي باختبار الخوارزميات والبرامج ويتعلم أن يقوم بتحسينها وتطويرها بنفسه، وهو المجال الذي يفحص خوارزميات البرمجة التي تتعلم وتتطور من تلقاء نفسها، يتم استخدام طريقة شبيهة بألية عمل الدماغ البشري عن طريق طبقات من الخلايا العصبية، فعند تعريض صورة لمثل هذا النظام تلاحظ كل طبقة نمطاً معيناً في الصورة فمثلاً الطبقة الأولى قد تلاحظ حدود الصورة وطبقة أخرى تلاحظ العين في منتصف الرأس وهو موجود في البشر، لم يكن الأداء الأول لهذا النظام أفضل من النظم الموجودة؛ ولكن تطور حتى وصلنا الآن إلى أن معظم التطبيقات الكبيرة تستخدمه [7].

#### 4. الشبكات العصبية الالتفافية ونماذجها الشائعة

يمكننا استنتاج أن التعلم العميق هو شبكة عصبية اصطناعية لها عدة طبقات مخفية؛ ولهذا سميت بالتعلم العميق، وتتطلب حواسيب خارقة، وبالرغم من أن الدراسات الأولية ركزت على الوسائل التي لا تحتاج إلى رقابة؛ فإن آخر التطورات في هذا المجال ركزت على التدريب العملي ونماذج الشبكات العصبية بالاستعانة بخوارزميات عكسية، وأكثر التقنيات شعبية في هذا المجال هي الشبكات العصبية الالتفافية وهي طريقة خاضعة للإشراف. حيث تتكون الشبكة العصبية الالتفافية من طبقة الإدخال والإخراج، بالإضافة إلى طبقات مخفية متعددة. تنقسم هذه الطبقات عموماً إلى ثلاثة أنواع: طبقة مرشح الالتفاف CONV، وطبقة التجميع POOL، وطبقة الاتصال التام Fully Connected Layer [8]. وفيما يلي سنتطرق إلى أهم النماذج

جدول 1: ملخص مقارنة للدراسات السابقة

دقة التصنيف	الأمراض المستهدفة	مجموعة البيانات	النموذج المستخدم	الدراسة
95%	عث الصدى، بقع عين الطاووس	3400 عينة	VGG16 VGG19 CNN	Sinan et al. (2021)
97.08%	بقع عين الطاووس، جرب الزيتون، عث الصدى	5400 عينة	MobiRes-Net	Amel et al. (2022)
98%	عث الصدى، بقع عين الطاووس	3400 عينة	AlexNet Resnet DenseNet Whale	Hamod et al. (2022)
98.40%	عث الصدى، بقع عين الطاووس	3300 عينة	Optimization Algorithm. Artificial Neural Network	Alshammari et al. (2023)
89.9%	بقع عين الطاووس	1000 عينة	Mask RCNN Fast RCNN.	Bocca et al. (2023)
98.63%	بقع عين الطاووس	954 عينة	MobileNet Resnet	Diker et al. (2024)

تُظهر الدراسات السابقة، بدءاً من دراسة Sinan وآخرون في عام 2021، وصولاً إلى الدراسات الحديثة في سنة 2023م وسنة 2024م إلى إمكانية استخدام تقنيات التعلم العميق لتحقيق دقة عالية في تصنيف أمراض أوراق الزيتون. مما يشير إلى تطور مستمر في هذا المجال.

#### 6. منهجية الدراسة والبيانات والنماذج المستخدمة

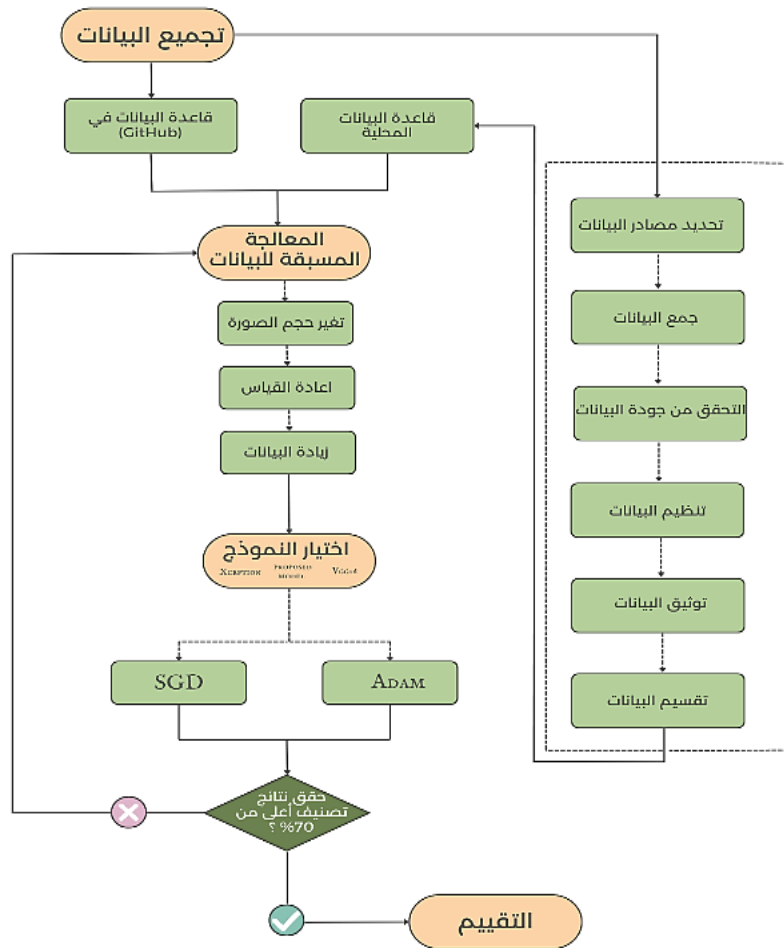
تمثل المنهجية التي تم اتباعها في تنفيذ هذه الدراسة في خمس مراحل وهي، جمع البيانات، المعالجة المسبقة للبيانات، إعداد وتطبيق عدد من النماذج وفق مسارين، الأول استخدام نموذج غير مسبق التدريب، والمسار الآخر تم خلاله استخدام نماذج أخرى مدربة مسبقاً، وتقييم النتائج لكل مسار. الشكل (3) يبين المخطط الصندوقي لسير العمل في تنفيذ الاستراتيجية.

محدودة. في [11] قدم Sinan وآخرون عام (2021) دراسة لمجموعة بيانات تتكون من 3400 عينة من أوراق الزيتون والتي تتضمن أيضاً أوراقاً صحية وذلك للكشف عن آفة عث الصدى ومرض بقع عين طاووس، استخدموا في هذه الدراسة نموذج VGG16 و VGG19، وكذلك بنية الشبكة العصبية الالتفافية المقترحة. بلغت نتائج الدراسة دقة تصنيف تصل إلى 95% بينما حقق نموذج VGG16 دقة تصل إلى 89% وحقق نموذج VGG19 دقة وصلت 84%.

وفي [12] قدم Amel وآخرون عام (2022) دراسة لمجموعة بيانات تتكون من 5400 عينة من أوراق الزيتون للكشف عن أمراض أوراق الزيتون مثل بقع عين الطاووس، وجرب الزيتون، وعت الصدى واقترحوا نموذجاً هجيناً MobiRes-Net شبكة عصبية عبارة عن سلسلة من نماذج ResNet50 و MobileNet وحقق النموذج MobiRes-Net دقة تصنيف بلغت 97.08% مما أظهر تفوقه على ResNet50 و MobileNet اللذين حققا دقة تصنيف 94.86% و 95.63% على التوالي. وفي [13] قدم Hamod وآخرون من نفس العام دراسة لمجموعة بيانات تتكون من 3400 عينة من أوراق الزيتون لتشخيص أمراض أوراق الزيتون مثل بكتيريا فيلت، وعقدة الزيتون، وعت الصدى، وبقع عين الطاووس. باستخدام خوارزمية جينية تكيفية قاموا بتطبيقه في ثلاثة نماذج (AlexNet)، (Resnet)، (DenseNet) أظهرت النتائج أن نموذج DenseNet تفوق في الأداء على النماذج الأخرى في التصنيف الثنائي حيث حقق دقة تبلغ حوالي 98% مقارنة بنموذج AlexNet الذي حقق دقة تبلغ حوالي 92% و Resnet الذي حقق دقة تبلغ حوالي 97%. كما أظهرت النتائج أن نموذج Resnet تفوق في الأداء على النماذج الأخرى في التصنيف متعدد الفئات حيث حقق دقة تبلغ حوالي 97% مقارنة بنموذج AlexNet الذي حقق دقة تبلغ حوالي 87% و DenseNet الذي حقق دقة تبلغ حوالي 96%.

قدم [14] Alshammari وآخرون (2023) نهجاً مبتكراً باستخدام شبكة عصبية اصطناعية محسنة لتحسين دقة التصنيف، محققين دقة بلغت 98.4%. كما حقق [15] بوكا وآخرون (2023) طريقة للكشف عن أمراض بقع عين الطاووس باستخراج كل من الميزات RGB ومتعددة الطيف لصور الأوراق واستخدامها في طريقتهم. في المرحلة الأولى، قاموا بفصل الأوراق عن الصورة باستخدام طريقة (Mask Region-based Mask) RCNN Convolutional Neural Network)، وفي المرحلة الثانية، قاموا باكتشاف الأوراق باستخدام Fast RCNN. في الخطوة الأخيرة، قاموا بتصنيف الأوراق المكتشفة باستخدام نموذج Inception V3. ووصلت دقة الطريقة المستخدمة إلى 89.9%. مؤخراً توصل [16] Diker وآخرون (2024) إلى دقة تصنيف مرتفعة وصلت إلى 98.63% باستخدام مجموعة بيانات بلغت 954 عينة منها 572 سليمة و 382 مصابة بمرض عين الطاووس، اعتماداً على نمودجي MobileNet و Resnet. تؤكد هذه الدراسات على أهمية استخدام تقنيات التعلم العميق في تشخيص أمراض أوراق الزيتون، وتشير إلى وجود إمكانية لتحقيق دقة عالية في هذا المجال. ومع ذلك، لا تزال هناك حاجة إلى مزيد من البحث لتطوير نماذج أكثر شمولية وقادرة على التعامل مع مجموعة متنوعة من الأمراض وظروف الزراعة. الجدول (1) يظهر ملخصاً لهذه الدراسات بناء على النماذج المستخدمة والخوارزميات والتقنيات المستخدمة وتقييم الأداء لها.





شكل 3: المخطط الصندوقي لمراحل سير تنفيذ الاستراتيجية

النوع الإسباني التي يتراوح عمرها من السنة إلى خمسة سنوات، وهي الأعمار التي تكون عُرضة للإصابة بهذه الآفات النشطة في فترة تجميع العينات الأولية.

• تقييم جودة المصادر: بعد العثور على خمسة مصادر مختلفة للأشجار الإسبانية في مدينة مصراته، تم تقييم جودة هذه المصادر وموثوقيتها من قبل مدير مكتب وقاية النبات بقطاع الزراعة.

ب- جمع البيانات: بعد تحديد المصادر المناسبة، بدأت مرحلة جمع البيانات، التي تطلبت زيارات ميدانية إلى هذه المصادر وتجميع العينات التي بلغ عددها 4170 عينة.

ج- التحقق من جودة البيانات: بمجرد جمع العينات، قمنا بالتوجه إلى مدير مكتب وقاية النبات بقطاع الزراعة للتحقق من جودتها من خلال إجراء فحص يدوي للتأكد من صحة العينات.

د- تنظيم البيانات: بعد التحقق من جودة العينات، تم تنظيمها بطريقة مناسبة وفقاً لنوع الإصابة إلى ثلاث فئات (3 Classes)، وهذه الفئات هي: الأوراق السليمة (Healthy)، آفة ذبابة الزيتون (Olive Leaf fly)، آفة فراشة الياسمين (Jasmine Butterfly).

هـ- توثيق البيانات: تمت عملية توثيق العينات التي تم جمعها وتحويلها إلى بيانات قابلة للعمل عليها من خلال استخدام عدة أدوات وهي: كاميرا (Canon 250D)، وعدسة (EF 70-200mm)، وصندوق اضاءة.

## 1.6 جمع البيانات

هي خطوة حاسمة نظراً لأن دقة النظام تعتمد بشكل كبير على عينات الصور لأغراض التدريب.

### 1. مجموعة البيانات المجمعة ذاتياً من قبل الباحث.

في هذا الجزء تم المرور بعدة مراحل للوصول إلى مجموعة بيانات ذات مصداقية ودقة تناسب الأبحاث العلمية.

#### أ- تحديد مصادر البيانات:

لتحديد مصادر البيانات بالشكل المناسب، تم المرور بعدة مراحل:

- تحديد نوع البيانات: قبل البدء في عملية تجميع البيانات، يجب تحديد نوع البيانات التي تتناسب مع هذه الدراسة. بما أن دراستنا تعمل على اكتشاف وتصنيف الآفات والأمراض في أشجار الزيتون باستخدام تقنيات التعلم العميق، فبالتالي نوع البيانات المناسب هو الصور لأوراق الزيتون المصابة والسليمة.
- البحث عن مصادر لجمع البيانات: بعدما قمنا بتحديد نوع البيانات المناسب، بدأنا في البحث عن مصادر البيانات المناسبة. من خلال الزيارات الميدانية لوزارة الزراعة والثروة الحيوانية بمدينة مصراته، والحصول على الاستشارات في تحديد أنواع الأمراض والآفات النشطة في ليبيا من قبل مكتب وقاية النبات بقطاع الزراعة. حيث تم اختيار الآفات النشطة من شهر 5 إلى شهر 8 في أشجار الزيتون

\*Corresponding author:

E-mail addresses: elrowayati@yahoo.com, m09181086@it.misuratau.edu.ly , m09181064@it.misuratau.edu.ly

(Convolution layer)، وتلها طبقة (Max-pooling layer)، وبينهما طبقة التنشيط (ReLU). تعمل طبقة (Convolution layer) عند كل مجموعة على تنفيذ عملية (convolution) على الصورة المدخلة باستخدام مجموعة محددة من (Filters) المخصصة لهذه المجموعة. يتم إنشاء خرائط الميزات (Feature map) بواسطة هذه العملية. بعد ذلك، تمرر خرائط الميزات إلى طبقة التنشيط (ReLU)، التي تقوم بتحويل الإشارات السالبة إلى صفر والإشارات الموجبة دون تغيير، وبذلك تعمل على تفعيل الميزات المهمة وتقليل الضوضاء في البيانات.

بعد ذلك، يأتي دور طبقة (Max-pooling layer)، حيث تقوم بتقليل الأبعاد المكانية لخرائط الميزات (Feature map) التي تم إنشاؤها بواسطة طبقة (Convolutional layer). تقوم طبقة (Max-pooling layer) بتحديد القيمة القصوى لكل منطقة في الخريطة، وبذلك تقلل من حجم البيانات وتقوم بتسهيل عملية التعلم وتحسين الأداء العام لنموذج الشبكة العصبية الالتفافية.

### 2.3.6 التصنيف (Classification):

التصنيف هو عملية تحليل السمات وتصنيف البيانات إلى فئات مختلفة باستخدام النماذج العصبية الالتفافية، وذلك من خلال استخراج الميزات وتطبيق طبقات الاتصال الكاملة للحصول على النتائج النهائية للتصنيف.

في سياق الشبكات العصبية الالتفافية، يتم تنفيذ عملية التصنيف في المرحلة الأخيرة. بعدما تقوم طبقة (Flatten) بتحويل خرائط الميزات (Feature map) من مصفوفات إلى متجهات، تقوم طبقة (Full connection layer) بربط جميع الميزات الناتجة من مرحلة استخراج الميزات بالطبقة الكثيفة (Dense) التي بدورها تكون النتيجة النهائية للشبكة العصبية وتصنف الصورة إلى أوراق سليمة أو مصابة بمرض أو آفة معينة.

### 4.6 خوارزميات التحسين

تعتبر خوارزميات التحسين عنصرًا أساسيًا في عملية تدريب النماذج العميقة، حيث تحدد بشكل كبير سرعة وفعالية عملية التعلم. من بين أشهر هذه الخوارزميات، نجد خوارزمية آدم (ADAM) وخوارزمية نزول التدرج العشوائي (SGD). خوارزمية نزول التدرج العشوائي (SGD) هي أبسط الخوارزميات وتقوم بتحديث معاملات النموذج في الاتجاه المعاكس لتدرج دالة الخسارة. تتميز ببساطتها وفعاليتها الحسابية، ولكنها قد تعاني من التذبذب حول الحد الأدنى العام وتتطلب ضبطاً يدوياً لمعدل التعلم [17].

خوارزمية آدم (ADAM): هي خوارزمية أكثر تعقيداً وتكيف مع معدل التعلم لكل معلمة بشكل فردي، مما يجعلها أسرع في التقارب وأكثر استقراراً من SGD [17]. الجدول (2) يعطي مقارنة بين الخوارزميتين.

جدول 2: مقارنة بين خوارزميتي التحسين [17]

الميزة	SGD	Adam
البساطة	بسيط	معقد
الفعالية الحسابية	عالية	متوسطة
سرعة التقارب	بطيئة نسبياً	سريعة
الاستقرار	منخفض	عالي
التكيف مع معدل التعلم	لا	نعم

### 5.6 التقييم (Evaluation):

لتقدير دقة النماذج المقترحة ومقارنتها، تم استخدام بعض مقاييس التقييم للتأكد من موثوقية النتائج.

و- تقسيم البيانات: في هذه المرحلة تم تقسيم البيانات إلى مجموعة التدريب (Training) وتمثل (70%)، ومجموعة التحقق (Validation) وتمثل (10%) ومجموعة الاختبار (Testing) وتمثل (20%). تم استخدام مجموعة التدريب لتعليم النموذج، ومجموعة التحقق لمراقبة أداء النموذج أثناء التدريب وضبط المعاملات، ومجموعة الاختبار لتقييم دقة التدريب.

### 2. مجموعة البيانات المتاحة على الانترنت.

تم الحصول عليها من خلال منصة (GitHub)، وتعتبر منصة (GitHub) منصة تطوير برمجيات تستخدم لإدارة ومشاركة مشاريع البرمجة المختلفة، والذي يسمح للمستخدمين أيضاً بالعثور على مجموعات البيانات ونشرها. حيث تتكون مجموعة البيانات من 6961 صورة مقسمة إلى ثلاث فئات (3 Classes)، وهذه الفئات هي: الأوراق السليمة، آفة عث الصدا، مرض بقعة عين الطاووس، هذه الصور كانت من نوع JPEG وحجمها 600 x 800 بيكسل.

### 2.6 المعالجة المسبقة للبيانات

مرحلة المعالجة المسبقة في التعلم العميق هي إحدى الخطوات الأساسية في تجهيز البيانات قبل إدخالها إلى نماذج التعلم العميق. يتم استخدام هذه المرحلة لتحسين جودة البيانات وتسهيل عملية التدريب وزيادة كفاءة النماذج. تمت مرحلة المعالجة المسبقة في هذه الدراسة على عدة خطوات مختلفة. وهي كالتالي:

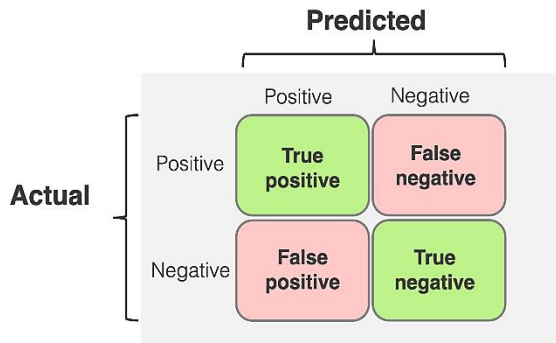
- تغيير حجم الصورة (resizing): في هذه العملية تم تغيير حجم الصورة من (600x600) إلى (256x256)؛ وذلك للحصول على صور موحدة ومتوافقة لإدخالها إلى النموذج بالشكل المناسب مع مراعاة عدم اقتصاص أي جزء من النسخة الأصلية للصورة.
- إعادة القياس (Rescaling): في هذه العملية تم تحويل كل بكسل من النطاق [0, 255] إلى [0, 1]، وذلك لتغييرها من نظام (RGB) إلى التدرج الرمادي (Grayscale)؛ وذلك لتسهيل عملية استخدام الصور في التحليل واستخراج المميزات بدقة وسهولة.
- زيادة البيانات (Data Augmentation): تهدف عملية زيادة البيانات إلى إنشاء نماذج تعمم بشكل أفضل عند التعامل مع بيانات جديدة غير معروفة، وفي هذه الدراسة تم استخدام عملية (Horizontal Flip) بمقدار 0.2.

### 3.6 اختيار النموذج

في هذه الخطوة يتم تحديد النموذج الذي سيتم تدريبه وهذه الخطوة تنقسم إلى مرحلتين أساسيتين في جميع النماذج، هما:

### 1.3.6 استخراج الميزات (Feature Extraction)

استخراج الميزات من الصور في نماذج التعلم العميق هو عملية هامة تُستخدم لتحويل الصور من تمثيلات بكسل واحدة إلى تمثيلات أكثر ابتكاراً وقدرة على الاستدلال. يساعد استخراج الميزات في التعلم العميق على تمثيل الصور بشكل معنوي وفهم المحتوى والسمات الأساسية فيها. وتتمثل الميزات التي يمكن استخراجها من الصور في الحواف (edges). وبالتالي يمكن استخدام هذه الميزات المستخرجة من الصور للتعرف على أنواع الأمراض في أشجار الزيتون. تتألف عملية استخراج الميزات من الصور في بناء نموذج تعلم عميق لتصنيف أمراض وأفات شجرة الزيتون من مجموعات متتابعة تسمى (Blocks). تتكون كل مجموعة من طبقات مختلفة، بدءاً من طبقة



شكل 4: مفهوم مصفوفة الارتباك

### 7. النتائج والمناقشة

في هذا القسم سنقوم بعرض نتائج اختبار وتقييم نماذج الشبكات العصبية الالتفافية المستخدمة، والتي تم تدريبها على مجموعتين من البيانات: مجموعة البيانات المحلية ومجموعة البيانات من منصة GitHub، وذلك لغرض المقارنة بين نماذج الشبكات العصبية الالتفافية المستخدمة من حيث قدرتها ودقتها في اكتشاف وتصنيف أمراض وأفات أشجار الزيتون. كما سنقوم بعرض نتائج هذه النماذج مع خوارزميات التحسين ADAM وSGD. حيث يتضح تأثير خوارزميات التحسين من خلال النتائج التي سيتم عرضها.

#### • نتائج مجموعة البيانات المحلية (Local Dataset):

الجدول (3) والشكل (5) يلخصان نتائج اختبار النماذج المستخدمة على مجموعة البيانات المحلية، نلاحظ أن نموذج (Xception) مع خوارزمية التحسين (SGD) حقق أفضل نتائج مع مجموعة البيانات المحلية. نموذج (Xception) تميز ببنائه العميقة والفعالة التي تجعله قادر على استخلاص ميزات معقدة من البيانات. وبالتالي، حتى مع خوارزمية تحسين بسيطة مثل SGD، يمكن لـ Xception أداء ممتاز.

#### جدول 3: نتائج النماذج على مجموعة البيانات المحلية

Model	Optimizer	Accuracy	Precision	Recall	F1-score
Xception	Adam	%96	%96	%97	%96
	SGD	%99	%99	%99	%99
VGG16	Adam	%95	%95	%96	%95
	SGD	%94	%95	%95	%95
Proposed model	Adam	%95	%95	%96	%95
	SGD	%81	%83	%81	%82

• الدقة (Accuracy): لقياس النسبة بين عدد الصور التي تم تصنيفها بشكل صحيح وإجمالي عدد الصور. يمكنك قياس الدقة على مقياس من 0 إلى 1 أو كنسبة مئوية. فكلما زادت الدقة، كلما كان ذلك أفضل. وبشكل عام الدقة تشير إلى مدى قرب التنبؤات من القيم الحقيقية، وهي مقياس شامل لأداء النموذج [18]. ويمكن التعبير عنها كما بالمعادلة رقم (1):

$$Accuracy = \frac{(TN + TP)}{(TP + FP + TN + FN)} * 100 \quad (1)$$

حيث:

True Positive (TP): هذه هي القيم الصحيحة المتوقعة بشكل صحيح، وهذا يعني أن الفئة الفعلية كانت صحيحة، كما أن توقع النموذج صحيح أيضاً. True Negative (TN): هذه هي القيم التي تكون فيها الفئة الفعلية خاطئة، ولكن الفئة المتوقعة تكون صحيحة.

False Positive (FP): هذه هي القيم التي تكون فئتها الفعلية خاطئة، لكن الفئة المتوقعة تكون صحيحة.

False Negative (FN): هذه هي القيم التي تكون فيها الفئة الفعلية صحيحة، ولكن الفئة المتوقعة تكون خاطئة.

• الضبط (Precision): يستخدم لتقييم انضباط النتائج الإيجابية المتوقعة من نموذج التصنيف. بمعنى آخر، عندما يقول النموذج أن شيئاً ما إيجابي، ما هي احتمالية أن يكون هذا التنبؤ صحيحاً؟ ويمكن التعبير عنها بالمعادلة (2):

$$Precision = \frac{TP}{TP + FP} * 100 \quad (2)$$

• الاستدعاء (Recall): يستخدم لحساب نسبة النتائج الإيجابية التي تم تصنيفها بشكل صحيح من إجمالي عدد النتائج الإيجابية. الاستدعاء يقيس مدى قدرة النموذج على تحديد جميع الحالات الإيجابية. يتم استخدام هذا المقياس عندما نريد أن نركز على تقليل الأخطاء السلبية الكاذبة. على سبيل المثال، في نموذج تشخيص أمراض الزيتون، قد نريد التأكد من أن النموذج لا يفوت أي شجرة مصابة بمرض معين. ويمكن التعبير عنها بالمعادلة (3): [19]

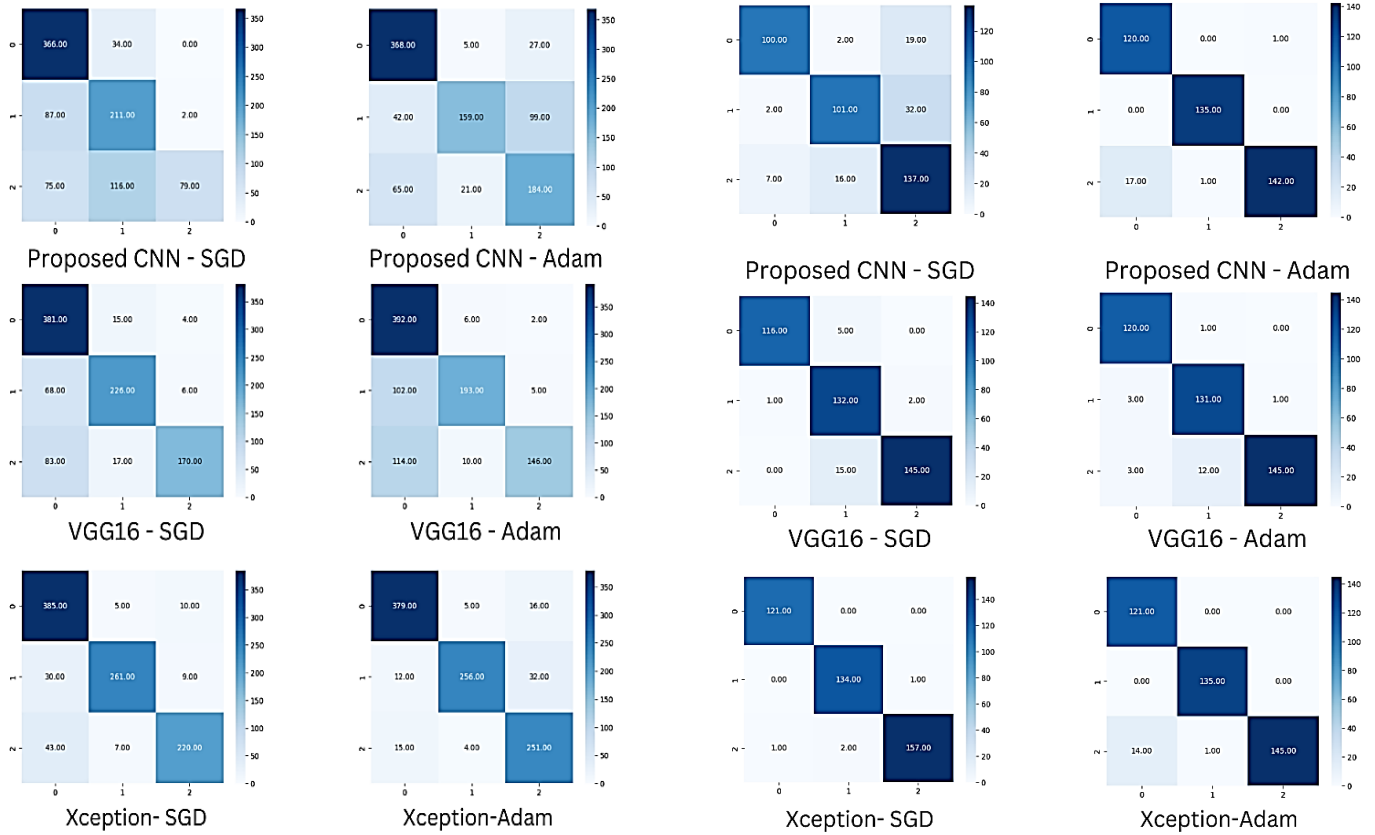
$$Recall = \frac{TP}{TP + FN} * 100 \quad (3)$$

• المقياس الشامل (F1-score): يعتبر مقياساً توافقي يجمع بين الضبط والاستدعاء (Precision) و (Recall) في مقياس واحد. وتتراوح قيمته بين 0 و1، حيث تمثل القيمة 1 أفضل أداء للنموذج. ويمكن التعبير عنها بالمعادلة (4): [19]

$$F1 - Score = \frac{2 * (Precision * Recall)}{(Precision + Recall) * 100} \quad (4)$$

• مصفوفة الثقة أو الارتباك (Confusion Matrix): هي جدول يستخدم في تعلم الآلة لتصنيف البيانات كما هو موضح بالشكل (4). تُظهر هذه المصفوفة بشكل واضح كيف قام نموذج التصنيف بتصنيف البيانات، سواء بشكل صحيح أو خاطئ. بمعنى آخر، فهي تُقارن بين التنبؤات التي قام بها النموذج والقيم الفعلية للبيانات. القطر الرئيسي: يمثل العناصر التي تم تصنيفها بشكل صحيح. العناصر خارج القطر الرئيسي: تمثل الأخطاء التي ارتكبها النموذج. كل خلية: تمثل عدد العينات التي تقع في تلك الفئة [20].





شكل 6: نتائج مجموعة البيانات المتاحة على منصة (GitHub) باستخدام مصفوفة الارتباك

شكل 5: نتائج اختبار النماذج على مجموعة البيانات المحلية باستخدام مصفوفة الارتباك

المقارنة مع الدراسات السابقة، تجاوزت نتائج هذه الدراسة نتائج دراسات سابقة مماثلة، مثل دراسة Sinan وزملائه، حيث حقق نموذجنا دقة أعلى بكثير. يعود هذا التحسن إلى عدة عوامل، منها: استخدمنا مجموعة بيانات محلية ذات جودة عالية وتنوع أكبر، تبين أن نموذج (Xception) هو الخيار الأمثل لهذه المهمة. ضبط المعلمات: قمنا بضبط معلمات النموذج والخوارزمية لتحقيق أفضل أداء.

نتائج مجموعة البيانات المتاحة على الانترنت من منصة (GitHub): الجدول (4) يلخص نتائج اختبار النماذج المستخدمة على مجموعة البيانات من منصة (GitHub)، نلاحظ أن نموذج (Xception) مع خوارزمية التحسين (Adam) حقق أفضل نتائج مع مجموعة البيانات المتاحة على الانترنت ضمن منصة (GitHub).

8. الاستنتاجات والتوصيات  
1.1.8 الاستنتاجات

ساهمت هذه الدراسة في تجميع مجموعة بيانات جديدة لم يتم تجميعها من قبل في هذه المنطقة الجغرافية، والتي يمكن استخدامها لإجراء مجموعة مختلفة ومتنوعة من الاختبارات ومقارنتها مع نتائج دراسات سابقة، أيضاً ساهمت الدراسة في إبراز نتائجها من خلال تفوقها في نتائج نموذج Xception عن باقي جميع الدراسات السابقة التي كانت من ضمن نطاق الدراسة. كما اعتمدت هذه الدراسة على استخدام تقنية التعلم العميق بعد أن أثبتت جدارته في تحقيق نتائج مرضية في تصنيف أمراض وأفات النباتات المختلفة، واعتمدت هذه الدراسة على تقنية CNN والتي تعتبر من أشهر تقنيات التعلم العميق في مجال تصنيف وتمييز الصور، وتقييم مدى كفاءة هذه النماذج في اكتشاف وتصنيف الأمراض والأفات بدقة عالية، وكذلك تقييم التأثير الناتج من استخدام مجموعات البيانات المختلفة على النتائج.

من خلال ما تم عرضه من نتائج، نلاحظ أن هناك فرقاً واضحاً بين النماذج المدربة مسبقاً، والنموذج المقترح أو غير المدرب مسبقاً، حيث كانت الأفضلية للنماذج المدربة مسبقاً في دقة النتائج على مجموعتي البيانات. وقد يرجع ذلك إلى أن النماذج المدربة مسبقاً تكون مدربة على مجموعات كبيرة من البيانات

جدول 4: نتائج النماذج على مجموعة بيانات GitHub

Model	Optimizer	Accuracy	Precision	Recall	F1-score
Xception	Adam	%91	%91	%91	%91
	SGD	%89	%91	%88	%89
VGG16	Adam	%75	%84	%72	%74
	SGD	%80	%85	%78	%79
Proposed model	Adam	%73	%74	%71	%71
	SGD	%68	%75	%74	%63

مما سبق نلاحظ أن النتائج التي تم عرضها في الجدول (3) تبين أن نموذج (Xception) مع البيانات المحلية وخوارزمية التحسين (SGD) وصل إلى دقة إجمالية تبلغ 99% وهي أعلى دقة تم الوصول إليها. علاوة على ذلك، فقد وصلت إلى 99% و99% و99% من حيث precision و recall و F1-score على التوالي. ويرجع هذا التفوق إلى أن هيكلية ال (Xception) تناسب بشكل أفضل من النماذج الأخرى مع خصائص مجموعة البيانات المحلية مقارنة بخصائص مجموعة البيانات المتاحة على منصة (GitHub) من حيث الضوضاء أو نوع الأمراض أو تعقيد الخلفية أي أن النموذج (Xception) المدرب على البيانات المتاحة على منصة (GitHub) واجه بعض التحديات مما أدى إلى تقليل أداء النموذج، حيث وصل إلى أعلى دقة 91% مع نموذج (Xception) وخوارزمية التحسين (Adam) كما مبين في الجدول (4) والشكل (6).

- [3]- K. Aggarwal et al., "Has the future started? The current growth of artificial intelligence, machine learning, and deep learning," *Iraqi J. Comput. Sci. Math.*, 2022, doi: 10.52866/ijcsm.2022.01.01.013.
- [4]- S. Vaid, R. Kalantar, and M. Bhandari, "Deep learning COVID-19 detection bias: accuracy through artificial intelligence," *Int. Orthop.*, vol. 44, no. 8, pp. 1539–1542, Aug. 2020, doi: 10.1007/S00264-020-04609-7.
- [5]- إبراهيم، عاطف محمد، حجاج، محمد نظيف، شجرة الزيتون: زراعتها ورعايتها وإنتاجها، الطبعة الأولى، منشأة المعارف، 2007.
- [6]- [جمال، محمد حسني، السوسو، مواهب، مورفولوجيا وتصنيف شجرة الزيتون، 2016. <https://almerja.com/reading.php?i=1&ida=1437&id=706&idm=.50927> (accessed Jun. 08, 2024)
- [7]- Karn and Ujjwal, "An intuitive explanation of convolutional neural networks," *data Sci. blog*, 2016, Accessed: Jun. 06, 2024. [Online]. Available: [https://scholar.google.com/scholar?hl=en&as\\_sdt=0%2C5&q=7.%09Karn%2C+U.+%282016%29.+An+intuitive+explanation+of+convolutional+neural+networks.+The+data+science+blog&btnG=](https://scholar.google.com/scholar?hl=en&as_sdt=0%2C5&q=7.%09Karn%2C+U.+%282016%29.+An+intuitive+explanation+of+convolutional+neural+networks.+The+data+science+blog&btnG=).
- [8]- S. Sakib, N. Ahmed, A. Kabir, and H. Ahmed, "An overview of convolutional neural network: Its architecture and applications," *Preprints*, 2019, [Online]. Available: <https://www.preprints.org/manuscript/201811.0546>.
- [9]- C. Li, Z. Zhang, and W. Lee, "Convolutional sequence to sequence model for human dynamics," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 5226–5234, [Online]. Available: [http://openaccess.thecvf.com/content\\_cvpr\\_2018/html/Li\\_Convolutional\\_Sequence\\_to\\_CVPR\\_2018\\_paper.html](http://openaccess.thecvf.com/content_cvpr_2018/html/Li_Convolutional_Sequence_to_CVPR_2018_paper.html).
- [10]- A. R. Muslikh, D. D. R. I. Setiadi, and A. Ojugo, "Rice Disease Recognition using Transfer Learning Xception Convolutional Neural Network," *Jurnal Tek. Inform.*, vol. 4, no. 6, pp. 1541–1547, 2023.
- [11]- S. Uğuz and N. Uysal, "Classification of olive leaf diseases using deep convolutional neural networks," *Neural Comput. Appl.*, vol. 33, no. 9, pp. 4133–4149, May 2021, doi: 10.1007/S00521-020-05235-5.
- [12]- A. Ksibi, M. Ayadi, B. O. Soufiene, M. M. Jamjoom, and Z. Ullah, "MobiRes-net: a hybrid deep learning model for detecting and classifying olive leaf diseases," *Appl. Sci.*, vol. 12, no. 20, p. 10278, 2022.
- [13]- Alshammari, H., Gasmı, K., Krichen, M., Ammar, L. B., Abdelhadi, M. O., Boukrara, A., & Mahmood, M. A. (2022). Optimal deep learning model for olive disease diagnosis based on an adaptive genetic algorithm. *Wireless Communications and Mobile Computing*, 2022, 1-13.
- [14]- Alshammari, Hamoud H., Ahmed I. Taloba, and Osama R. Shahin. "Identification of olive leaf disease through optimized deep learning approach." *Alexandria Engineering Journal* 72 (2023): 213-224.
- [15]- Bocca, Pedro, Adrian Orellana, Carlos Soria, and Ricardo Carelli. "On field disease detection in olive tree with vision systems." *Array* 18 (2023): 100286.
- [16]- Diker, A., Elen, A., Közkurt, C. et al. An effective feature extraction method for olive peacock eye leaf disease classification. *Eur Food Res Technol* 250, 287–299 (2024). <https://doi.org/10.1007/s00217-023-04386-8>.
- [17]- Dozat, Timothy. "Incorporating Nesterov Momentum into Adam." (2016).

مثل (ImageNet) مما يعطيها الأفضلية من حيث استخلاص الميزات وتصنيفها بدقة أعلى. وكان أيضاً هناك فارق ملحوظ في نتائج النماذج المدربة على مجموعة البيانات المحلية والنماذج المدربة على مجموعة البيانات المتاحة على الانترنت، حيث كان التفوق لمجموعة البيانات المحلية على مجموعة البيانات المتاحة على الانترنت؛ وقد يرجع ذلك لعدة أسباب مثل جودة الصور، أو اختلافات المرض، أو تعقيد الخلفية.

وفي الختام يمكن استخدام النموذج بشكل عملي من قبل المزارعين أو الخبراء الزراعيين بعد أن يتم تطويره بصورة أكثر توسع ليشمل مجموعة أكبر من الأفات والأمراض ومن ثم استخدام هذا النموذج ودمجه بصورة فعالة مع تطبيقات الهواتف المحمولة، والتي بدورها تسهل على المزارعين من خلال إدخال البيانات أو صورة مباشرة للنظام، ومن ثم الحصول على الاستشارات في الوقت الفعلي.

## 2.8. التوصيات

في هذه الدراسة تم تصميم وتنفيذ عدد من النماذج والقيام بالتجارب على ثلاث آفات ومرض واحد، وبالتالي يمكن اقتراح عدد من الأعمال المستقبلية التي يمكن من خلالها تطوير هذه الدراسة كالتالي:

- تطوير هذه الدراسة بحيث تشمل أنواعاً أكثر من الأمراض والأفات المختلفة مثل الأمراض والأفات الخاصة بأشجار الليمون، وأشجار التفاح، وذلك للمساعدة والمساهمة في تصنيف أكبر قدر ممكن من هذه الإصابات السنوية التي تصيب النباتات بصفة عامة.
- القيام بالمزيد من المعالجة المسبقة على مجموعة البيانات المتاحة على (GitHub)، لتحقيق نتائج محسنة للتي تم الوصول إليها في هذه الدراسة.
- زيادة مجموعة البيانات المحلية وذلك بدراسة أمراض أشجار الزيتون في ترونة ومسلاته وكذلك منطقة الجبل الأخضر ليكون النموذج المقترح أكثر مرونة وفاعلية ودقة.
- إنشاء تطبيق للهاتف يستخدم هذه النماذج المقترحة، بحيث يساعد بدوره المزارعين والأشخاص الأقل خبرة في تصنيف هذه الأمراض ومن ثم اقتراح الأساليب المناسبة للعلاج.

## 3. شكر وتقدير

نتقدم بجزيل الشكر للعاملين بمكتب وقاية النبات بوزارة الزراعة بدولة ليبيا على مساعدتهم التي قدموها لنا خلال فترة تجميع البيانات المحلية من تحديد مصادر البيانات إلى مراجعة وفحص وتصنيف وتوثيق البيانات. وأيضاً نتقدم بجزيل الشكر الى مدير مكتب الشبكات والبنية التحتية بالهيئة العامة للاتصالات على إمداده لنا بالوصول إلى خادم ويندوز بمواصفات عالية للقيام بالتجارب على أكمل وجه.

## 4. قائمة المراجع

- [1]- S. Kaur, S. Pandey, and S. Goel, "Plants Disease Identification and Classification Through Leaf Images: A Survey," *Arch. Comput. Methods Eng.*, vol. 26, no. 2, pp. 507–530, Apr. 2019, doi: 10.1007/S11831-018-9255-6.
- [2]- R. D'Andria, A. Lavini, A. Tombesi, S. Saavedra, and محمد علي ، تقنيات الانتاج في زيت الزيتون، الطبعة الأولى ، مدريد 2007.

- [18]- Novaković, Jasmina Dj, Alempije Veljović, Siniša S. Ilić, Željko Papić, and Milica Tomović. "Evaluation of classification models in machine learning." *Theory and Applications of Mathematics & Computer Science* 7, no. 1 (2017): 39.
- [19]- Vujović, Ž. "Classification model evaluation metrics." *International Journal of Advanced Computer Science and Applications* 12, no. 6 (2021): 599-606.
- [20]- Beauxis-Aussalet, Emma, and Lynda Hardman. "Simplifying the visualization of confusion matrix." In *26th Benelux conference on artificial intelligence (BNAIC)*. 2014.