



## تصنيف صور حرائق الغابات باستخدام خوارزميات التعلم العميق

بدر نجيب عويدات

كلية تقنية المعلومات، جامعة الزيتونة، ترهونة، ليبيا

### الكلمات المفتاحية:

### المخلص

تقنيات التعلم العميق  
كشف حرائق الغابات  
تصنيف الصور  
صور حرائق الغابات  
الشبكة العصبية التلافيفية العميقة

تعد تقنيات التعلم العميق من بين أهم وأكثر التقنيات تطوراً في مجال الذكاء الاصطناعي خلال العقدين الماضيين. تُظهر هذه التقنيات قدرات استثنائية في تحليل البيانات المعقدة، ومن بين التطبيقات الواعدة للتعلم العميق هي اكتشاف اللهب في الصور بطرق دقيقة وفعالة. خوارزميات التعلم العميق تعتبر وسيلة قوية وفعالة لتصنيف الصور، بما في ذلك تصنيف صور حرائق الغابات. تمثل هذه الخوارزميات جزءاً مهماً من مجال تحليل الصور والرؤية الحاسوبية، حيث يمكنها التعامل مع البيانات ذات البعد العالي والتعرف على الأنماط المعقدة في الصور. تستخدم خوارزميات التعلم العميق في تصنيف صور حرائق الغابات لتحديد وتصنيف المناطق المتأثرة بالحرائق بدقة عالية، مما يمكن من اتخاذ إجراءات سريعة وفعالة للحد من أضرار الحرائق وحماية البيئة والممتلكات. من الجدير بالذكر أن خوارزميات التعلم العميق تتطلب كميات كبيرة من البيانات التدريبية لتحقيق أفضل أداء ممكن، بالإضافة إلى تكنولوجيا متقدمة لمعالجة الصور وتحليلها بكفاءة. باستخدام خوارزميات التعلم العميق في تصنيف صور حرائق الغابات، يمكن تحسين دقة التصنيف وتحديد المناطق المتأثرة بالحرائق بدقة أكبر، مما يمكن من توجيه الجهود والموارد بشكل فعال للتعامل مع الحرائق وتقليل الأضرار الناتجة عنها. في هذا البحث تم استخدام ثلاث خوارزميات تعلم عميقة هي الشبكة العصبية التلافيفية العميقة Deep Convolutional Neural Network (DCNN) ونموذج VGG16 العميق ونموذج MobileNet للكشف عن حرائق الغابات في الصور وقد اعطت خوارزمية MobileNet اعلى نسبة دقة بلغت 100%.

## Classification of forest fire images using deep learning algorithms

Bader N. Awedat

Faculty of Information Technology, Al-Zaytouna University, Tarhuna, Libya

### Keywords:

Deep learning techniques  
Wildfire detection  
Image classification  
Forest fire images  
Deep Convolutional Neural Network

### ABSTRACT

Deep learning techniques have emerged as one of most significant and advanced technologies in field of artificial intelligence over past two decades. These techniques demonstrate exceptional capabilities in analyzing complex data, with one of promising applications being accurate and effective wildfire detection in images. Deep learning algorithms serve as powerful and efficient means for image classification, including classification of forest fire images. These algorithms constitute an important part of field of image analysis and computer vision, as they can handle high-dimensional data and recognize complex patterns in images. Deep learning algorithms are used in classifying forest fire images to accurately identify and classify fire-affected areas, enabling prompt and effective actions to mitigate fire damage and protect environment and properties. It is worth noting that deep learning algorithms require large amounts of training data to achieve optimal performance, in addition to advanced technology for efficiently processing and analyzing images. By using deep learning algorithms in classifying forest fire images, classification accuracy and identification of fire-affected areas can be improved, allowing for effective allocation of efforts and resources to deal with fires and reduce resulting damages. In this study, three deep learning

\*Corresponding author:

E-mail addresses: [bader\\_najep@yahoo.com](mailto:bader_najep@yahoo.com)

Article History : Received 29 April 2024 - Received in revised form 23 August 2024 - Accepted 06 October 2024

algorithms were employed: Deep Convolutional Neural Network (DCNN), VGG16 model, and MobileNet model, for detecting forest fires in images, with MobileNet achieving highest accuracy rate of 100%.

## 1. المقدمة

تتعدد الطرق والتقنيات في مجال تحليل الصور والرؤية الحاسوبية، ومن بين هذه الطرق تبرز خوارزميات التعلم العميق كوسيلة قوية وفعالة لتصنيف الصور، بما في ذلك تصنيف صور حرائق الغابات. يعتبر هذا البحث ضمن الجهود التي تسعى إلى تقييم أداء هذه الخوارزميات وتطبيقها في مجال محدد يتعلق بالحفاظ على البيئة والممتلكات.

تعد حرائق الغابات من الكوارث الطبيعية التي تسبب في أضرار جسيمة على البيئة والاقتصاد والمجتمع، ولذلك يعد تحديد المناطق المتأثرة بها بدقة وسرعة أمراً بالغ الأهمية. وباستخدام خوارزميات التعلم العميق، يمكن تحسين دقة تصنيف هذه المناطق بشكل كبير، مما يمكن من اتخاذ إجراءات سريعة وفعالة للتعامل مع الحرائق وتقليل الأضرار الناتجة عنها.

يعتمد أداء خوارزميات التعلم العميق على كميات كبيرة من البيانات التدريبية وتكنولوجيا متقدمة لمعالجة الصور وتحليلها بكفاءة. ومن خلال استخدام ثلاث خوارزميات تعلم عميقة في هذا البحث، هي الشبكة العصبية التلافيفية العميقة (Deep Convolutional Neural Network) ونموذج VGG16 العميق ونموذج MobileNet، يتم تحليل وتقييم أدائها في تصنيف صور حرائق الغابات وتحديد المناطق المتأثرة بالحرائق بدقة عالية.

يعد هذا البحث مساهمة قيمة في مجال تحليل الصور والرؤية الحاسوبية، ويسهم في تطوير تطبيقات عملية لحماية البيئة والممتلكات والحفاظ عليها من تأثيرات حرائق الغابات.

## 2. الدراسات السابقة

1.2. تمحورت دراسة هاي لي وبنغ سون (2023) حول تطوير نموذج لاكتشاف الحرائق باستخدام تقنيات التعلم العميق، حيث أن الاهتمام زاد بهذا المجال مؤخراً بهدف تقليل فقدان المعلومات الدلالية وتحسين دقة التنبؤ، جمع البحث بين تقنية تقسيم الصور بالأبيض والأسود بعنبة ديناميكية وتعلم النقل باستخدام الشبكات الباقية (Residual Networks). تم تكامل استراتيجية فعالة لتوسيع بيانات التدريب والتي تدمج بين بيانات التجارب على منصة حرائق حقيقية وقاعدة بيانات الصور المستندة إلى الغابات، حيث يتم تصوير بيانات التجارب على منصة حرائق حقيقية بناءً على إضاءات وخلفيات مختلفة. وقد أثبت البحث أن هذه الاستراتيجية تعتبر حلاً فعالاً يمكنه حل مشكلة تدريب النماذج العميقة القوية باستخدام مجموعة بيانات متنوعة وكبيرة، مما يمكن من تحسين الأداء العام لنموذج التدريب.

وقد وصلت دقة مستوى الشبكات الباقية في مهام اكتشاف الحرائق استناداً إلى الصور مع أقل عدد من العمليات الحسابية. تم تدريب النموذج باستخدام مجموعة بيانات صورية تم بناؤها ذاتياً، وتم اختبارها على مجموعة بيانات صور عامة للحرائق. في سياق تجارب عديدة، حققت الطريقة دقة في التدريب والاختبار تبلغ 98.26% و99.90% على التوالي، مع قيمة خسارة بنسبة 0.036 و0.04 [2].

### جدول 1: نتائج دراسة هاي لي واخرون.

الخوارزمية	النموذج المسبق	معدل الدقة
تقنية نقل التعلم مع الشبكات الباقية	بيانات من منصة حرائق حقيقية	دقة التدريب: 98.26%، دقة الاختبار: 99.90%، قيمة
	بناءً على إضاءات وخلفيات مختلفة	

2.2. قالت دراسة ساتيشكومار، ف. إي (2023) أن تطبيق تقنية التعلم النقلي على النماذج المدربة مسبقاً يُظهر تحسناً في الأداء، لكنه قد يؤدي إلى فقدان قدرات التصنيف الأصلية للنماذج. لحل هذه المشكلة، تم استخدام "التعلم دون النسيان (Learning without Forgetting - LwF)" وهو نهج في مجال التعلم الآلي يهدف إلى توسيع قدرات نماذج الذكاء الاصطناعي على التعامل مع مهام جديدة دون أن تفقد القدرات التي تعلمتها سابقاً. أظهرت النتائج أن تقنية التعلم النقلي بالتعلم دون النسيان تحسن من أداء النماذج المقترحة، خاصةً عند التعامل مع مجموعات البيانات الجديدة وغير المعروفة. وبالاعتماد على النتائج التجريبية، تشير الدراسة إلى أن النماذج المقترحة تفوقت على الأساليب الأخرى في هذا المجال، وتبين أن التعلم دون النسيان يمكنه تصنيف مجموعات البيانات الجديدة بنجاح. تناولت الدراسة تطوير أساليب للكشف التلقائي عن الحرائق في الغابات باستخدام تقنيات الرؤية الحاسوبية المبنية على الذكاء الاصطناعي. توضح الدراسة استخدام الشبكات العصبية التلافيفية (CNN) في تحسين أداء التصنيف الصوري، وتسلط الضوء على تحديات التدريب وفقر البيانات. استخدمت الدراسة ثلاثة نماذج هي VGG16 و InceptionV3 و Inception ومجموعتي بيانات هما BoWFire و Original Forest Fire وكانت نتائج النماذج كما في الجدول 2 [3].

### جدول 2: نتائج دراسة ساتيشكومار واخرون.

النموذج	مجموعة البيانات	بدون LwF	مع LwF
VGG16	BoWFire	51.81	76.32
	Original Forest Fire	94.38	92.71
InceptionV3	BoWFire	72.04	87.12
	Original Forest Fire	92.04	93.82
Inception	BoWFire	77.14	89.41
	Original Forest Fire	97.77	94.66

3.2. قامت دراسة هاتيجه جاتال ريس وفيسيل تورك (2023) باستخدام خوارزميات Convolutional Neural Network (CNN) مع تقنية Transfer Learning لكشف حرائق الغابات. استخدمت الدراسة مجموعة بيانات من 3000 صورة، منها 1500 صورة لحرائق الغابات و 1500 صورة لا تحتوي على حرائق الغابات.

تم تدريب الخوارزميات الخمسة التالية على مجموعة البيانات:

النموذج M-1: خوارزمية CNN بدون تقنية Transfer Learning

النموذج M-2: خوارزمية CNN مع تقنية Transfer Learning باستخدام VGG16.

النموذج M-3: خوارزمية CNN مع تقنية Transfer Learning باستخدام ResNet50.

النموذج M-4: خوارزمية CNN مع تقنية Transfer Learning باستخدام InceptionV3.

النموذج M-5: مزيج من CNN و SVM مع تقنية Transfer Learning باستخدام VGG16.

وقد تم تدريب النماذج M-2 و M-3 و M-4 و M-5 مسبقاً على مجموعة بيانات ImageNet التي تحتوي على أكثر من 14 مليون صورة مُصنفة. وقد

شكل الحريق وحجمه. تم تدريب هذا النموذج على مجموعة بيانات من 1000 صورة، منها 600 صورة لحرائق غابات و 400 صورة غير حرائق غابات. تم تقسيم مجموعة البيانات إلى مجموعة تدريب ومجموعة اختبار بنسبة 70٪ إلى 30٪. تم استخدام مجموعة التدريب لتدريب النموذج، وتم استخدام مجموعة الاختبار لتقييم أدائه. أظهرت نتائج الدراسة أن النموذج مزدوج القنوات حقق دقة بنسبة 98.90٪، وهي أعلى من دقة نماذج التعلم العميق الأخرى. وكان للنموذج أيضاً دقة عالية (Precision) بنسبة 99.24٪ واسترجاع (Recall) 98.55٪ [6].

### جدول 5: نتائج دراسة تشاواي تشانغ واخرون.

اسم القناة	عدد القنوات	المدرّب مسبقاً	الدقة	النموذج
RGB	1	نعم	95.88%	المدرّب مسبقاً AlexNet
TIR	1	نعم	97.78%	المُحسّن باستخدام نقل AlexNet التعلم
TIR, بانكروماتيك	2	نعم	98.90%	نموذج شبكات عصبية اصطناعية مزدوجة القنوات

### 3. المواد وطرق العمل

تم العمل على مجموعة بيانات مكونة من 999 صورة لحرائق الغابات مقسمة لفئتين، الفئة الأولى non fire images تحتوي على 244 صورة. والفئة الثانية fire image تحتوي على 755 صورة.

تم العمل على ثلاثة نماذج عميقة هي الشبكة العصبية التلافيفية (CNN)، نموذج ناقل التعلم VGG16 using Transfer Learning والنموذج المدرّب مسبقاً MobileNet.

### 4. مجموعة البيانات:

تم إنشاء مجموعة البيانات في تحدي NASA Space Apps عام 2018. تم جمع البيانات لتدريب نموذج يمكنه التمييز بين الصور التي تحتوي على الحريق (صور الحريق) والصور العادية (صور غير الحريق) [1]. تم تقسيم البيانات إلى مجلدين، مجلد fire images يحتوي على 755 صورة خارجية للحرائق، تحتوي بعضها على دخان كثيف، والآخر هو non fire images الذي يحتوي على 244 صورة طبيعية (مثل: غابة، شجرة، عشب، نهر، أشخاص، غابة مغمورة بالضباب، بحيرة، حيوانات، طريق، وشلال). البيانات متحيزة، مما يعني أن المجلدين لا يحتويان على عدد متساوٍ من العينات. وتم استخدام 800 صورة للتدريب و 199 صورة للتحقق. تم استخدام التقسيم المتقاطع (Cross-Validation) لتقسيم البيانات إلى بيانات تدريب واختبار وتحقيق بشكل متقاطع. تقسيم البيانات إلى بيانات تدريب بنسبة 80% و 20% بيانات للاختبار. وتم تقسيم بيانات التدريب إلى بيانات تدريب بنسبة 80% من بيانات التدريب و 20% من البيانات للتحقق. مما يعني أنه تم استخدام التقسيم المتقاطع حيث تم استخدام كل من بيانات التدريب وبيانات التحقق في تقييم الأداء عدة مرات مع تغيير البيانات المستخدمة في كل مرة.

أظهرت النتائج أن الخوارزمية M-5 هي الخوارزمية التي حققت أفضل أداء، حيث بلغت معدل دقة 97.5%.

تشير النتائج إلى أن استخدام خوارزميات CNN مع تقنية Transfer Learning يمكن أن يحسن بشكل كبير أداء خوارزميات الكشف عن حرائق الغابات [4].

### جدول 3: نتائج دراسة هاتيجه جاتال ريس واخرون.

الخوارزمية	النموذج المسبق	معدل الدقة
M-1	CNN بدون تقنية Transfer Learning	92.5%
M-2	CNN مع تقنية Transfer Learning باستخدام VGG16	95.0%
M-3	CNN مع تقنية Transfer Learning باستخدام ResNet50	95.5%
M-4	CNN مع تقنية Transfer Learning باستخدام InceptionV3	96.0%
M-5	مزيج من CNN و SVM مع تقنية Transfer Learning باستخدام VGG16	97.5%

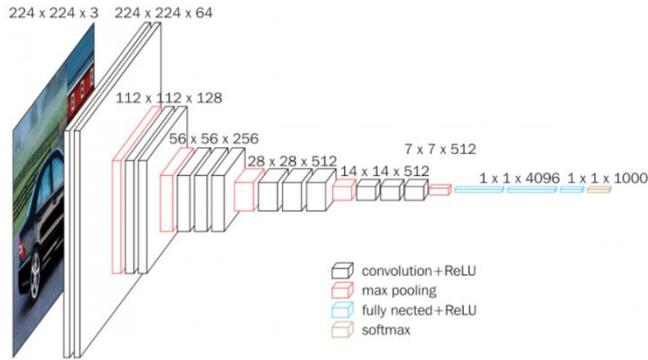
4.2 في دراسة سوها بيرك كوكوك وزينب هلال كيليمجي (2021)، تم استخدام خوارزميات ResNet-18, VGG16, DenseNet121, Inception-V3, Random Forest, Support Vector Machines (SVM), k-Nearest Neighbors (KNN) على مجموعة بيانات من صور الأقمار الصناعية لحرائق الغابات في تركيا. تتكون المجموعة من 1000 صورة، 500 منها تحتوي على حرائق غابات و 500 منها لا تحتوي على حرائق غابات. تم تقسيم البيانات إلى مجموعة تدريب (80%) ومجموعة اختبار (20%). وتوصلت الدراسة إلى أن نماذج التعلم العميق، مثل نموذج ResNet-18، كانت أكثر دقة في اكتشاف حرائق الغابات من النماذج التقليدية، مثل نموذج Random Forest. وقد كان نموذج ResNet-18 قادراً على تحقيق معدل اكتشاف صحيح يبلغ 95٪، بينما كان نموذج Random Forest قادراً على تحقيق معدل اكتشاف صحيح يبلغ 85٪. أظهرت النتائج أن نماذج التعلم العميق يمكن أن تكون أداة قيمة لاكتشاف حرائق الغابات في الوقت المناسب. ويمكن أن تساعد هذه النماذج في تقليل الخسائر البشرية والمادية الناجمة عن حرائق الغابات [5].

### جدول 4: نتائج دراسة سوها بيرك كوكوك واخرون.

النموذج	دقة النموذج
ResNet-18	95%
VGG16	94%
DenseNet121	93%
Inception-V3	92%
Random Forest	85%

5.2 في دراسة تشاواي تشانغ واخرون (2023) استخدمت ثلاثة نماذج لشبكات عصبية اصطناعية CNN تعتمد على نموذج AlexNet. هذه النماذج هي نموذج AlexNet المُدرّب مسبقاً يعتمد على نموذج AlexNet الأصلي والذي يستخدم قناة واحدة فقط هي قناة RGB. ونموذج AlexNet المُحسّن والمدرّب مسبقاً يعتمد على نموذج AlexNet الأصلي ويستخدم قناة واحدة فقط هي قناة TIR. ونموذج AlexNet مزدوج القنوات يعتمد على نموذج AlexNet ولكنه يستخدم قناتين، واحدة هي قناة TIR والأخرى هي قناة بانكروماتيك. نموذج الشبكات العصبية الاصطناعية مزدوج القنوات هو نموذج ينقسم إلى قناتين رئيسيتين هما قناة TIR وتركز هذه القناة على بيانات الأشعة تحت الحمراء الحرارية، والتي يمكن أن تكون مفيدة في الكشف عن حرائق الغابات لأنها تميل إلى أن تكون أكثر سخونة من المناطق المحيطة بها. وقناة بانكروماتيك وتركز هذه القناة على بيانات كثافة الإشعاع الكهرومغناطيسي في جميع الأطوال الموجية المرئية. يمكن أن تكون هذه البيانات مفيدة في الكشف عن حرائق الغابات لأنها يمكن أن تساعد في تحديد

5.2.5. دوال التنشيط: تستخدم ReLU في الطبقات التنشيطية و Sigmoid في الطبقة النهائية لتوليد احتمالات الفئات.



الشكل 3: الهندسة العامة لنموذج VGG16 [9].

3.5. نموذج MobileNet: هو نموذج خفيف الوزن ومنخفض القدرة الحاسوبية مصمم خصيصًا لتطبيقات الرؤية الحاسوبية على الأجهزة المحمولة. يتم تحميل النموذج الأساسي (MobileNet) مع الوزن المدرب مسبقًا على مجموعة البيانات ImageNet.

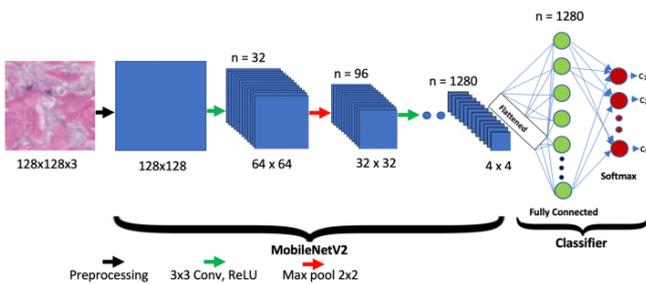
المكونات: يتكون النموذج المستخدم في الدراسة من

1.3.5. نموذج MobileNet: مسبق التدريب لتحليل الصور واستخراج الميزات.

2.3.5. طبقة GlobalAveragePooling2D: تقليل الأبعاد للبيانات المعقدة.

3.3.5. طبقة Dense: كاملة الاتصال لتصنيف الصور.

4.3.5. دوال التنشيط: تستخدم ReLU في الطبقات التنشيطية و Sigmoid في الطبقة النهائية لتوليد احتمالات الفئات.



الشكل 4: الهندسة العامة لنموذج MobileNet [10].

6. معايير تقييم الخوارزميات:

بعد بناء أحد نماذج خوارزميات التصنيف يتم تطبيق عدة معايير لتأكد من صحة التصنيف ونتائج الخوارزمية ومنها:

1.6. نسبة صحة خوارزمية التصنيف (Accuracy):

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} = \frac{\text{TP} + \text{TN}}{\text{P} + \text{N}} \quad (1)$$

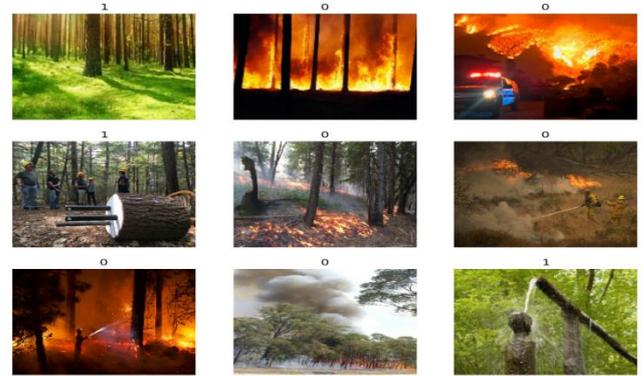
حيث أن:

TP = (True Positives): هو عدد السجلات التي تم التنبؤ بفتحها بشكل صحيح.

TN = (True Negatives): هو عدد السجلات التي تم التنبؤ بها لو رفضها ضمن الفئة بشكل صحيح.

FP = (False Positives): هو عدد السجلات السالبة التي تنبأ بها النموذج بشكل خاطئ، والحقها بالفئة الموجبة.

FN = (False Negatives): هو عدد السجلات الموجبة التي تم اعتبارها بالخطأ سالبة مع أنها موجبة.



الشكل 1: عينة من مجموعة بيانات صور حرائق الغابات.

5. خوارزميات الدراسة

1.5. الشبكة العصبية التلافيفية (CNN): هو نموذج عصبي عميق متكامل يستخدم على نطاق واسع في تطبيقات الرؤية الحاسوبية مثل تصنيف الصور والتعرف عليها.

المكونات: يتكون النموذج المستخدم في الدراسة من

1.1.5. طبقة Conv2D: تنفيذ التصنيفية المكونة من عدة فلاتر لاستخراج الميزات من الصور.

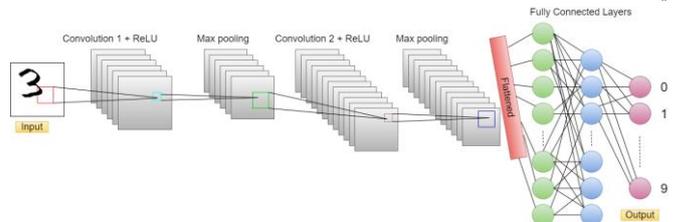
2.1.5. طبقة MaxPooling2D: لتقليل حجم الصورة المستخدمة لتقليل التعقيد وزيادة الفعالية.

3.1.5. طبقة Flatten: تقوم بتسطيح البيانات المتعددة الأبعاد إلى بيانات ذات بعدين للتخصيص للطبقات المتصلة.

4.1.5. طبقة Dense: كاملة الاتصال تقوم بتصنيف الصور إلى فئات مختلفة.

5.1.5. طبقة Dropout: لمنع الفرط وتقليل احتمال الفرط في التدريب.

6.1.5. دوال التنشيط: تستخدم ReLU في الطبقات التنشيطية و Sigmoid في الطبقة النهائية لتوليد احتمالات الفئات.



الشكل 2: الهندسة العامة لنموذج CNN [8].

2.5. نموذج (Transfer Learning using VGG16): يستند النموذج إلى VGG16 وهو نموذج معماري معروف في مجال تصنيف الصور. يتم استخدام النموذج الأساسي (VGG16) مع الوزن المدرب مسبقًا على مجموعة البيانات ImageNet. تم تجميد جميع طبقات VGG16 الأساسية لمنع تحديث الوزن المدرب مسبقًا.

المكونات: يتكون النموذج المستخدم في الدراسة من

1.2.5. نموذج VGG16 مسبق التدريب معماريًا لتحليل الصور واستخراج الميزات.

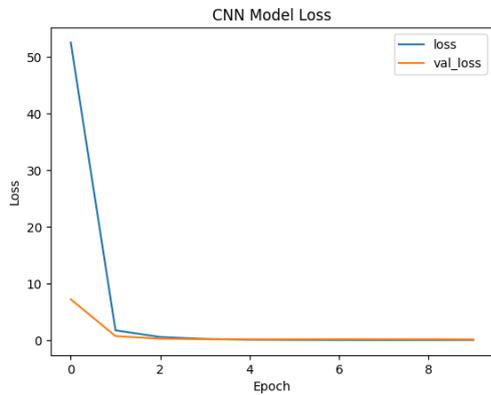
2.2.5. طبقة GlobalAveragePooling2D: تقوم بتقليل الأبعاد للبيانات المعقدة مثل الصور.

3.2.5. طبقة Dense: كاملة الاتصال لتصنيف الصور.

4.2.5. طبقة Dropout: لمنع الفرط الزائد.

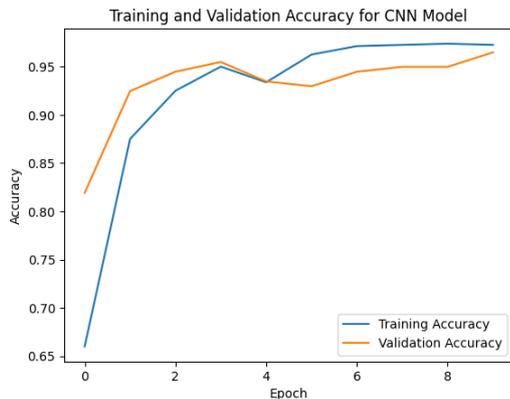
**1.8. نموذج CNN:**

الخسارة (Loss): يبدأ النموذج بقيمة خسارة عالية تبلغ 52.5192 وتنخفض تدريجياً خلال الحقب العشرة لتصل إلى 0.0756 في نهاية التدريب. مما يدل على قدرة النموذج على التعلم وتحسين أدائه.



الشكل 5: دالة الخسارة لنموذج CNN.

2.8. الدقة (Accuracy): يزداد معدل الدقة من 66% في البداية إلى 97.12% في نهاية التدريب، مما يشير إلى تحسن النموذج في تصنيف البيانات وقدرة النموذج على التعلم والتكيف مع البيانات.



الشكل 6: معدل تعلم نموذج CNN.

3.8. مصفوفة الارتباط وتقرير التصنيف: مصفوفة الارتباط (Confusion Matrix) وتقرير التصنيف (Classification Report) يُظهران أن النموذج يقوم بتصنيف الفئتين بدقة جيدة، حيث تبلغ الدقة الوسطية (F1-score) حوالي 96%.

النموذج قادر على التعامل مع البيانات بشكل فعال ويتمتع بقدرة جيدة على التعرف على الأنماط داخل البيانات. وذلك من خلال مقياس ROC AUC الذي أعطى نسبة 97%.

2.6. مقياس المثلالية (Recall): هي نسبة السجلات الموجبة التي تم التنبؤ بها وتصنيفها بشكل صحيح إلى كل السجلات الموجبة.

$$\text{Recall} = \frac{TP}{TP+FN} \quad (2)$$

3.6. مقياس الدقة (Precision):

$$\text{Precision} = \frac{TP}{TP+FP} \quad (3)$$

4.6. المتوسط الحسابي (macro avg): المتوسط الحسابي يستخدم لحساب متوسط قيم المعايير الأدائية (مثل الدقة والاستدعاء وقيمة F1 score) عبر كل الفئات بدون اعتبار لحجم الفئات. باستخدام المعادلة:

$$\text{Macro Avg} = \frac{\sum_{i=1}^n \text{Metric}_i}{\text{Total support}}$$

5.6. المتوسط المرجح (weighted avg): يتم حساب المتوسط المرجح عن طريق حساب المتوسط الحسابي لقيم المعايير الأدائية (مثل الدقة والاستدعاء و F1 score) عبر كل الفئات باستخدام وزن يعتمد على عدد العينات من خلال المعادلة:

$$\text{Weighted Avg} = \frac{(\text{Metric}_0 * \text{support}_0) + (\text{Metric}_1 * \text{support}_1)}{\text{Total support}}$$

6.6. مقياس F (F-measure):

$$F1 = \frac{2 * \text{Precision} * \text{recall}}{\text{Precision} + \text{recall}}$$

**7. النتائج**

في هذا البحث تم استخدام ثلاث نماذج عميقة على مجموعة بيانات صور حرائق الغابات. جميع النماذج تظهر أداءً جيداً على بيانات التدريب والتحقق. وكان نموذج MobileNet يظهر أفضل أداء مع نسبة دقة 100% على بيانات التدريب ونسبة دقة 97% على بيانات التحقق.

**جدول 6: مقارنة أداء النماذج.**

Model	Training Loss	Training Accuracy	Val Loss	Val Accuracy
CNN	0.08	97.12%	0.17	94%
VGG16	0.04	99%	0.18	94%
MobileNet	$9.57 \times 10^{-6}$	100%	0.31	96%

**جدول 7: مصفوفة الارتباك.**

Model	TP	FP	FN	TN
CNN	146	4	8	41
VGG16	146	4	7	42
MobileNet	145	5	1	48

**جدول 8: تقرير التصنيف.**

Model	Class	Precision	Recall	F1-Score	Support
CNN	0	0.95	0.97	0.96	150
	1	0.91	0.84	0.87	49
VGG16	0	0.95	0.97	0.96	150
	1	0.91	0.86	0.88	49
MobileNet	0	0.99	0.97	0.98	150
	1	0.91	0.98	0.94	49

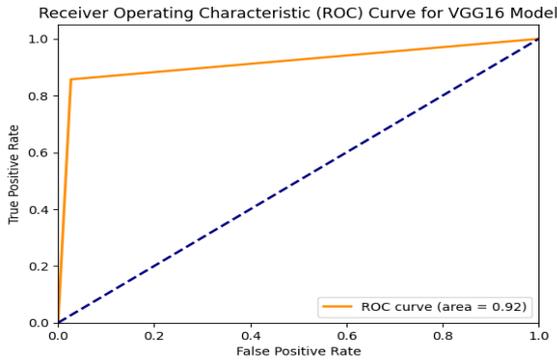
**جدول 9: حساب المتوسط الحسابي (macro avg).**

model	Precision	Recall	F1-Score
CNN	0.93	0.91	0.92
VGG16	0.93	0.92	0.92
MobileNet	0.95	0.97	0.96

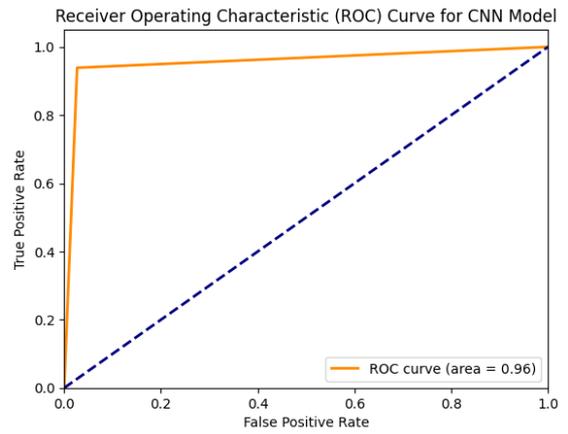
**جدول 10: حساب المتوسط المرجح (Weighted Avg).**

model	Precision	Recall	F1-Score
CNN	0.94	0.94	0.94
VGG16	0.94	0.94	0.94
MobileNet	0.97	0.97	0.97

**8. تحليل النتائج:**



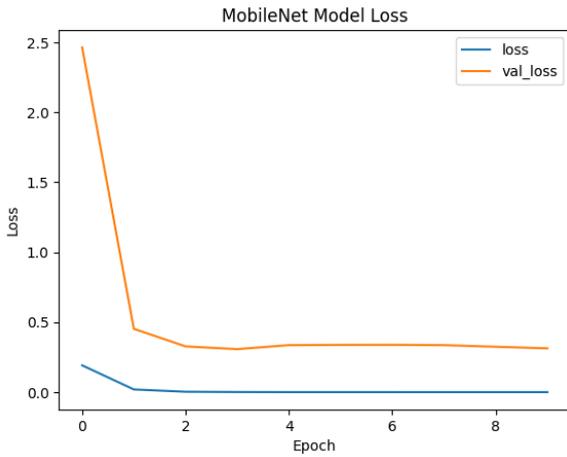
الشكل 10: مقياس ROC AUC لنموذج VGG16.



الشكل 7: مقياس ROC AUC لنموذج CNN.

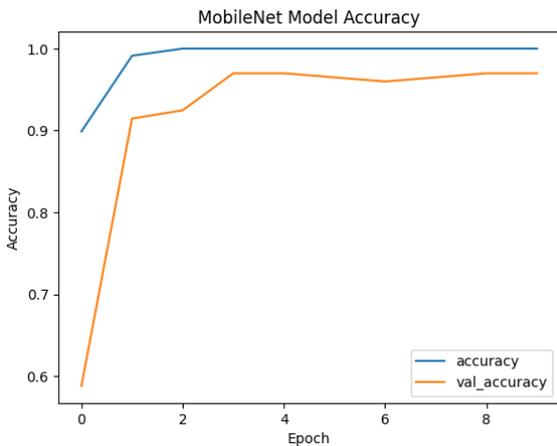
**نموذج MobileNet:**

الخسارة (Loss): يظهر النموذج أداءً ممتازاً بالنسبة للخسارة، حيث تتراوح قيم الخسارة بين 0.1912 في البداية و9.5719 e-06 في نهاية التدريب.



الشكل 11: دالة الخسارة لنموذج MobileNet.

الدقة (Accuracy): يتحسن معدل الدقة من 89.88% في البداية إلى 100% في نهاية التدريب، مما يوضح قدرة النموذج على التعلم والتكيف بشكل فعال.

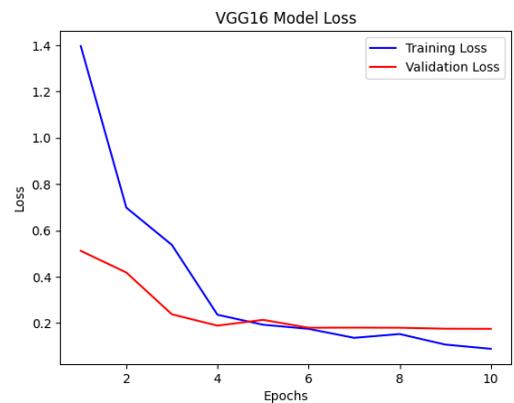


الشكل 12: معدل تعلم نموذج MobileNet.

مصفوفة الارتباط وتقرير التصنيف: يظهر النموذج أداءً ممتازاً في تصنيف الفئتين، مع دقة عالية وقيم ROC AUC ممتازة.

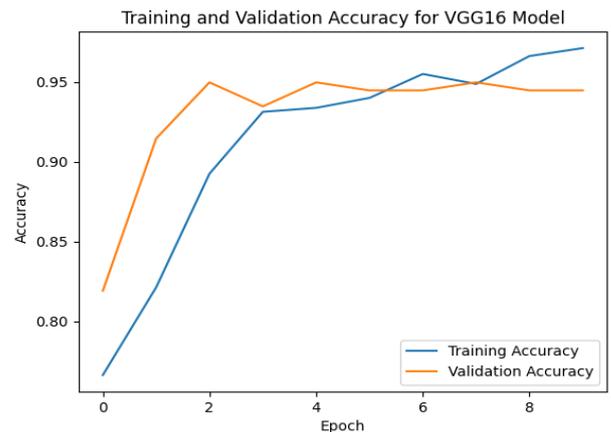
**نموذج VGG16**

الخسارة (Loss): يبدأ النموذج بقيمة خسارة 1.3956 وتنخفض تدريجياً خلال الحقب العشرة إلى 0.0891 في نهاية التدريب.



الشكل 8: دالة الخسارة لنموذج VGG16.

الدقة (Accuracy): يزداد معدل الدقة من 76.63% في البداية إلى 99.12% في نهاية التدريب، مما يدل على تحسن النموذج في تصنيف البيانات.



الشكل 9: معدل تعلم نموذج VGG16.

مصفوفة الارتباط وتقرير التصنيف: يظهر النموذج أداءً جيداً في تصنيف الفئتين، مع دقة مرتفعة ولكن قليل من الانحراف في التصنيف. قيمة ROC AUC هي (0.9152) تشير إلى أداء جيد للنموذج في التمييز بين الفئتين، حيث تقارب قيمتها من القيمة القصوى 1. تظهر قيمة ROC AUC أن النموذج قادر على تمييز العينات بشكل جيد، حيث تظهر قيمة عالية لقدرته على التمييز بين النتائج الإيجابية والسلبية.

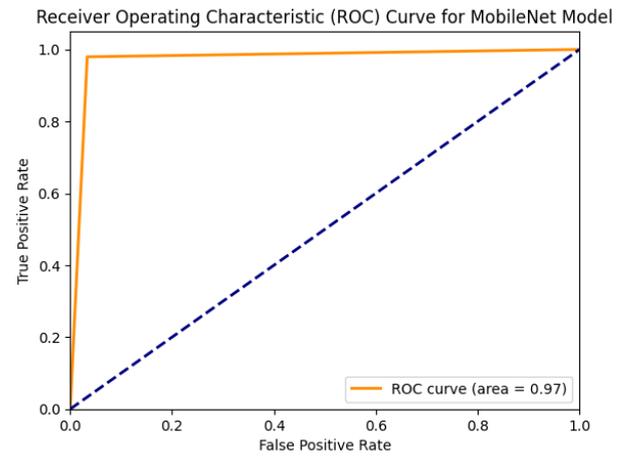
تشابهت الدراسة الحالية مع الدراسة السابقة في استخدام تقنيات نقل التعلم، واختلفت في مجموعات البيانات والطرق المستخدمة في تحسين أداء النماذج.

3. الدراسة السابقة التي قام بها هاتيجه جاتال ريس وفيسيل تورك (2023) ركزت على استخدام خوارزميات Convolutional Neural Network (CNN) مع تقنية Transfer Learning لكشف حرائق الغابات. أما الدراسة الحالية فقد قامت بمقارنة أداء ثلاثة نماذج عميقة (CNN)، VGG16، MobileNet على مجموعة بيانات صور حرائق الغابات. وكان من بين النتائج أن نموذج MobileNet تشابهت الدراستين في أن كلا الدراستين تستخدمان النماذج العميقة مع تقنية Transfer Learning لتحسين أداء كشف حرائق الغابات. وكلا الدراستين تقدمان تحليلاً مفصلاً لأداء النماذج المستخدمة، بما في ذلك معدلات الدقة ومصنوفات الارتباك وتقارير التصنيف. وتختلف النماذج المستخدمة في كل دراسة، حيث استخدمت الدراسة السابقة خوارزميات CNN مع تقنية Transfer Learning، بينما استخدمت الدراسة الحالية ثلاثة نماذج عميقة (CNN)، VGG16، MobileNet. تختلف نتائج أداء النماذج بين الدراستين، حيث حققت الدراسة السابقة أفضل أداء مع النموذج M-5 بنسبة دقة 97.5%، في حين حقق نموذج MobileNet في الدراسة الحالية أفضل أداء مع نسبة دقة 100% على بيانات التدريب ونسبة دقة 97% على بيانات التحقق.

4. الدراسة التي قام بها سوها بيرك كوكوك وزينب هلال كيليمجي في عام 2021 ركزت على استخدام خوارزميات مختلفة لكشف حرائق الغابات باستخدام صور الأقمار الصناعية في تركيا. تم في هذه الدراسة استخدام خوارزميات مثل ResNet-18، VGG16، DenseNet121، Inception-V3، Support Vector Machines (SVM)، Random Forest، و k-Nearest Neighbors (KNN) على مجموعة بيانات تتألف من 1000 صورة، حيث 500 منها تحتوي على حرائق غابات و500 منها لا تحتوي على حرائق غابات. توصلت هذه الدراسة إلى أن نماذج التعلم العميق، مثل ResNet-18، كانت أكثر دقة في اكتشاف حرائق الغابات مقارنة بالنماذج التقليدية مثل Random Forest.

كلا الدراستين تستخدمان النماذج العميقة لكشف حرائق الغابات. وتوجد تقنية Transfer Learning في كلا الدراستين، حيث تم تدريب النماذج مسبقاً على مجموعة بيانات كبيرة. وكان الاختلاف في أن الدراسة السابقة استخدمت مجموعة بيانات صور الأقمار الصناعية في تركيا، بينما الدراسة الحالية تستخدم مجموعة بيانات صور حرائق الغابات. وكانت النماذج المستخدمة في كل دراسة تختلف، حيث استخدمت الدراسة السابقة نماذج مثل ResNet-18 و VGG16 و MobileNet، في حين استخدمت الدراسة الحالية نماذج CNN و VGG16 و MobileNet. وكانت نتائج الأداء بين الدراستين متفاوتة، حيث حققت الدراسة الحالية أداءً أفضل بنسبة دقة أعلى لنموذج MobileNet.

5. تشابهت الدراسة الحالية مع الدراسة التي أجراها تشاو واي تشانغ وزملاؤه في عام 2023 في استخدام الشبكات العصبية الاصطناعية لكشف حرائق الغابات وتقنية Transfer Learning في تدريب النماذج. وكان الاختلاف من حيث النماذج المستخدمة في كل دراسة، حيث استخدمت الدراسة المذكورة نماذج AlexNet بتعديلات مختلفة، بينما استخدمت الدراسة الحالية نماذج CNN و VGG16 و MobileNet.



الشكل 13: مقياس ROC AUC لنموذج MobileNet.

يتبين أن جميع النماذج قد حققت أداءً ممتازاً بالنسبة للدقة وتصنيف الفئات، ولكن يمكن ملاحظة أن نموذج MobileNet قد حقق أداءً أفضل بالنسبة للخسارة والدقة مقارنة بالنموذجين الآخرين.

#### المناقشة

بناءً على النتائج المعروضة في الدراسة الحالية والدراسات السابقة يمكن القول أن

1. في الدراسة الحالية تم استخدام ثلاث نماذج عميقة لاكتشاف حرائق الغابات باستخدام مجموعة بيانات صورية. تضمنت النماذج المستخدمة CNN، VGG16، MobileNet، وتم تدريبها واختبارها على بيانات التدريب والتحقق بشكل منفصل. في الدراسة السابقة التي نشرها هاي لي وبنغ سون في عام 2023، تم استخدام الشبكات الباقية (Residual Networks) وتم تدريب النموذج باستخدام مجموعة بيانات صورية متنوعة تم جمعها من منصة حرائق حقيقية وقاعدة بيانات الصور المستندة إلى الغابات وهذه الاستراتيجية قد أثبتت فعاليتها في تحسين الأداء العام لنموذج التدريب. من خلال المقارنة بين الدراسة السابقة ودراسة الحالية، يمكن القول إن النتائج تتجاوز بالفعل التوقعات فيما يتعلق بفعالية النماذج العميقة في اكتشاف حرائق الغابات باستخدام تقنيات التعلم العميق. تظهر كلا الدراستين أن النماذج العميقة تعتبر فعالة جداً في هذا السياق، مع تحقيق مستويات عالية من الدقة والأداء في تصنيف البيانات المتعلقة بالحرائق.

2. بناءً على الدراسة السابقة التي أجراها من قبل ساتيشكومار، ف. إي (2023)، ركزت الدراسة على تطوير أساليب للكشف التلقائي عن الحرائق في الغابات باستخدام تقنيات الرؤية الحاسوبية المبنية على الذكاء الاصطناعي. واستخدمت الدراسة ثلاثة نماذج هي VGG16 و InceptionV3 و Xception، مع مجموعتي بيانات هي BoWFire و Original Forest Fire. أظهرت نتائج الدراسة أن النماذج المدربة مسبقاً دون استخدام تقنية التعلم دون النسيان (LwF) كان أداؤها متبايناً بناءً على نسب الدقة في التصنيف. فقد حققت النماذج الثلاثة نتائج متفاوتة بين استخدام مجموعتي بيانات Original Forest Fire و BoWFire. من خلال استخدام تقنية التعلم دون النسيان (LwF)، أظهرت النتائج تحسناً في أداء النماذج المدربة مسبقاً على مجموعتي بيانات Original Forest Fire و BoWFire، فقد ارتفعت نسب الدقة للنماذج الثلاثة المستخدمة في الدراسة. تشير هذه النتائج إلى أن تقنية التعلم دون النسيان (LwF) تساهم في تحسين أداء النماذج المدربة مسبقاً، وتسمح لها بالتعامل بفعالية مع مجموعات البيانات الجديدة وغير المعروفة.

## قائمة المراجع

- [1]- Kaggle. (2018). Fire Dataset. Retrieved December 10, 2023, from <https://www.kaggle.com/datasets/phyllake1337/fire-dataset>
- [2]- Li, H., & Sun, P. (2023). Image-Based Fire Detection Using Dynamic Threshold Grayscale Segmentation and Residual Network Transfer Learning. *Mathematics*, 11(18), 3940.
- [3]- Sathishkumar, V. E., Cho, J., Subramanian, M., & Naren, O. S. (2023). Forest fire and smoke detection using deep learning-based learning without forgetting. *Fire ecology*, 19(1), 1-17.
- [4]- G. S. Tandel, M. Biswas, O. G. Kakde, A. Tiwari, H. S. Suri, M. Turk, J. Laird, C. Asare, A. A. Ankrah, N. N. Khanna, B. K. Madhusudhan, L. Saba, and J. S. Suri, A Review on a Deep Learning Perspective in Brain Cancer Classification, *Cancers*, vol. 11, p. 111, jan 2019.
- [5]- Hatice Catal Reis, Veysel Turk. Detection of forest fire using deep convolutional neural networks with transfer learning approach." *Applied Soft Computing*, vol. [143], Page no. [110362], August 2023.
- [6]- Süha Berk KUKUK, Zeynep Hilal KİLİMCİ, (2021), Comprehensive Analysis of Forest Fire Detection using Deep Learning Models and Conventional Machine Learning Algorithms, *International Journal of Computational and Experimental Science and ENgineering (IJCESN)*, Vol. 7-No.2 (2021) pp. 84-94, ISSN: 2149-9144.
- [7]- Zhang, Z., Guo, Y., Chen, G., & Xu, Z. (2023). Wildfire Detection via a Dual-Channel CNN with Multi-Level Feature Fusion. *Forests*, 14, 1499. <https://doi.org/10.3390/f14071499>.
- [8]- Al Bataineh, A.; Kaur, D.; Al-khassaweneh, M.; Al-sharoha, E. Automated CNN Architectural Design: A Simple and Efficient Methodology for Computer Vision Tasks. *Mathematics* 2023, 11, 1141. <https://doi.org/10.3390/>.
- [9]- Varshney, P. (2020). VGGNet-16 Architecture: A Complete Guide. Kaggle. Retrieved from <https://www.kaggle.com/code/blurredmachine/vggnet-16-architecture-a-complete-guide> (Accessed: January 30, 2024).
- [10]- Sharma, N. (2023, December 31). What is MobileNetV2? Features, Architecture, Application and More. *Analytics Vidhya*. Retrieved from <https://www.analyticsvidhya.com/blog/2023/12/what-is-mobilenetv2/> (Accessed: January 2, 2024).

تختلف مصادر البيانات المستخدمة في كل دراسة، حيث استخدمت الدراسة المذكورة صورًا تستند إلى قنوات مختلفة (TIR، RGB، وبانكروماتيك)، بينما استخدمت الدراسة الحالية صورًا لحرائق الغابات.

يختلف أداء النماذج في كل دراسة، حيث أظهرت الدراسة الحالية أفضل أداء لنموذج MobileNet بنسبة دقة 100% على بيانات التدريب ونسبة دقة 97% على بيانات التحقق، بينما أظهرت الدراسة المذكورة أعلى دقة لنموذج مزدوج القنوات بنسبة 98.90%.

باختصار، كلا الدراستين يهدفان إلى استخدام الشبكات العصبية لكشف حرائق الغابات، ولكنهما تختلفان في النماذج المستخدمة ومصادر البيانات وأداء النماذج.

## الخاتمة والاعمال المستقبلية

يظهر البحث أن استخدام ثلاثة نماذج عميقة في تحليل صور حرائق الغابات أدى إلى نتائج مشجعة على مجموعة البيانات المستخدمة. جميع النماذج (CNN، VGG16، MobileNet) أظهرت أداءً جيدًا على بيانات التدريب والتحقق، مع تفوق نموذج MobileNet الذي حقق نسبة دقة 100% على بيانات التدريب ونسبة دقة 97% على بيانات التحقق. تقدم هذه الدراسة نقطة انطلاق للأبحاث المستقبلية في مجال استخدام الشبكات العصبية العميقة لتحليل صور حرائق الغابات، وتسلسل الضوء على الفرص المستقبلية لتطوير تقنيات التعلم الآلي لمراقبة وتحليل الكوارث الطبيعية. بناءً على تحليل النتائج، يمكن اقتراح العديد من الاعتبارات للأبحاث المستقبلية، بما في ذلك:

1. استكشاف استخدام نماذج أخرى للشبكات العصبية العميقة لتحليل الصور، ومقارنة أدائها بالنماذج التي استخدمت في هذا البحث.
2. توسيع مجموعة البيانات لتشمل مزيدًا من السيناريوهات والظروف المختلفة للحرائق، مما قد يساعد في تعزيز قدرة النماذج على التعرف على أشكال متنوعة من الحرائق.
3. تحسين تقنيات التعلم العميق المستخدمة في هذا البحث، مثل ضبط معلمات النماذج وتحسين تقنيات التحسين.
4. دراسة تأثير استخدام مصادر بيانات متعددة (مثل الصور الحرارية والبانورامية) على أداء النماذج في تحليل حرائق الغابات.