

مذكرة تخرج شهادة ليسانس لمشروع بعنوان :

بناء نموذج لتصنيف صور

الأعشاب الضارة المنتشرة بالحقول الزراعية في وادي سوف

من إعداد :

تحت إشراف :

د. قية سناء سحر

بورقعة رمضان

زهو عبد الحكيم

عمارة أيمن

نوقشت يوم : 5 جوان 2024

لجنة المناقشة :

د. ... : جامعة الشهيد حمه لخضر - مشرفا

د. ... : جامعة الشهيد حمه لخضر - مناقشا

Abstract

This study aims to develop an artificial intelligence model by utilizing Convolutional Neural Networks (CNNs) to identify weed species in the El Oued region, particularly those found in potato fields. The goal is to enhance weed detection and enable farmers to implement timely control measures.

A CNN-specific model was trained from scratch using a dataset containing images of four types of weeds: Chenopodium, Cynodon, Malva, and Polypogon. Transfer learning techniques were applied, leveraging pre-trained VGG-16, ImageNetV2, and InceptionV3 models to improve classification accuracy.

The results demonstrated the superiority of the InceptionV3 model, achieving a validation accuracy of 93.46%. These findings highlight the potential of CNNs as effective tools for weed management, supporting the development of practical applications to detect and map weed spread in fields, ultimately enhancing agricultural productivity.

Keywords: Artificial intelligence, Convolutional Neural Networks, Weeds, Image classification, Transfer learning.

ملخص

تهدف هذه الدراسة لتطوير نموذج قائم على الذكاء الاصطناعي من خلال بناء نموذج بواسطة الشبكات العصبية الالتفافية (CNNs) للتعرف على أنواع الأعشاب الضارة بمنطقة وادي سوف وخاصة تلك المنتشرة في حقول البطاطا، وذلك بهدف تسهيل عملية الكشف عنها و تمكين الفلاحين من اتخاذ إجراءات المكافحة المناسبة .

تم تدريب نموذج خاص CNN من الصفر على مجموعة بيانات تضم صورًا لأربعة أنواع من الأعشاب الضارة : مزريطة، نجم، خبيز وذيل الفار. كما تم تطبيق تقنية التعلم الانتقالي باستخدام نماذج VGG-16 و ImageNetV2 و InceptionV3 المدربة مسبقًا لتحسين دقة التصنيف.

أظهرت النتائج تفوق نموذج InceptionV3 حيث بلغت دقة التصنيف على بيانات التحقق 93.46% تؤكد هذه النتائج إمكانية استخدام CNNs كأداة فعالة في مجال إدارة الأعشاب الضارة، مما يدعم تطوير تطبيقات عملية للكشف عنها ورسم خرائط انتشارها في الحقول، وبالتالي تعزيز الإنتاجية الزراعية.

الكلمات المفتاحية: الذكاء الاصطناعي، الشبكات العصبية الالتفافية، الأعشاب الضارة، تصنيف الصور، التعلم الانتقالي.

المحتويات

i	المحتويات
iv	قائمة الأشكال
vii	قائمة الجداول
1	المقدمة
3	1 تأثير الأعشاب الضارة وطرق مكافحتها
4	1.1 مقدمة
4	2.1 التعريف بالعشب الضار
4	3.1 التأثيرات المباشرة للأعشاب الضارة
5	4.1 التأثيرات الغير المباشرة للأعشاب الضارة
5	5.1 فوائد مكافحة الأعشاب الضارة
5	6.1 مصادر انتشار الأعشاب الضارة
7	7.1 طرق مقاومة ومكافحة الأعشاب الضارة
9	8.1 تنوع الأعشاب الضارة في الأنظمة الزراعية
9	9.1 معلومات حول الأعشاب المستخدمة في التصنيف
10	10.1 عشبة المزريطة
12	11.1 عشبة النجم
14	12.1 عشبة الخبيز
16	13.1 عشبة ذيل الفار
17	14.1 خاتمة

2 التعلم العميق والشبكات العصبية

18

1.2	مقدمة	19
2.2	ماهو التعلم العميق ؟	19
3.2	تطبيقات التعلم العميق	21
4.2	خصائص التعلم العميق	24
5.2	أشهر نماذج التعلم العميق	25
6.2	مفهوم تصنيف الصور	28
7.2	أهداف تصنيف الصور :	29
8.2	آلية فهم الشبكات العصبية للصور	30
9.2	ضبط معلمات شبكة CNN لتصنيف الصور	31
10.2	خاتمة	34

3 إنجاز المشروع

35

1.3	مقدمة	36
2.3	المنهجية المتبعة لإنجاز المشروع	36
3.3	تجميع البيانات	37
4.3	معالجة البيانات	39
5.3	بناء وتدريب نموذج خاص من الصفر	41
6.3	بناء وتدريب نموذج بواسطة التعلم الانتقالي	48
7.3	التعلم الإنتقالي : VGG-16	49
8.3	التعلم الإنتقالي : MobileNetV2	53
9.3	التعلم الإنتقالي : Inception-v3	54
10.3	التقييم	56
11.3	حفظ النموذج	59
12.3	توظيف النموذج بموقع ويب	60
13.3	توظيف النموذج بتطبيق أندرويد	63
14.3	خاتمة	66

67	الخاتمة
68	المصادر
75	الإختصارات

قائمة الأشكال

1.1	عملية تحضير لمحلول رش	7
2.1	صورة لعشبة مزريطة (<i>Chenopodium murale</i>)	10
3.1	رسم توضيحي للمزريطة : (1) الساق، (2) الأوراق، (3) النورات، (4) الأزهار.	11
4.1	صورة لعشبة نجم (<i>Cynodon dactylon</i>)	12
5.1	رسم توضيحي للنجم : (1) السيقان، (2) السنابل، (3) السنيبلات، (4) اللسين.	13
6.1	صورة لعشبة خبيز (<i>Malva parviflora</i>)	14
7.1	رسم توضيحي للخبيز : (1) عنق الورقة، (2) التويج، (3) الثمار.	15
8.1	صورة لعشبة ذيل الفار (<i>Polypogon monspeliensis</i>)	16
9.1	رسم توضيحي لذيل الفار : (1) نصل الورقة، (2) السنيبلات.	17
1.2	علاقة التعلم العميق بتعلم الآلة والذكاء الاصطناعي.	20
2.2	تطبيقات الذكاء الاصطناعي في حياتنا.	21
3.2	تسخير الذكاء الاصطناعي لتحسين الإنتاجية وحل المشكلات المعقدة.	24
4.2	أنواع الشبكات العصبونية.	25
5.2	تحديد الأشخاص والدراجات باستخدام YOLO.	26
6.2	توليد الرسم باستخدام الذكاء الاصطناعي.	27
7.2	فهم تصنيف الصور في الذكاء الاصطناعي.	28
8.2	التعرف على الأشعة السينية وتصنيفها من خلال التعلم العميق.	29
9.2	تصنيف صور (المزريطة، النجم، الخبيز، وذيل الفار) باستخدام (CNN).	30
10.2	رحلة الصورة عبر شبكة CNN وآلية الأخيرة لتعرفها على عشبة الخبيز.	31
1.3	مخطط لمنهجية إنجاز المشروع.	37
2.3	رسم بياني شريطي يوضح توزيع عدد الصور لكل نوع.	38
3.3	إستعراض بعض الصور من مجموعة البيانات.	38

39	4.3	صورة لعشبة خبيز بعد تطبيق تقنية التعزيز.
41	5.3	رحلة الصورة عبر شبكة CNN وآلية الأخيرة لتعرفها على عشبة الخبيز.
41	6.3	مقطع من الكود لبنية النموذج الخاص.
42	7.3	مثال توضيحي لعمل طبقة Conv2D في الشبكات العصبية.
43	8.3	توضيح لدالة التنشيط ReLU.
43	9.3	تأثير دالة التنشيط ReLU على الصورة.
44	10.3	آلية عمل طبقة MaxPooling2D.
44	11.3	تقليل الاعتمادية بين الخلايا العصبية: Dropout كمثال.
45	12.3	تحويل مصفوفة متعددة الأبعاد إلى متجه باستخدام Flatten.
45	13.3	تصور لبنية النموذج الخاص باستخدام Keras.
46	14.3	ملخص لبنية النموذج الخاص.
47	15.3	منحنى بياني يوضح دقة وخسارة النموذج الخاص خلال فترة التدريب.
47	16.3	تقييم أداء النموذج الخاص: الدقة والخسارة على بيانات التحقق.
48	17.3	آلية عمل التعلم الانتقالي.
49	18.3	مقطع من الكود لتحميل وتهيئة نموذج VGG-16.
49	19.3	تكييف نموذج مُدرّب مسبقاً لمهمة جديدة.
50	20.3	تجميد طبقات نموذج VGG-16 المُدرّب مسبقاً.
50	21.3	ملخص لبنية النموذج المستند على التعلم الانتقالي باستخدام VGG-16.
51	22.3	تصوير لمراحل نقل التعلم : تجميد الطبقات، استخراج الميزات، ثم التصنيف.
52	23.3	عرض لمراحل من عملية تدريب نموذج VGG-16.
52	24.3	منحنى بياني يوضح دقة وخسارة نموذج VGG-16 خلال فترة التدريب.
52	25.3	تقييم أداء نموذج VGG-16: الدقة والخسارة على بيانات التحقق.
53	26.3	ملخص لبنية النموذج المستند على التعلم الانتقالي باستخدام MobileNetV2.
54	27.3	منحنى بياني يوضح دقة وخسارة نموذج MobileNetV2 خلال فترة التدريب.
54	28.3	تقييم أداء نموذج MobileNetV2: الدقة والخسارة على بيانات التحقق.
55	29.3	ملخص لبنية النموذج المستند على التعلم الانتقالي باستخدام Inception-v3.
55	30.3	منحنى بياني يوضح دقة وخسارة نموذج Inception-v3 خلال فترة التدريب.

55	31.3	تقييم أداء نموذج Inception-v3: الدقة والخسارة على بيانات التحقق.
57	32.3	مصفوفة الخطأ للنموذج الخاص.
57	33.3	مصفوفة الخطأ لنموذج VGG-16.
58	34.3	مصفوفة الخطأ لنموذج MobileNetV2.
58	35.3	مصفوفة الخطأ لنموذج Inception-v3.
59	36.3	حفظ نموذج InceptionV3 بالجهاز.
60	37.3	تحويل النموذج من صيغة h5 الى صيغة tflite.
61	38.3	الصفحة الرئيسية للموقع.
61	39.3	صفحة الكشف للموقع.
62	40.3	إستعراض لنتيجة كشف عن عشبة خبيز.
62	41.3	صفحة من صفحات المكتبة.
63	42.3	صفحة "عن مشروعنا".
63	43.3	أيقونة التطبيق.
64	44.3	واجهة التطبيق.
65	45.3	إستعراض لبعض نتائج التصنيف.

قائمة الجداول

1.3	ظبط أبعاد الصور على (224 × 224) بكسل	40
2.3	تقسيم مجموعة البيانات	40
3.3	ملخص لنتائج تقييم النماذج الأربعة على بيانات التحقق	56

المقدمة

تحتل الجزائر مكانة هامة في إنتاج البطاطا على المستوى القاري، حيث تساهم بشكل كبير في تلبية الطلب المحلي والإقليمي. وتعد الجزائر من بين الدول الرائدة بإفريقيا في إنتاج هذا المحصول الاستراتيجي، مما يعكس الجهود المبذولة لتطوير القطاع الزراعي وتحقيق الأمن الغذائي. ويساهم المناخ المتنوع والتربة الخصبة في الجزائر في توفير بيئة ملائمة لزراعة البطاطا، بالإضافة إلى الخبرة المتراكمة لدى الفلاحين الجزائريين في هذا المجال. كما تعمل الدولة على الدعم والتحفيز للإنتاج من خلال الاستثمار في البنية التحتية الزراعية، وتوفير المدخلات اللازمة، وتقديم الدعم الفني للفلاحين. كما تسعى الجزائر إلى تعزيز مكانتها كمنتج رئيسي للبطاطا في إفريقيا، والمساهمة في تحقيق الأمن الغذائي على المستوى القاري، وذلك عبر زيادة الإنتاجية وتحسين جودة المنتج، وتوسيع نطاق التصدير إلى الأسواق الإقليمية والدولية.

في هذا السياق، تبرز ولاية الوادي كرائدة في إنتاج البطاطا على المستوى الوطني. ففي السنوات الأخيرة، تربعت ولاية وادي سوف على عرش إنتاج البطاطا في الجزائر، بقدرة إنتاجية تتجاوز 20 مليون قنطار سنوياً. ويساهم هذا الإنتاج بحوالي 45% من إجمالي المنتج الوطني، مما يمثل حوالي 60% من قيمة الإنتاج الزراعي المحلي بالولاية. وعلى الرغم من وفرة الإنتاج الفلاحي في وادي سوف، إلا أنه يواجه تحديات عديدة، من بينها انتشار الأعشاب الضارة بالحقول والتي تؤثر سلباً على إنتاجية وجودة محاصيل البطاطا.

تُمثل مكافحة الحشائش في محاصيل البطاطا تحدياً كبيراً للفلاحين، نظراً لتداخل عدة عوامل معقدة. إذ يختلف توزيع الأعشاب الضارة وأنواعها بشكل كبير تبعاً للمنطقة والظروف البيئية، مما يعقد عملية التشخيص الدقيق ويؤدي إلى استخدام مبيدات غير فعالة أو ذات تأثير سلبي على النظام البيئي. فيتطلب الرش دقة عالية، حيث أن الرش غير الدقيق لمبيدات الأعشاب يمكن أن يؤثر سلباً على محصول البطاطا ويسبب أضراراً للنباتات، مما ينعكس على جودة المحصول وحجمه. كما يلعب التوقيت دوراً حاسماً في فعالية المكافحة، فتأخر التشخيص والتدخل يؤدي إلى تفاقم المشكلة، مما يسبب ضعفاً للمنتج وخسارة مادية للفلاحين. فعندما تكبر الحشائش وتزداد كثافتها، يصبح من الصعب، بل قد يستحيل، القضاء عليها باستخدام مبيدات الأعشاب، مما يجبر الفلاح للجوء إلى العمالة اليدوية لنزعها، وهو أمر مكلف إذ يستهلك وقتاً وجهداً كبيرين.

في ضوء هذه التحديات، يتجه البحث العلمي نحو تطوير حلول مبتكرة قائمة على التكنولوجيا. ومن بين هذه الحلول المبتكرة، تبرز تقنيات الذكاء الاصطناعي كأداة واعدة لتحسين كفاءة ودقة مكافحة هذه الأعشاب.

تتميز أنظمة الذكاء الاصطناعي بقدرتها على تحليل كميات هائلة من البيانات البصرية واستخراج الأنماط المعقدة، مما يسمح لها بتشخيص أنواع مختلفة من الأعشاب بدقة عالية. وذلك من خلال تدريب نماذج التعلم الآلي على مجموعات بيانات كبيرة من الصور لهذه الأعشاب، يمكن لهذه النماذج تعلم تمييز الصفات المميزة لكل نوع من الأعشاب الضارة، مما يسهل عملية الكشف والتصنيف الدقيق. تفتح هذه التقنية الباب أمام تطوير تطبيقات متقدمة في مجال الزراعة الدقيقة، حيث يمكن استخدام أنظمة الرؤية الحاسوبية المزودة بالذكاء الاصطناعي لتوجيه الروبوتات الزراعية أو أنظمة الرش الذكية لاستهداف الأعشاب بشكل انتقائي، مما يقلل من استخدام المبيدات الكيميائية ويحمي البيئة.

الفصل 1

تأثير الأعشاب الضارة وطرق مكافحتها

1.1 مقدمة

تُعد الأعشاب الضارة من ألد أعداء الفلاحين، فهي تنافس المحاصيل على الضوء والماء والعناصر الغذائية، مما يؤثر سلباً على نموها وإنتاجيتها. وتتسبب هذه الأعشاب في خسائر اقتصادية كبيرة، وتعيق عمليات الحصاد وتقلل من جودة المنتج النهائي. لذا، كان لزاماً علينا البحث عن طرق فعالة لمكافحتها والحد من انتشارها. في هذا الفصل، سنتناول تأثير الأعشاب الضارة على المحاصيل الزراعية، ونتعرف على أبرز طرق المكافحة التقليدية والحديثة، مع إبراز أهمية المكافحة المتكاملة لتحقيق أفضل النتائج.

2.1 التعريف بالعشب الضار

العشب الضار هو كل عشب دخيل على زراعة المنتج وبالتالي فهو ينمو دون رغبة الفلاح حيث يزاحم الزراعات وخاصة منها الحبوب على الضوء والماء والعناصر المغذية الأساسية كالآزوت والفسفور والبوتاسيوم وكذلك العناصر الثانوية الصغرى (oligo-éléments) كالزنك والمانيسيوم، تؤثر الأعشاب الضارة على المزروعات بطريقة مباشرة وطريقة غير مباشرة [34].

3.1 التأثيرات المباشرة للأعشاب الضارة

تشكل الأعشاب الضارة تحدياً كبيراً للأنظمة الزراعية، حيث تؤثر سلباً على الإنتاجية والجودة. وتتجلى آثارها السلبية في عدة جوانب، منها:

- **توفير بيئة ملائمة للآفات والأمراض:** تُعد الأعشاب الضارة مأوى للعديد من الحشرات الضارة ومسببات الأمراض النباتية، مما يزيد من خطر انتشارها وتفشيتها في المحاصيل. فعلى سبيل المثال، توفر الأعشاب المظلية بيئة مناسبة لنمو حشرات المن، والتي تُعد ناقلاً رئيسياً للعديد من الفيروسات النباتية. [55]
- **تعقيد عمليات الحصاد:** تؤدي كثافة الأعشاب الضارة إلى صعوبة عمليات الحصاد الميكانيكية، مما يزيد من الوقت والتكلفة اللازمين لحصاد المحاصيل. [42]
- **تدهور جودة المحاصيل:** تتنافس الأعشاب الضارة مع المحاصيل على الموارد الأساسية، مثل الماء والضوء والمغذيات، مما يؤدي إلى ضعف نمو المحاصيل وانخفاض إنتاجيتها. كما يمكن لبعض الأعشاب الضارة أن تلوث المحاصيل ببذورها أو موادها الكيميائية، مما يؤثر على جودتها وقيمتها السوقية. [44]

- **منافسة المحاصيل على الموارد:** تتنافس الأعشاب الضارة المحاصيل على الضوء، الماء، المغذيات والمساحة، مما يحد من نمو المحاصيل وإنتاجيتها. [43]

بالإضافة إلى ذلك، يمكن أن تؤثر الأعشاب الضارة على صحة الإنسان والحيوان، كما يمكن أن تسبب مشاكل بيئية. لذلك، فإن إدارة الأعشاب الضارة بشكل فعال أمر بالغ الأهمية لتحقيق استدامة الإنتاج الزراعي. [48]

4.1 التأثيرات الغير المباشرة للأعشاب الضارة

بالإضافة إلى الآثار المباشرة، تسبب الأعشاب الضارة أيضًا تأثيرات غير مباشرة سلبية على الإنتاج الزراعي، منها:

- **محافظة الأعشاب على مناخ مصغر رطب:** تساهم الأعشاب الضارة في خلق بيئة رطبة حول النباتات، مما يوفر ظروفًا ملائمة لنمو الفطريات المسببة للأمراض مثل البياض الدقيقي، والملديو، والأصداء. [46]
- **تأخير الحصاد:** تؤدي كثافة الأعشاب الضارة إلى زيادة الحشو (Bourrage) في المحاصيل، مما يُعيق عمليات الحصاد ويسبب خسارة في الوقت تُقدر بين 20% و 30%. [42]
- **سمية بعض الأنواع:** تُعتبر بعض أنواع الأعشاب سامة للحيوانات، مثل نبات الحمرة الذي يشكل خطرًا على بعض سلالات الأغنام. [40]

5.1 فوائد مكافحة الأعشاب الضارة

أظهرت التجارب التي قام بها المركز الفني للحبوب سابقًا والمعهد الوطني للزراعات الكبرى بتونس¹ أن مكافحة الأعشاب الضارة تُمكن الفلاح من تحقيق زيادة في إنتاجية المحاصيل تتراوح ما بين 7 إلى 10 قناطر في الهكتار الواحد. [41]

6.1 مصادر انتشار الأعشاب الضارة

تتميز الأعشاب الضارة بقدرتها الفائقة على الانتشار والاستمرار في البيئات الزراعية، [49] وذلك بفضل مجموعة من الآليات التي تُسهل انتقال بذورها وانتشارها على نطاق واسع. وتشمل أهم آليات انتشار الأعشاب الضارة:

- **استعمال بذور عادية ذات نقاوة ضعيفة:** تحتوي البذور العادية على نسبة من بذور الأعشاب الضارة، والتي تنتشر في الحقل عند زراعة هذه البذور. [56]

¹ <http://www.ingc.com.tn>

- **عن طريق الغبار:** تنتقل بذور الأعشاب الضارة الصغيرة وخفيفة الوزن بسهولة عبر الغبار الذي تحمله الرياح. [51]
- **عن طريق الرياح:** تُعتبر الرياح من أهم عوامل انتشار بذور الأعشاب الضارة، خاصة تلك التي تمتلك تراكيب تساعد على الطيران لمسافات طويلة. [51]
- **مياه الري ومياه السيول:** يمكن لمياه الري ومياه السيول أن تحمل بذور الأعشاب الضارة وتنقلها إلى مناطق جديدة. [51]
- **الرعي بالقطيع:** يمكن للحيوانات الرعوية أن تنقل بذور الأعشاب الضارة العالقة بفروها أو بأجهزتها الهضمية. [39]

1.6.1 العوامل المساهمة في استفحال وتكاثر الأعشاب الضارة

- تتعدد العوامل التي تساهم في استفحال وتكاثر الأعشاب الضارة في الحقول الزراعية، ومن أهمها:
- **عدم تطبيق التداول الزراعي (حبوب / حبوب):** يؤدي تكرار زراعة نفس المحصول، وخاصة الحبوب، إلى توفير بيئة مناسبة لنمو الأعشاب الضارة المتخصصة في هذا النوع من المحاصيل. [50]
 - **اختصار تحضير الأرض:** يُقلل تحضير الأرض بشكل غير كافٍ من فعالية السيطرة على الأعشاب الضارة، حيث تبقى البذور قريبة من سطح التربة وقادرة على الإنبات. [42]
 - **المقاومة المتأخرة:** التأخر في تطبيق إجراءات مكافحة يؤدي إلى نمو الأعشاب الضارة وتكاثرها بشكل كبير، مما يزيد من صعوبة السيطرة عليها. [16]
 - **الاستعمال المتكرر لنفس المبيد ضد الأعشاب الضارة:** يؤدي الاستخدام المتكرر لنفس المبيد إلى ظهور سلالات من الأعشاب الضارة مقاومة لهذا المبيد، مما يفقده فعاليته. [53]
 - **عدم استعمال المبيدات المناسبة:** يجب اختيار مبيد الأعشاب المناسب بناءً على نوع الأعشاب المستهدفة ومرحلة نموها، وإلا فإن فعالية المكافحة ستكون ضعيفة.
 - **عدم تنظيف جوانب الطريق والحقول:** تُشكل جوانب الطرق والحقول بيئة مناسبة لنمو وتكاثر الأعشاب الضارة، والتي يمكن أن تنتقل بسهولة إلى الحقول المجاورة. [46]

7.1 طرق مقاومة ومكافحة الأعشاب الضارة

تُعد عملية مكافحة الأعشاب الضارة في الزراعة، ضرورة أساسية لتحقيق إنتاجية عالية من حيث الكم والجودة. وتعتمد بالأساس علي طرق المكافحة المندمجة والمتمثلة في الطرق الوقائية والزراعية والكيميائية. إلا أن الطرق الكيميائية المتمثلة في عملية رش المبيدات المصادق عليها في الزراعات الكبرى، هي الأكثر انتشارا واستعمالا من طرف الفلاحين[45].



شكل 1.1: عملية تحضير لمحلول رش

1.7.1 الطرق الوقائية والزراعية :

- التداول الزراعي: يساعد التخطيط المدروس للتداول الزراعي، بما في ذلك زراعة المحاصيل المنظفة والغامة والملوثة بالتناوب، على كسر دورة حياة الأعشاب الضارة ومنع تكاثرها[4].
- اختيار البذور: استخدام بذور عالية الجودة وخالية من بذور الأعشاب يساهم في تقليل انتشارها في الحقل[56].
- استخدام أصناف متأقلمة: تُظهر بعض الأصناف النباتية قدرة تنافسية أعلى تجاه الأعشاب الضارة، مما يجعلها خيارًا جيدًا للزراعة في المناطق المعرضة للإصابة.
- الحراثة: تعتبر الحراثة من الطرق التقليدية للتحكم في الأعشاب الضارة، حيث تساعد على دفن البذور ومنع نموها[50].

- **تأخير البذر:** يمكن لتأخير عملية البذر أن يحد من نمو الأعشاب الضارة، حيث يمنح المحاصيل فرصة للنمو والتنافس بشكل أفضل [15].
- **استخدام الغبار الميت:** يعمل الغبار الميت على منع وصول الضوء إلى بذور الأعشاب الضارة، مما يثبط إنباتها [50].
- **التسميد الآزوتي:** يُعزز التسميد الآزوتي المناسب نمو المحاصيل ويزيد من قدرتها التنافسية تجاه الأعشاب الضارة [45].

2.7.1 الطرق الكيميائية :

- تُستخدم مبيدات الأعشاب كأحد الأدوات الهامة في مكافحة الأعشاب الضارة، إلا أن استخدامها يجب أن يتم بعناية وحكمة للحد من التأثيرات السلبية على البيئة وصحة الإنسان [47]. ومن أهم النقاط التي يجب مراعاتها عند استخدام مبيدات الأعشاب:
- **التدخل المبكر:** يُعد التدخل المبكر بمبيدات الأعشاب، وخاصة في مراحل النمو الأولى للأعشاب، أكثر فعالية في السيطرة عليها [40].
- **التعرف على أهم الأعشاب الموجودة بالحقل والتمييز بينها:** يجب على الفلاحين امتلاك المعرفة الكافية لتحديد أنواع الأعشاب الموجودة في حقولهم، وذلك لاختيار المبيد المناسب لكل نوع [54].
- **اختيار المبيد المناسب:** يجب اختيار مبيد الأعشاب بناءً على نوع الأعشاب المستهدفة، ومرحلة نموها، والظروف البيئية [54].
- **الالتزام بالجرعات الموصى بها:** تجنب زيادة الجرعات لتقليل مخاطر التلوث البيئي وتأثير المبيدات على المحاصيل [54].
- **القيام بتعديل آلة الرش:** يجب التأكد من عمل آلة الرش بكفاءة وضبطها بشكل صحيح لضمان توزيع المبيد بشكل متجانس وتجنب الهدر أو التأثير السلبي على المحاصيل [2].
- **مراعاة الظروف المناخية الملائمة للمداواة:** تؤثر العوامل الجوية مثل درجة الحرارة والرطوبة والرياح على فعالية المبيدات، لذا يجب اختيار الوقت المناسب للرش وفقاً للظروف الجوية السائدة [2].

8.1 تنوع الأعشاب الضارة في الأنظمة الزراعية

تعتمد توزيعات الأعشاب الضارة ونوعها على عوامل بيئية مختلفة، مثل نوع التربة وظروف الرطوبة ودرجات الحرارة. وتُصنف الأعشاب الضارة وفقاً لنوعها البيئي، والذي يشير إلى الموطن المفضل لها. فعلى سبيل المثال، تُعد الأعشاب الضارة المعروفة بالأنواع المحبة للرطوبة شائعة في التربة الرطبة، في حين تفضل الأنواع المحبة للجفاف ظروفًا أكثر جفافاً [52].

بالإضافة إلى ذلك، ترتبط بعض الأعشاب الضارة بمحاصيل معينة. على سبيل المثال، يُعرف عندنا في حقول البطاطا بانتشار أنواع محددة من الأعشاب الضارة مثل المزريطة، النجم، الخبيز، ذيل الفار وهي تعتبر الأنواع الأكثر شيوعاً بمنطقة وادي سوف. لذا سوف نركز في دراستنا هذه على تلك الأنواع الأربعة من أجل التوصل في الأخير لبناء نموذج يعمل بالذكاء الاصطناعي ويكون قادر على التمييز والتعرف على نوع العشبة من بين هذه الأنواع الأربعة.

9.1 معلومات حول الأعشاب المستخدمة في التصنيف

تنتشر العديد من الأعشاب الضارة التي تؤثر على نمو الزرع وتقلل من إنتاجية المحاصيل. وقع اختيارنا في هذا المشروع على أربعة أنواع شائعة بمنطقة وادي سوف وهم: المزريطة، النجم، الخبيز، وذيل الفار. سنقدم معلومات شاملة لكل نوع على حدة، مع التركيز على أهم الخصائص بكل نوع.

10.1 عشب المزريطة



شكل 2.1: صورة لعشب مزريطة (*Chenopodium murale*)

نبات عشبي حولي، يتميز برائحة قوية غير مستحبة، السيقان مضلعة أو شبه أسطوانية، لونها يميل إلى الأحمر الأرجواني، وهي عارية ملساء. الأوراق متبادلة على الساق. شكلها مثلثي وذات حواف مسننة ملساء ولونها أخضر وقد يميل إلى الأحمر في بعض الأحيان. الأزهار صغيرة جدا تتجمع في نورات كثيفة تخرج من ابط الأوراق [57].

1.10.1 النمو والإزهار

ينمو نبات المزريطة كلما توفرت له الظروف المناسبة، حيث نجده تقريبا في معظم فصول السنة ناميا في الحدائق وبين المزروعات. إلا أن فصل الربيع هو أهم الفصول التي يزدهر فيها.

2.10.1 أماكن التواجد

يزدهر في الحدائق والمزارع ومعظم الأماكن الرطبة، كما ينمو في مناطق الروابي والمرتفعات المحيطة بالأهواض والمزارع، ونادرا ما نجده في المناطق الرملية الجافة.

3.10.1 الانتشار الجغرافي

نبات عالمي الانتشار (Cosmopolites) فهو ينمو في معظم بقاع العالم.

4.10.1 ملاحظات

- نبات ضار جدا، يصعب القضاء عليه إذا طغى على منطقة معينة، وذلك بسبب قدرته الهائلة على إنتاج البذور والتكاثر.
- تشير بعض البحوث إلى إمكانية الحصول على مواد مبيدة لآفات الحشرية المصيبة للحبوب المخزنة، فقد لوحظ مثلا أن مستخلصات هذا النبات بواسطة الهكسان والإيثانول.
- تمتلك خواص إبادية ضد الحشرات الضارة بالحبوب.

5.10.1 رسم توضيحي للمزينة



شكل 3.1: رسم توضيحي للمزينة : (1) الساق، (2) الأوراق، (3) النورات، (4) الأزهار.

11.1 عشب النجم



شكل 4.1: صورة لعشب نجم (Cynodon dactylon)

النجم من النباتات المعروفة، وهو ضار جدا إذا طغى على الأراضي الزراعية، ويمتلك هذا النبات جذامير معمرة تزحف تحت الأرض وتخرج منها السيقان الهوائية، الأوراق شريطية صغيرة طولها لا يتعدى 4 سم، أما السنابل فتخرج من قمة الساق وهي تأخذ شكلا مميزا، فهي طويلة وتتفرع من نقطة واحدة [57].

1.11.1 النمو والإزهار

نبات معمر ينمو طوال العام، أما سنابله فتظهر في الربيع والصيف.

2.11.1 أماكن التواجد

يفضل الأماكن الرطبة كثيرة الماء، مثل المزارع وأماكن صعود المياه.


3.11.1 الانتشار الجغرافي

نبات عالمي الانتشار (Cosmopolites) فهو ينمو في معظم بقاع العالم.

4.11.1 ملاحظات

- على حسب التحاليل الكيميائية فإن النجم يحتوي على بروتينات بسيطة، سكريات، بعض القلويدات، والعناصر المعدنية مثل الفسفور وأكسيد المغنزيوم والكلسيوم والصوديوم والبوتاسيوم.
- لوحظ أن القلويدات المستخلصة من هذا النبات تعمل على تخفيض جريان الدم، لذلك فهو يستعمل في حالات الرعاف والخروج المستمر لدم الطمث والبواسير حيث تستعمل الجذامير على شكل مستحلب (مغلى).
- المستخلص الكحولي للنجم يمتلك نشاط مضاد للفيروسات.
- النجم نبات مسهل ومنقي للدم ومدر للصفراء، كما أنه يستعمل ضد إصابات المسالك البولية والحصى البولية والمرارة ونقص اليوريا والتهاب المفاصل هذا بالإضافة إلى دوره الكبير في الوقاية من أمراض الكبد.

5.11.1 رسم توضيحي للنجم



شكل 5.1: رسم توضيحي للنجم : (1) السيقان، (2) السنايل، (3) السنييلات، (4) اللسين.

12.1 عشبة الخبيز



شكل 6.1: صورة لعشبة خبيز (Malva parviflora)

وأصله في العربية خباز، ورد في كتب اللغة أنه بقلة عريضة الورق لها ثمرة مستديرة واحدها خبازة، يقول الشاعر:

"وعاد خباز يسقيه الندى *** ذراوة تنسجه الهوج الدرج"

والخبيز نبات عشبي حولي أو معمر، سيقانه تنمو زاحفة وهي أسطوانية خضراء اللون وتكسوها بعض الشعيرات، أوراق الخبيز شبه دائرية وحوافها متموجة وغير منتظمة، عندما يحين موعد الإزهار تظهر أزهار صغيرة تحت الأوراق وهي تتميز بكأس أخضر ملتحم السبلات أما التويج فهو صغير جدا ولونه وردي مبيض. ثمار الخبيز كروية وتظل محاطة بالكأس إلى أن تجف وتسقط [57].

1.12.1 النمو والإزهار

ينمو في أواخر الشتاء ويزهر خلال الربيع.

2.12.1 أماكن التواجد

ينمو في معظم المناطق الشمالية منها والجنوبية، إلا أنه يكثر في المناطق المحمية مثل الحدائق والمزارع، كما يزدهر في مناطق المرتفعات والروابي المحيطة بالأهوا.


3.12.1 الانتشار الجغرافي

ينتشر في منطقة حوض البحر الأبيض المتوسط.

4.12.1 ملاحظات

- أوراق الخبيز يمكن استهلاكها غضة، وهي تستعمل في تحضير بعض السلائط.
- يمكن أن يعتبر من النباتات الضارة خاصة عندما ينمو بكثافة بين النباتات المزروعة.

5.12.1 رسم توضيحي للخبيز



شكل 7.1: رسم توضيحي للخبيز : (1) عنق الورقة، (2) التويج، (3) الثمار.

13.1 عشب ذيل الفار



شكل 8.1: صورة لعشب ذيل الفار (*Polypogon monspeliensis*)

يسمى ذيل الفار نسبة إلى سنابله الناعمة التي تشبه الذيل، وهي نباتات نجيلية تنمو لعام واحد، لها سيقان رقيقة قائمة تحمل أوراقا شريطية خضراء، السنابل كثيفة ناعمة صوفية المظهر وطول السنبل الواحدة يصل إلى 15 سنتمترًا [57].

1.13.1 النمو والإزهار

ينمو في الشتاء والربيع وهو يزدهر في الأماكن الرطبة، هذا وقد ينمو في الفصول الأخرى عندما تتوفر الظروف المناسبة.

2.13.1 أماكن التواجد

من النباتات التي تحتاج إلى بعض الرطوبة فهي لا تستطيع مقاومة الظروف الشديدة من الحرارة والجفاف، لذلك غالبا منا نجدها في الأماكن الرطبة كالحدائق المنزلية والمزارع.

3.13.1 الانتشار الجغرافي

ينتشر في المناطق شبه المدارية.

4.13.1 ملاحظات

- ينمو كنبات ضار في الحقائق والمزارع مقاومته سهلة وغير مكلفة.
- تأكله الحيوانات ويمكن الإستفادة منه عندما ينمو بكثرة.

5.13.1 رسم توضيحي لذيل الفار



شكل 9.1: رسم توضيحي لذيل الفار : (1) نصل الورقة، (2) السنييلات.

14.1 خاتمة

وبهذا نكون قد تعرفنا على التأثير السلبي للأعشاب الضارة على المحاصيل الزراعية، واستعرضنا أبرز طرق مكافحتها، بدءاً من الطرق التقليدية اليدوية ووصولاً إلى استخدام المبيدات. كما أكدنا على أهمية تطبيق مفهوم مكافحة المتكاملة لتحقيق أفضل النتائج بأقل ضرر على البيئة. وفي الفصل القادم، سننتقل إلى عالم التكنولوجيا الحديثة، حيث سنتعرف على مفهوم الذكاء الاصطناعي وتطبيقاته المتنوعة في شتى المجالات، بما في ذلك مجال الزراعة، وكيف يساهم في تطويره وتحسين إنتاجيته.

الفصل 2

التعلم العميق والشبكات العصبية

1.2 مقدمة

في الفصل السابق، تطرقنا لتأثير الأعشاب على المحاصيل الزراعية، واستعرضنا الطرق المتاحة لمكافحتها، سواء كانت يدوية أو كيميائية. أما في هذا الفصل، فسنجاوز الأساليب التقليدية، لنستكشف كيف يمكن للتكنولوجيا الحديثة، وتحديدًا تقنيات الذكاء الاصطناعي والتعلم الآلي، أن تحدث ثورة في طرق مكافحة الأعشاب الضارة. سنتعمق في مفهوم التعلم العميق، أحد فروع الذكاء الاصطناعي، وكيف يمكن لشبكات CNNs، وهي أحد نماذج التعلم العميق المتخصصة في تحليل الصور، أن تساعد في تحديد وتصنيف الأعشاب الضارة بدقة وكفاءة عالية.

2.2 ماهو التعلم العميق ؟

يُعد التعلم العميق أحد فروع التعلم الآلي الذي يستلهم آلية عمله من البنية المعقدة لشبكات الخلايا العصبية في الدماغ البشري. تعتمد هذه التقنية على شبكات عصبونية اصطناعية عميقة، تتكون من طبقات متعددة من العُقد الاصطناعية المترابطة، تُحاكي الخلايا العصبية البيولوجية. تقوم هذه الشبكات بمعالجة البيانات واستخلاص الأنماط والمعلومات منها، مما يُمكنها من اتخاذ القرارات وتحقيق مهام مُعقدة.

يشبه التعلم العميق عملية التعلم عند البشر، حيث يتم تحسين الأداء تدريجيًا من خلال التعرض المتكرر للبيانات والخبرات. كلما زادت كمية البيانات المُدخلة إلى الشبكة العصبونية، زادت قدرتها على التعلم وتحسين دقة نتائجها. تتميز هذه النماذج العميقة بقدرتها على التعلم الذاتي من كميات هائلة من البيانات غير المُهيكلية، مما يجعلها أدوات قوية في مجموعة واسعة من التطبيقات. [22]



شكل 1.2: علاقة التعلم العميق بتعلم الآلة والذكاء الاصطناعي.

3.2 تطبيقات التعلم العميق



شكل 2.2: تطبيقات الذكاء الاصطناعي في حياتنا.

تُعتبر تطبيقات التعلم العميق واسعة النطاق ومتنوعة، مما يعكس قدرته على التعامل مع المشكلات المعقدة وتحسين جوانب عديدة من حياتنا. من بين أهم استخداماته:

أ- الزراعة الذكية:

- تحليل بيانات الأقمار الصناعية والطائرات بدون طيار ل:

– تحسين إدارة المحاصيل

– الكشف المبكر عن الحشائش الضارة والأمراض

– مراقبة صحة النباتات ونموها

ب- الرعاية الصحية والتشخيص الطبي:

- تحليل الصور الطبية (الأشعة السينية، التصوير بالرنين المغناطيسي، إلخ) للكشف عن الأمراض

وتشخيصها بدقة، مثل:

- الكشف المبكر عن السرطان
- تشخيص أمراض القلب والأوعية الدموية
- تحليل صور الجلد للكشف عن الأمراض الجلدية
- تحليل البيانات الجينية لفهم الأمراض وتطوير علاجات شخصية

ج- الرؤية الحاسوبية وتحليل الفيديو:

- تطوير أنظمة المراقبة والأمان:
- التعرف على الوجوه والأشخاص
- الكشف عن الأحداث غير العادية
- تحليل سلوك الحشود
- تطوير السيارات ذاتية القيادة:
- تحليل بيئة الطريق (الكشف عن المشاة، إشارات المرور، المركبات الأخرى)
- اتخاذ قرارات القيادة الآمنة
- المراقبة البيئية والجغرافية:
- تحليل صور الأقمار الصناعية للكشف عن التغيرات البيئية والكوارث الطبيعية
- مراقبة التلوث وتغير المناخ

د- الألعاب والترفيه:

- تطوير شخصيات ذكية في الألعاب تتصرف بواقعية وتتفاعل مع اللاعبين
- تصميم بيئات ألعاب تفاعلية وغامرة
- تطوير تجارب واقع افتراضي وواقع معزز أكثر واقعية

هـ- التجارة الإلكترونية والإعلان:

- تحليل سلوك المستخدم لتقديم توصيات مخصصة للمنتجات والخدمات

- تحسين استهداف الإعلانات وزيادة فعاليتها
- تطوير روبوتات المحادثة لتقديم خدمة العملاء

و- أنظمة التوصية:

- تحليل تفضيلات المستخدمين لتقديم توصيات مخصصة في منصات مثل:

– Netflix (الأفلام والمسلسلات)

– Spotify (الموسيقى)

– Amazon (المنتجات)

ز- التنبؤ بالتسلسلات الزمنية:

- التنبؤ بالأحداث المستقبلية في مجالات مثل:

– البيانات المالية (الأسهم، العملات)

– الطقس

– حركة المرور

– الطلب على الطاقة

ح- الأمن السيبراني:

- الكشف عن التهديدات الأمنية وحماية الشبكات والأنظمة من الهجمات الإلكترونية

- تحليل أنماط الهجمات وتطوير استراتيجيات دفاعية

ط- الروبوتات:

- تطوير روبوتات قادرة على التعلم والتكيف مع بيئتها
- تحسين قدرة الروبوتات على أداء مهام معقدة في مجالات مثل:

– التصنيع

– الخدمات اللوجستية

– الرعاية الصحية

ي- معالجة اللغات الطبيعية (NLP) والتعرف على الكلام:

- تطوير مساعدات ذكية وأنظمة ردود آلية متقدمة
- ترجمة اللغات بدقة عالية
- تحويل الكلام إلى نص بكفاءة
- تحليل المشاعر وفهم اللغة الطبيعية



شكل 3.2: تسخير الذكاء الاصطناعي لتحسين الإنتاجية وحل المشكلات المعقدة.


4.2 خصائص التعلم العميق

يتميز التعلم العميق بمجموعة من الخصائص التي تميزه عن غيره من تقنيات التعلم الآلي، وتجعله أداة قوية في حل المشكلات المعقدة. من أبرز هذه الخصائص:

- التعلم التمثيلي:** القدرة على تعلم تمثيلات متعددة المستويات للبيانات، مما يسمح بالتقاط العلاقات المعقدة وتحقيق أداء عالٍ.
- التعلم من البيانات غير المهيكلة:** القدرة على التعلم من كميات هائلة من البيانات غير المهيكلة (مثل الصور والنصوص والصوت).

- ج- **التعلم الذاتي:** القدرة على اكتشاف الأنماط والمعلومات من البيانات دون الحاجة إلى برمجة صريحة.
- د- **قابلية التوسع:** القدرة على التعامل مع كميات كبيرة من البيانات ومشاكل أكثر تعقيداً من خلال زيادة حجم الشبكة العصبية.
- هـ- **قابلية التعميم:** القدرة على التعميم بشكل جيد على بيانات جديدة لم تُرها من قبل.
- و- **الاعتماد على البيانات الضخمة:** تتطلب نماذج التعلم العميق كميات كبيرة من البيانات للتدريب الفعال.
- ز- **قابلية التفسير المحدودة:** يصعب فهم كيفية اتخاذ نماذج التعلم العميق للقرارات، مما يجعلها "صناديق سوداء".
- ح- **التعلم المستمر:** القدرة على التحديث والتكيف مع البيانات الجديدة بمرور الوقت، مما يُحسن من أداء النموذج.

5.2 أشهر نماذج التعلم العميق



شكل 4.2: أنواع الشبكات العصبونية.

توجد العديد من نماذج التعلم العميق، ولكل منها خصائصها وتطبيقاتها المميزة. من بين أشهر هذه النماذج:


1.5.2 الشبكات العصبية الالتفافية (CNNs) :

هذه النماذج مُصممة خصيصًا للتعامل مع البيانات المكانية، مثل الصور. تعتمد على طبقات الالتفاف لاستخراج الميزات من الصور [38]، مما يجعلها فعالة في مهام مثل:

- التعرف على الصور

- تصنيف الصور

- الكشف عن الأجسام



شكل 5.2: تحديد الأشخاص والدراجات باستخدام YOLO.

2.5.2 الشبكات العصبية متعددة الطبقات (MLP) :


هي نماذج عصبية تتكون من طبقات متعددة من الخلايا العصبية الاصطناعية. تستخدم في مجموعة واسعة من التطبيقات، [9] بما في ذلك:

- التصنيف
- الانحدار
- التنبؤ

3.5.2 الشبكات التوليدية العميقة (GANs) :

تستخدم هذه النماذج لإنشاء بيانات جديدة تشبه البيانات الموجودة. تتكون من شبكتين عصبيتين: شبكة مولدة وشبكة تمييزية. [21] تستخدم في تطبيقات مثل:

- توليد الصور الواقعية
- تحسين جودة الصور
- توليد بيانات اصطناعية



شكل 6.2: توليد الرسم باستخدام الذكاء الاصطناعي.

4.5.2 الشبكات العصبية المتكررة (RNNs) :


هذه النماذج مُصممة للتعامل مع البيانات المتسلسلة، مثل النصوص والكلام. [30] تستخدم في تطبيقات مثل:

- معالجة اللغات الطبيعية
- التعرف على الكلام
- الترجمة الآلية

6.2 مفهوم تصنيف الصور


يُعد تصنيف الصور أحد أهم تطبيقات الرؤية الحاسوبية والتعلم العميق، حيث يهدف إلى تمكين الآلة من "رؤية" وفهم محتوى الصور وتصنيفها إلى فئات محددة. يشبه هذا العملية التي يقوم بها البشر عند النظر إلى صورة ما، حيث نتعرف على الأشياء الموجودة فيها ونصنفها بناءً على معرفتنا السابقة وخصائصها المرئية. [36]

★ Single-label classification



Dog

★ Multi-label classification




Cat, Dog, Rabbit

شكل 7.2: فهم تصنيف الصور في الذكاء الاصطناعي.

7.2 أهداف تصنيف الصور :


- أ- **التنظيم والفهرسة:** يُساهم تصنيف الصور في تنظيم كميات هائلة من الصور الرقمية وفهرستها، مما يُسهل البحث والوصول إلى الصور ذات الصلة.
- ب- **التحليل والفهم:** يُمكن استخدام تصنيف الصور لتحليل محتوى الصور وفهم المشهد المرئي، مثل تحديد نوع المشهد (طبيعي، حضري، إلخ) أو تحديد الأجسام الموجودة في الصورة.
- ج- **الكشف والتعرف:** يُمكن استخدام تصنيف الصور كخطوة أولية في مهام الكشف والتعرف على الأجسام، حيث يتم تحديد موقع الأجسام في الصورة وتصنيفها إلى فئات محددة (مثل السيارات، الأشخاص، الحيوانات).
- د- **التطبيقات المتخصصة:** يُستخدم تصنيف الصور في مجموعة واسعة من التطبيقات المتخصصة، مثل:
 - **الزراعة الذكية:** تحليل صور المحاصيل للكشف عن الآفات والأمراض.
 - **المراقبة البيئية:** تحليل صور الأقمار الصناعية لمراقبة التغيرات البيئية والكوارث الطبيعية.
 - **القيادة الذاتية:** تحليل الصور والفيديو للكشف عن المشاة والمركبات والعوائق الأخرى.
 - **التشخيص الطبي:** تحليل الصور الطبية للكشف عن الأمراض وتشخيصها.



شكل 8.2: التعرف على الأشعة السينية وتصنيفها من خلال التعلم العميق.

8.2 آلية فهم الشبكات العصبية للصور


تُشكل الشبكات العصبية الالتفافية (CNNs) حجر الأساس في مجال رؤية الكمبيوتر، لما لها من قدرة استثنائية على تحليل وفهم الصور، محاكية بذلك آلية عمل الدماغ البشري. تعتمد هذه الشبكات على تنظيم هرمي للطبقات يسمح لها بالتعلم من البيانات وتفسير الأنماط المعقدة داخل الصور. [19]



شكل 9.2: تصنيف صور (المزرية، النجم، الخبيز، وذيل الفار) باستخدام (CNN).

وتبدأ عملية التحليل بطبقة الإدخال التي تتلقى البيانات الأولية للصورة، لتنتقل بعدها إلى طبقة الالتفاف، وهي بمثابة المحرك الرئيسي لعملية الاستخراج والتحليل. تقوم هذه الطبقة بتطبيق مرشحات خاصة على أجزاء صغيرة من الصورة لاستخلاص الملامح المهمة، والتي تمرر بعدها إلى طبقة التنشيط لتحديد المناطق الأكثر أهمية. ثم تأتي طبقة التجميع لتقليل حجم البيانات مع الحفاظ على المعلومات الأساسية، لتصل أخيراً إلى طبقة الإخراج التي تقوم بتصنيف الصورة بناءً على التحليل الذي تم إجراؤه في الطبقات السابقة [25].

ويطلق على عملية مرور البيانات من طبقة الإدخال وصولاً إلى طبقة الإخراج اسم "الانتشار الأمامي" (Forward Propagation) أما بعد تصنيف الصورة، تتم مقارنة النتيجة مع القيمة الحقيقية للصورة لتحديد مدى دقة النموذج. ويتم حساب الخطأ في التصنيف، ثم تتم عملية "الانتشار الخلفي" (Backpropagation) لنشر هذا الخطأ عبر جميع طبقات الشبكة العصبية بشكل عكسي. وتهدف هذه العملية إلى تعديل أوزان ومتحيزات كل طبقة بحيث يتم تقليل الخطأ في التصنيف في المحاولات اللاحقة، وبالتالي تحسين دقة النموذج بشكل تدريجي [13].



شكل 10.2: رحلة الصورة عبر شبكة CNN وآلية الأخيرة لتعرفها على عتبة الخبيز.

تُعتبر الشبكات العصبية الالتفافية (CNNs) من أهم نماذج التعلم العميق في معالجة الصور. تكمن قوتها في قدرتها على استخراج الميزات المهمة تلقائيًا، متجاوزة بذلك الحاجة لهندسة الميزات يدويًا. تجعلها هذه القدرة الخيار الأمثل لمهام التصنيف المعقدة، حيث تتعامل مع الصور بمستويات مختلفة من التجريد، بدءًا من تحديد الحواف والألوان وصولاً إلى التعرف على الأشكال والأشياء المعقدة.

ومع ذلك، تجدر الإشارة إلى أن تحقيق الأداء الأمثل لهذه الشبكات يتطلب ضبطًا دقيقًا لمعاملاتها الفائقة. تلعب هذه المعلمات، كعدد طبقات الشبكة ومعدل التعلم، دورًا حاسمًا في توجيه عملية تعلم الشبكة وقدرتها على استخلاص الميزات المهمة من الصور بدقة. فالتوازن الدقيق بين هذه المعلمات هو المفتاح لتحقيق أقصى استفادة من قدرات CNNs في مهام تصنيف الصور.

9.2 ضبط معلمات شبكة CNN لتصنيف الصور

المعلمات الفائقة هي المفاتيح التي تتحكم في سلوك و أداء نموذج التعلم الآلي. على عكس معلمات النموذج التي يتم تعلمها من البيانات، فإن المعلمات الفائقة يتم تحديدها قبل عملية التدريب وتلعب دورًا حاسمًا في توجيه عملية التعلم وتحقيق أفضل النتائج. يؤثر اختيار القيم المناسبة للمعلمات الفائقة بشكل كبير على قدرة النموذج على تعميم المعرفة على بيانات جديدة، وبالتالي، فإن ضبطها بعناية يمثل جانبًا أساسيًا في بناء نماذج تعلم آلي فعالة.

1.9.2 أنواع المعلومات للشبكة العصبية (CNN) :

توجد مجموعة متنوعة من المعلومات الفائقة التي يمكن ضبطها في نماذج تصنيف الصور، وتشمل:

أ- معلومات الشبكة العصبية:

- عدد الطبقات: يؤثر على قدرة الشبكة على تعلم الأنماط المعقدة.
- عدد الخلايا العصبية في كل طبقة: يؤثر على قدرة الشبكة على تمثيل البيانات.
- معدل التعلم: يحدد مدى سرعة تحديث أوزان الشبكة أثناء التدريب.
- نوع الطبقات (تلافيفية، كثيفة، تجميع): يؤثر على استخراج الميزات والتصنيف.

ب- معلومات الالتفاف:

- عدد الفلاتر: يؤثر على استخراج الميزات.
- حجم الفلتر: يؤثر على مجال رؤية الفلتر.
- خطوة الالتفاف: تحدد المسافة التي يتحرك بها الفلتر عبر الصورة.
- تعبئة: تحدد كيفية التعامل مع حواف الصورة أثناء الالتفاف.

ج- معلومات التجميع:

- نوع التجميع (Max/Average): يحدد كيفية تقليل حجم البيانات.
- حجم التجميع: يحدد حجم منطقة التجميع.
- خطوة التجميع: تحدد المسافة التي تتحرك بها منطقة التجميع.

د- معلومات التدريب:

- معدل التعلم: يحدد سرعة تحديث أوزان الشبكة.
- حجم الدفعة: يحدد عدد الصور المستخدمة في كل خطوة تدريب.
- عدد العصور: يحدد عدد مرات مرور مجموعة البيانات خلال التدريب.
- تقنيات التسوية: مثل (Dropout) تمنع فرط التلاؤم.

هـ- معلمات الطبقات الكثيفة:

- عدد الخلايا: يؤثر على قدرة الطبقة على تمثيل البيانات.
- تقنيات التنشيط: مثل (ReLU, Sigmoid) تؤثر على تنشيط الخلايا وإخراج القيم.

و- معلمات تحسين الصور:

- حجم الصورة: يؤثر على دقة النموذج ووقت التدريب.
- تحسين التباين: يحسن استخراج الميزات.

ز- معلمات خوارزمية التدريب:

- خوارزمية التحسين: مثل (Adam, RMSprop) تؤثر على تحديث أوزان الشبكة.
- معلمات الخوارزمية: مثل معدل التعلم (momentum) تحتاج إلى ضبط لتحقيق أفضل أداء.

2.9.2 تقنيات ضبط المعلمات للشبكة العصبية (CNN) :

توجد العديد من الطرق لضبط المعلمات الفائقة في CNNs منها :

- البحث اليدوي :** يقوم الباحث بتجربة مجموعات مختلفة من المعلمات الفائقة بناءً على خبرته ومعرفته. هذه الطريقة تستغرق وقتاً طويلاً وغير فعالة.
- البحث الشبكي (Grid Search):** يتم تعريف نطاق قيم لكل معلمة فائقة، ويقوم الخوارزمية بتجربة جميع المجموعات الممكنة. هذه الطريقة شاملة ولكنها قد تكون مكلفة حسابياً.
- البحث العشوائي (Random Search):** يتم اختيار قيم المعلمات الفائقة بشكل عشوائي من نطاق محدد. هذه الطريقة فعالة من حيث التكلفة ولكنها قد تقوت المجموعات المثلى.
- التحسين التكراري :** يقوم التحسين التكراري بتحسين معلمات النموذج بشكل تكراري باتجاه أفضل القيم.
- الضبط القائم على النموذج :** تستخدم هذه التقنية نموذجاً ثانوياً للتنبؤ بأداء النموذج الأساسي لمجموعات مختلفة من المعلمات الفائقة.
- الضبط التلقائي باستخدام التعلم الآلي :** تستخدم هذه التقنية خوارزميات التعلم الآلي لتحديد أفضل مجموعة من المعلمات الفائقة.

3.9.2 معايير تقييم أداء النموذج للشبكة العصبية (CNN) :

لتقييم فعالية المعلومات الفائقة ومدى تأثيرها على أداء نموذج التعلم الآلي، نعتمد على مجموعة متنوعة من المقاييس التي تساعدنا في فهم سلوك النموذج وتحديد نقاط قوته وضعفه. من بين هذه المقاييس الرئيسية:

- أ- **الدقة:** تقيس نسبة التنبؤات الصحيحة التي يحققها النموذج مقارنة بإجمالي التنبؤات. تعكس الدقة مدى قدرة النموذج على تصنيف البيانات بشكل صحيح.
- ب- **الخسارة:** تعبر عن مقدار الخطأ في تنبؤات النموذج. تساعدنا الخسارة في فهم مدى ابتعاد تنبؤات النموذج عن القيم الحقيقية، وكلما انخفضت الخسارة، زادت دقة النموذج.
- ج- **التقارب:** يُشير إلى عدد دورات التدريب (العصور) التي يحتاجها النموذج للوصول إلى مستوى أداء مُرضٍ ومستقر. يُعد التقارب السريع مؤشراً جيداً على كفاءة عملية التعلم.
- د- **الاستقرار:** يعكس مدى تباين أداء النموذج عبر مجموعات بيانات مختلفة أو عمليات تشغيل متعددة. نموذج مستقر يُظهر أداءً متسقاً بغض النظر عن الاختلافات الطفيفة في البيانات أو الظروف.
- هـ- **مصفوفة الخطأ:** توضح أنواع الأخطاء التي يرتكبها النموذج من خلال مقارنة التنبؤات بالتصنيفات الحقيقية. تساعدنا مصفوفة الالتباس في فهم أنواع البيانات التي يواجه النموذج صعوبة في تصنيفها.
- و- **منحنيات ROC و AUC:** تُستخدم لتقييم أداء نماذج التصنيف الثنائي. تعكس هذه المقاييس قدرة النموذج على التمييز بين الفئات المختلفة.

10.2 خاتمة

يعد ضبط المعلومات الفائقة جزءاً لا يتجزأ من عملية التعلم الآلي، فهو يؤثر بشكل كبير على أداء نماذج التعلم العميق. ومن خلال اختيار تقنية الضبط المناسبة وتقييم أدائها بعناية، يمكننا تحسين كفاءة ودقة نماذجنا. ومع التقدم المستمر في تقنيات الضبط التلقائي، يُتوقع أن تصبح هذه العملية أكثر سهولة وفعالية في المستقبل. بعد أن وضعنا الأساس النظري لفهم التعلم العميق وتطبيقاته في تصنيف الصور باستخدام شبكات CNNs، حان الوقت للانتقال إلى التطبيق العملي. في الفصل القادم، سنخوض في مشروع بناء نموذج CNN لتصنيف صور الأعشاب الضارة، مستفيدين من المعرفة التي اكتسبناها حول بنية الشبكات، وكيفية عملها، والمفاهيم الأساسية المرتبطة بها.

الفصل 3

إنجاز المشروع


1.3 مقدمة

بعد أن تعرفنا على أسس التعلم العميق وشبكات CNNs، حان الوقت لوضع هذه المعرفة موضع التطبيق. في هذا الفصل، سنخوض رحلة عملية لبناء نموذج CNN لتصنيف صور الأعشاب الضارة. سنبدأ ببناء نموذج بسيط من الصفر، لنفهم المراحل المختلفة لبناء الشبكة وتدريبها. ثم سنتعرف على تقنية التعلم الانتقالي، والتي تتيح لنا الاستفادة من نماذج CNNs قوية موجودة مسبقاً، وتعديلها لتناسب مهمتنا الخاصة. سنقارن بين النهجين، ونقيم أداء النماذج المختلفة، لنرى كيف يمكن للتعلم الانتقالي أن يوفر الوقت والجهد ويحقق نتائج دقيقة في تصنيف الأعشاب الضارة.

2.3 المنهجية المتبعة لإنجاز المشروع

يوضح الشكل التالي المنهجية المتبعة في تنفيذ مشروعنا. وهي تتألف من خمس خطوات رئيسية: جمع البيانات، ومعالجة البيانات، ثم بناء وتدريب النموذج، وبعدها تقييم الأداء، وأخيراً توظيف النموذج بموقع ويب وتطبيق للجوال.


أنظر الشكل 1.3



شكل 1.3: مخطط لمنهجية إنجاز المشروع.

3.3 تجميع البيانات

تم تجميع البيانات المستخدمة في هذا المشروع من مواقع مختلفة لبحث الصور [1]. تم جمع ما مجموعه 1004 صورة (حوالي 250 صورة لكل نوع) ويعرض الشكل الآتي توزيع عدد الصور المجمعة على كل نوع.



شكل 2.3: رسم بياني شريطي يوضح توزيع عدد الصور لكل نوع.




شكل 3.3: إسترأض بعض الصور من مجموعة البيانات.

4.3 معالجة البيانات

قبل الشروع في بناء نموذج لتصنيف الصور، تبرز هنا أهمية عملية تحضير البيانات Data processing كخطوة أساسية لضمان نجاحه. تُعرف هذه العملية أيضًا بإعداد البيانات [14]، وتتضمن ثلاث مراحل رئيسية:

1.4.3 تعزيز البيانات Data augmentation


في سياق التعلم الآلي، وللتغلب على تحدي محدودية البيانات وتأثيرها السلبي على أداء النماذج، نستخدم تقنية تعزيز البيانات [23] لزيادة تنوع مجموعة البيانات الأصلية بشكل مصطنع وذلك عبر تطبيق تحويلات على الصور شملت التدوير حتى (20 درجة)، الإزاحة (10% من الأبعاد)، القص (10 درجات)، تغيير الحجم (10%)، والانعكاس الأفقي، كما يوضح الشكل 4.3 على صورة لورقة الخبيز، مما ينتج نسخًا متنوعة من الصورة الأصلية فيساعد النموذج على التعميم وتجنب فرط التعلم (Overfitting) [8].



شكل 4.3: صورة لعشبة خبيز بعد تطبيق تقنية التعزيز.

2.4.3 ضبط أبعاد الصور Resize images

نظرًا لاختلاف أبعاد الصور بمجموعة البيانات، وفي حين أن معظم نماذج التعلم العميق تتطلب أن تكون جميع الصور المدخلة بنفس البعد. لذا، يتم في هذه المرحلة توحيد أبعاد الصور فأخترنا أن تكون هذه الأبعاد (224×224) بكسل، يعد توحيد أبعاد الصور خطوة مهمة لتسريع عملية التدريب، كما يضمن معالجة جميع الصور بشكل متسق، مما يؤدي إلى تحسين دقة النموذج. [31] يوضح الجدول 1.3 تغيير أبعاد صورة لورقة الخبيز.



جدول 1.3: ضبط أبعاد الصور على (224×224) بكسل

3.4.3 تقسيم البيانات Dataset splitting


هنا نقسم مجموعة البيانات إلى مجموعتين فرعيتين: مجموعة التدريب Training data ومجموعة التحقق data Validation تم تخصيص 80% من البيانات (805 صورة) لمجموعة التدريب، بينما تم تخصيص 20% المتبقية (199 صورة) لمجموعة التحقق [20]. يوضح الجدول 2.3 توزيع البيانات بين المجموعتين.

بيانات التدريب (80%)	بيانات التحقق (20%)
805 صورة	199 صورة
العدد الإجمالي للصور: 1004	

جدول 2.3: تقسيم مجموعة البيانات

5.3 بناء وتدريب نموذج خاص من الصفر

في هذه المرحلة، قمنا بتصميم نموذج شبكة عصبية إلتقافية (CNN) من الصفر. [7] يتكون النموذج من سلسلة من الطبقات، كل طبقة منها تؤدي وظيفة محددة في عملية استخراج الميزات وتحديد نوع العشبة التي بالصورة.



شكل 5.3: رحلة الصورة عبر شبكة CNN وآلية الأخيرة لتعرفها على عشبة الخبيز.

خطوات بناء النموذج: يعرف مقتطف الكود التالي بنية شبكتنا العصبية النهائية التي إختبرناها حسب التجارب المتكررة ونتائجها وذلك من خلال ضبط المعلمات الفائقة. أنظر (شكل 6.3) دعنا نقوم بتفصيل عملية بناء نموذجنا خطوة بخطوة

```
In [27]: model = Sequential()

model.add(Conv2D(32, (3, 3), activation='relu', input_shape=(224, 224, 3)))
model.add(MaxPooling2D(2, 2))

model.add(Conv2D(64, (3, 3), activation='relu'))
model.add(MaxPooling2D(2, 2))
model.add(Dropout(0.3))

model.add(Conv2D(128, (3, 3), activation='relu'))
model.add(MaxPooling2D(2, 2))
model.add(Dropout(0.3))

model.add(Flatten())

model.add(Dense(128, activation='relu'))
model.add(Dropout(0.5))

model.add(Dense(4, activation='softmax'))
```

شكل 6.3: مقطع من الكود لبنية النموذج الخاص .

أ- تهيئة النموذج:


يبدأ الكود باستيراد المكتبات الضرورية ثم تهيئة نموذج متسلسل باستخدام Sequential() تسمح لنا هذه الأخيرة بإضافة طبقات بشكل متسلسل، مما يشكل بنية تشبه السلسلة [28].

ب- إستخراج الميزات:

بالدباية أضفنا طبقة إنتقافية ثنائية الأبعاد (Conv2D) مع 32 مرشحًا، وحجم نواة 3x3 وتنشيط ReLU تقوم طبقة Conv2D بتطبيق مرشحات التلافيف على الصورة المدخلة لاستخراج الميزات المهمة. تعمل المرشحات عن طريق تحريك نافذة صغيرة (حجم النواة) عبر الصورة، وحساب حاصل الضرب النقطي بين المرشح وقيم البكسل المقابلة في النافذة. ينتج عن هذا خريطة ميزات جديدة تسلط الضوء على أنماط وأنواع معينة من الحواف والتركيبات في الصورة الأصلية [24].


Convolution Operator

$$(I * K)_{xy} = \sum_{i=1}^h \sum_{j=1}^w K_{ij} \cdot I_{x+i-1, y-j-1}$$




شكل 7.3: مثال توضيحي لعمل طبقة Conv2D في الشبكات العصبية.

من جهة أخرى تساهم دالة التنشيط ReLU في تسريع عملية التدريب وتحسين أداء النموذج وذلك من خلال تحويل جميع القيم السالبة إلى الصفر، مع الحفاظ على القيم الموجبة كما هي. يساعد هذا في إدخال اللاخطية للشبكة العصبية، مما يسمح لها بتعلم ميزات أكثر تعقيداً [3].




شكل 8.3: توضيح لدالة التنشيط ReLU.

Activation Layer (ReLU)



شكل 9.3: تأثير دالة التنشيط ReLU على الصورة.


بعد طبقة Conv2D ، قمنا بإدراج طبقة تجميع قصوى (MaxPooling2D) بحجم مرشح 2x2 تعمل هذه الطبقة على اختزال أبعاد خرائط الميزات المكانية عن طريق استخراج القيمة القصوى من كل منطقة 2x2 يساهم هذا الاختزال في تحسين كفاءة النموذج الحسابية وتقليل عدد المعلومات، كما يساعد على جعل النموذج أكثر ثباتاً تجاه التغيرات الطفيفة لموضع الميزات أو المعلومات المهمة بداخل الصورة، مما يعزز قدرة النموذج على التعميم. [27].



شكل 10.3: آلية عمل طبقة MaxPooling2D.

ج- معالجة الميزات:


لتحسين استخراج الميزات وتمييز الأنماط المعقدة، قمنا بتكرير تسلسل طبقات التلافيف (Conv2D) والتجميع القصوى (MaxPooling2D) مرتين إضافيتين باستخدام 64 و 128 مرشحاً على التوالي. كما تم إدراج طبقات تسرب (Dropout) بمعدل 0.3 بعد كل طبقة تجميع، للحد من فرط التعلم (Overfitting) وتحسين التعميم [29].



شكل 11.3: تقليل الاعتمادية بين الخلايا العصبية: Dropout كمثال.

تعمل هذه الأخيرة على إيقاف تنشيط الخلايا العصبية بشكل عشوائي أثناء التدريب، مما يجبر النموذج على الاعتماد على مجموعة متنوعة من الميزات وتجنب الاعتماد المفرط على مجموعة محددة منها [29].


بعد عملية استخراج الميزات متعددة الأبعاد من الصور باستخدام طبقات التلافيف والتجميع، قمنا بتحويل هذه الميزات إلى متجه أحادي البعد باستخدام طبقة التسوية [11] (Flatten) يُغذي هذا المتجه طبقة عصبونية كثيفة (Dense) تحتوي على 128 وحدة وتستخدم دالة التنشيط ReLU. تعمل هذه الطبقة على إسقاط الميزات المستخرجة إلى فضاء جديد يسهل تصنيفه. ثم أضفنا طبقة تسرب (Dropout) بمعدل 0.5 بعد الطبقة الكثيفة.



شكل 12.3: تحويل مصفوفة متعددة الأبعاد إلى متجه باستخدام Flatten.

د- تصنيف الميزات:

في المرحلة النهائية ، قمنا بإضافة طبقة كثيفة (Dense) ثانية تحتوي على أربع وحدات عصبية، تعادل عدد أنواع الأعشاب المراد تصنيفها. تُطبق هذه الطبقة دالة التنشيط [12] Softmax، والتي تعمل على تحويل مخرجات الطبقة السابقة إلى توزيع احتمالي، حيث يمثل كل ناتج من الوحدات الأربع احتمال انتماء الصورة إلى فئة معينة. يتم اختيار الفئة ذات الاحتمال الأعلى كتوقع نهائي لصنف الصورة من طرف النموذج.



شكل 13.3: تصور لبنية النموذج الخاص باستخدام Keras.

```
model.summary()
```

Model: "sequential"

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 222, 222, 32)	896
max_pooling2d (MaxPooling2D)	(None, 111, 111, 32)	0
conv2d_1 (Conv2D)	(None, 109, 109, 64)	18496
max_pooling2d_1 (MaxPooling2D)	(None, 54, 54, 64)	0
dropout (Dropout)	(None, 54, 54, 64)	0
conv2d_2 (Conv2D)	(None, 52, 52, 128)	73856
max_pooling2d_2 (MaxPooling2D)	(None, 26, 26, 128)	0
dropout_1 (Dropout)	(None, 26, 26, 128)	0
flatten (Flatten)	(None, 86528)	0
dense (Dense)	(None, 128)	11075712
dropout_2 (Dropout)	(None, 128)	0
dense_1 (Dense)	(None, 4)	516


=====
Total params: 11,169,476
Trainable params: 11,169,476
Non-trainable params: 0
=====

شكل 14.3: ملخص لبنية النموذج الخاص.

بعد تحديد بنية النموذج، تم تدريبه باستخدام خوارزمية التحسين (Adam) [17] بمعدل تعلم قدره 0.0001 مع استخدام دالة خسارة التصنيف التبادلي (Categorical entropy-Cross) لتقييم مدى تطابق تنبؤات النموذج مع التصنيفات الحقيقية للأعشاب. كما تم توظيف مقياس دقة التوقع (Accuracy) لتقييم الأداء العام للنموذج.

لتحسين عملية التدريب، تم اعتماد تقنيتي الاستدعاء المبكر (Early Stopping) و الحفظ التلقائي (Checkpoint Model) [5]، يعمل الاستدعاء المبكر عن طريق مراقبة دقة التحقق النموذجية ووقف عملية التدريب إذا لم تحقق دقة التحقق تقدماً ملحوظاً على مدى عدد محدد من الفترات تم تحديد 10 فترات كحد إيقاف في هذه الحالة. من ناحية أخرى، يقوم الحفظ التلقائي بتخزين أفضل نموذج تم تدريبه أثناء التدريب (بناءً على أعلى قيمة دقة تحقق). كما تم تدريب النموذج لـ 100 فترة، وهي قيمة تم تحديدها وفقاً لقدرات وحدة معالجة الرسومات الخاصة بالحاسوب.

النتيجة :



شكل 15.3: منحنى بياني يوضح دقة وخسارة النموذج الخاص خلال فترة التدريب.

يوضح الشكل 15.3 التطور التدريجي لأداء النموذج من خلال متابعة كل من دقة التصنيف ودالة الخسارة عبر عدد الفترات التدريبية. يشير الاتجاه التصاعدي لمنحنى الدقة واقترب دقة التحقق من دقة التدريب إلى أن النموذج يتعلم بفعالية ويعمم بشكل جيد على البيانات الجديدة. بالإضافة إلى ذلك، فإن الانخفاض التدريجي لمنحنى الخسارة في كل من بيانات التدريب والتحقق يدعم استنتاج أن النموذج لا يعاني من فرط التعلم (Overfitting). بشكل عام، تعكس هذه المنحنيات أداءً جيدًا للنموذج وقدرته على التعميم بنجاح على البيانات الجديدة.

```
In [42]: score = model.evaluate(validation_generator, steps=len(validation_generator))

accuracy = score[1] * 100
loss = score[0] * 100

print("Accuracy:", accuracy, "%")
print("Loss:", loss, "%")

7/7 [=====] - 2s 279ms/step - loss: 0.4444 - accuracy: 0.8241
Accuracy: 82.4120581150055 %
Loss: 44.44069266319275 %
```

شكل 16.3: تقييم أداء النموذج الخاص: الدقة والخسارة على بيانات التحقق.


يظهر الشكل 16.3 أداء النموذج من حيث الدقة والخسارة على مجموعة بيانات التحقق. وقد حقق النموذج دقة بلغت 82.41% مع خسارة 44.44% تعتبر هذه النتائج إلى حد ما مقبولة. إلا أن هناك مجالاً لتحسين أداء النموذج. في حين أن زيادة حجم بيانات التدريب قد تؤدي إلى تحسين الدقة، إلا أن هذه الطريقة تعد مكلفة وغير عملية. لذلك، سيتم توظيف تقنيات التعلم الانتقالي كوسيلة لتحقيق مزيد من التحسينات في أداء النموذج وذلك بدون زيادة في عدد البيانات. وسيتم تناول هذا النهج بالتفصيل في القسم التالي من المشروع.

6.3 بناء وتدريب نموذج بواسطة التعلم الانتقالي

في القسم السابق، قمنا بتصميم وتدريب شبكة عصبية إلتقافية مخصصة على مجموعة بياناتنا لتصنيف الأعشاب الضارة. وعلى الرغم من الجهود المبذولة، أظهر النموذج أداءً محدودًا. يرجع ذلك إلى حاجة النموذج إلى تعلم كيفية استخراج الميزات العامة من الصور، مثل الحواف والتدرجات اللونية، قبل اكتشاف الميزات الأكثر تعقيدًا وتمييزًا. في سيناريوهات العالم الحقيقي، قد يستلزم هذا الأمر أيامًا من التدريب وملايين الصور لتحقيق أداء مرضٍ. لتجاوز هذه التحديات، سنستكشف نهجًا أكثر فعالية يتمثل في استخدام نموذج عام تم تدريبه مسبقًا وإعادة تدريبه على مجموعة البيانات الخاصة بنا. يُعرف هذا النهج بالتعلم الانتقالي [10].

يشكل التعلم الانتقالي أسلوبًا قويًا في التعلم الآلي حيث يتم إعادة استخدام نموذج تم تدريبه مسبقًا على مهمة معينة كنقطة انطلاق لمهمة أخرى مختلفة. يجد هذا النهج تطبيقات واسعة في العديد من مجالات التعلم العميق، بما في ذلك تصنيف الصور ومعالجة اللغة الطبيعية وحتى تصميم أنظمة الذكاء الاصطناعي للألعاب. تكمن قيمة التعلم الانتقالي في قدرته على تكييف نموذج مدرب مسبقًا مع مهمة جديدة، مما يوفر الوقت والجهد والموارد الحسابية اللازمة لتدريب نموذج من الصفر.

Transfer Learning



شكل 17.3: آلية عمل التعلم الانتقالي.

لتحقيق أداءٍ مُحسّن وتجاوز تحديات تدريب نموذج من الصفر، إقترحنا الاستفادة من ثلاثة نماذج شهيرة للشبكات العصبية الإلتقافية (CNN) مُدرّبة مسبقًا: VGG-16 و MobileNetV2 و Inception-v3. تم تدريب هذه النماذج على مجموعة بيانات ImageNet الضخمة، والتي تضم ملايين الصور المُصنّفة إلى آلاف الفئات

المختلفة[6]. يُتيح لنا استخدام هذه النماذج المُدرّبة مسبقًا الاستفادة من المعرفة المكتسبة من مجموعة البيانات الضخمة ونقلها إلى مهمتنا الخاصة بتصنيف الأعشاب الضارة.

7.3 التعلم الإنتقالي : VGG-16

سنقوم بشرح عملية بناء النموذج، مع التركيز بكل خطوة على حدة


ا- تهيئة نموذج VGG-16 :

يتم استيراد نموذج[32] VGG-16 من مكتبة تطبيقات Keras مع تحميل أوزان ImageNet، والتي تمثل المعرفة المكتسبة من تدريبه على ملايين الصور. لتكييف نموذج VGG-16 مع مهمة تصنيف الأعشاب الخاصة بنا، تم تعيين الوسيط `include\_top = False` يؤدي هذا إلى إزالة الطبقات الأخيرة من النموذج الأصلي، والتي تكون مسؤولة عن التصنيف في مجموعة بيانات ImageNet. تم استبدال هذه الطبقات بطبقات جديدة مصممة خصيصًا لتصنيف الأنواع الأربعة للأعشاب الضارة في مجموعة البيانات الخاصة بنا. بالإضافة إلى ذلك، تم تحديد الوسيط `input\_shape` ليتوافق مع أبعاد صور التدريب، مما يضمن التوافق بين بنية النموذج وبيانات الإدخال.

```
from tensorflow.keras.applications.vgg16 import VGG16
```

```
model_vgg16 = VGG16(input_shape=(224, 224,3), include_top=False, weights='imagenet')
```

شكل 18.3: مقتطف من الكود لتحميل وتهيئة نموذج VGG-16.



شكل 19.3: تكيف نموذج مُدرّب مسبقًا لمهمة جديدة.

ب- تجميد الطبقات :

بهدف تسريع عملية التدريب وزيادة فعاليته، يتم تجميد جميع طبقات VGG-16 الأساسية والاستفادة من المعرفة المكتسبة مسبقاً من تدريبها على مجموعة بيانات ImageNet. يسمح هذا النهج للنموذج بالتركيز على تعلم الميزات الخاصة بمهمتنا في تصنيف الأعشاب من خلال الطبقات المضافة حديثاً، مع الاستفادة في الوقت ذاته من الميزات العامة المستخرجة بواسطة VGG-16 من مجموعة البيانات الضخمة.

```
for layer in model_vgg16.layers:
    layer.trainable=False
```

شكل 20.3: تجميد طبقات نموذج VGG-16 المُدرَّب مسبقاً.

نحن نفعل ذلك لأن طبقات VGG-16 تم تدريبها بالفعل على مجموعة بيانات ImageNet الضخمة، وهي قادرة على استخراج ميزات عالية المستوى من الصور. من خلال تجميد هذه الطبقات، فإننا نضمن الاحتفاظ بهذه المعرفة الأساسية أثناء تدريب نموذجنا الخاص.

وبالتالي، فإن تجميد طبقات VGG-16 يسمح لنموذجنا بالتركيز على تعلم الميزات المحددة لمهمة تصنيف الأعشاب الضارة، مع الاستفادة في نفس الوقت من القاعدة القوية التي توفرها طبقات VGG-16 المدربة مسبقاً.

ج- بناء النموذج :

```
In [73]: model = Sequential()
model.add(model_vgg16)
model.add(Flatten())
model.add(Dense(128, activation='relu'))
model.add(Dropout(0.35))#0.25
model.add(Dense(4, activation='softmax'))
```

```
In [74]: model.summary()
```

Model: "sequential_2"


Layer (type)	Output Shape	Param #
vgg16 (Functional)	(None, 7, 7, 512)	14714688
flatten_2 (Flatten)	(None, 25088)	0
dense_4 (Dense)	(None, 128)	3211392
dropout_4 (Dropout)	(None, 128)	0
dense_5 (Dense)	(None, 4)	516

```
=====
Total params: 17,926,596
Trainable params: 3,211,908
Non-trainable params: 14,714,688
```

شكل 21.3: ملخص لبنية النموذج المستند على التعلم الإنتقالي بإستخدام VGG-16.

يتم بناء نموذج التصنيف الخاص بنا باستخدام بنية متسلسلة من Keras. نبدأ بإضافة نموذج VGG-16 المُجمّد كطبقة أساسية، مما يُتيح لنا الاستفادة من ميزاته المُستخرجة مسبقاً من مجموعة بيانات ImageNet. تلي ذلك طبقة تسطيح (Flatten) لتحويل المخرجات متعددة الأبعاد من VGG-16 إلى متجه أحادي البعد، مما يُسهّل عملية المعالجة بواسطة الطبقات اللاحقة. نضيف بعد ذلك طبقة كثيفة (Dense) مكونة من 128 وحدة تنشيط مع دالة تنشيط ReLU لإدخال اللابخطية في النموذج. لتقليل فرصة التعلّم الزائد وتحسين قابلية التعميم، يتم دمج طبقة تسرب (Dropout) بنسبة 0.35. أخيراً، نضيف طبقة كثيفة أخرى مع 4 وحدات تنشيط ودالة تنشيط Softmax لإنتاج توزيع احتمالي على الفئات الأربعة للأعشاب الضارة.

من خلال الجمع بين القوة التمثيلية لنموذج VGG-16 المُدرّب مسبقاً والطبقات المضافة حديثاً، نُنشئ نموذج تصنيف قوياً ومرناً قادر على التمييز بدقة بين الأصناف الأربعة.



شكل 22.3: تصوير لمراحل نقل التعلم : تجميد الطبقات، استخراج الميزات، ثم التصنيف.

د- تجميع ثم تدريب النموذج :

قمنا بتجميع النموذج باستخدام دالة الخسارة 'categorical_crossentropy' وهي مناسبة لمهام التصنيف متعدد الفئات. مع اختيار مُحسّن Adam بمعدل تعلم 0.001 كما استخدمنا مقياس 'accuracy' لتقييم أداء النموذج أثناء التدريب. بعدها ، يتم تدريب النموذج على مجموعة البيانات الخاصة بنا ل 18 فترة، مما يسمح له بتعلم الأنماط المميزة للأعشاب الضارة وتعديل أوزانه وفقاً لذلك.

```
In [75]: adam = tf.keras.optimizers.Adam(learning_rate = 0.001)#0.0008


In [76]: model.compile(loss='categorical_crossentropy', optimizer='adam', metrics=['accuracy'])

In [77]: hist = model.fit(train_generator, epochs=18, validation_data=validation_generator)
```


```
Epoch 1/18
26/26 [=====] - 15s 541ms/step - loss: 1.4198 - accuracy: 0.5093 - val_loss: 0.7485 - val_accuracy: 0.7035
Epoch 2/18
26/26 [=====] - 11s 421ms/step - loss: 0.7417 - accuracy: 0.6795 - val_loss: 0.6753 - val_accuracy: 0.7538
Epoch 3/18
26/26 [=====] - 11s 424ms/step - loss: 0.5816 - accuracy: 0.7801 - val_loss: 0.4838 - val_accuracy: 0.8141
Epoch 4/18
26/26 [=====] - 11s 418ms/step - loss: 0.5014 - accuracy: 0.7925 - val_loss: 0.4564 - val_accuracy: 0.8241
Epoch 5/18
26/26 [=====] - 11s 424ms/step - loss: 0.4605 - accuracy: 0.8161 - val_loss: 0.3683 - val_accuracy: 0.8392
Epoch 6/18
26/26 [=====] - 11s 402ms/step - loss: 0.4333 - accuracy: 0.8373 - val_loss: 0.3775 - val_accuracy: 0.8643
Epoch 7/18
26/26 [=====] - 11s 380ms/step - loss: 0.4564 - accuracy: 0.8400 - val_loss: 0.3707 - val_accuracy: 0.8700
```

شكل 23.3: عرض لمراحل من عملية تدريب نموذج VGG-16.

Accuracy



Loss



شكل 24.3: منحني بياني يوضح دقة وخسارة نموذج VGG-16 خلال فترة التدريب.

```
In [65]: score = model.evaluate(validation_generator, steps=len(validation_generator))

accuracy = score[1] * 100
loss = score[0] * 100

print("Accuracy:", accuracy, "%")
print("Loss:", loss, "%")

7/7 [=====] - 11s 647ms/step - loss: 0.2625 - accuracy: 0.8894
Accuracy: 88.94472122192383 %
Loss: 26.250505447387695 %
```

شكل 25.3: تقييم أداء نموذج VGG-16: الدقة والخسارة على بيانات التحقق.

8.3 التعلم الإنتقالي : MobileNetV2

استكمالاً لإختبار تقنيات التعلم الإنتقالي، تم تطبيق نفس المنهجية وهذه المرة باستخدام نموذج MobileNetV2 المُدرَّب مسبقاً [26]. تم اتباع نفس الخطوات المذكورة سابقاً في بناء النموذج، مع تعديل طفيف تمثل في استخدام نسبة تسرب أقل (0.25) في طبقة Dropout للحد من تأثير التعلُّم الزائد. بالإضافة إلى ذلك، تم استخدام مُحسِّن Adam مع معدل تعلم مُخفَّف قيمته 0.00025 لتحقيق تقارب أكثر استقراراً. باقي الخطوات بما في ذلك تجميد طبقات النموذج ثم البناء والتدريب، فقد ظلت نفسها كذلك المستخدمة في نموذج VGG-16.

```
In [99]: model = Sequential()
model.add(model_mobilenetv2)
model.add(Flatten())
model.add(Dense(128, activation='relu'))
model.add(Dropout(0.25))
model.add(Dense(4, activation='softmax'))
```


```
In [100]: model.summary()
```

Model: "sequential_3"


Layer (type)	Output Shape	Param #
mobilenetv2_1.00_224 (Functional)	(None, 7, 7, 1280)	2257984
flatten_3 (Flatten)	(None, 62720)	0
dense_6 (Dense)	(None, 128)	8028288
dropout_5 (Dropout)	(None, 128)	0
dense_7 (Dense)	(None, 4)	516
Total params: 10,286,788		
Trainable params: 8,028,804		
Non-trainable params: 2,257,984		

شكل 26.3: ملخص لبنية النموذج المستند على التعلم الإنتقالي باستخدام MobileNetV2.

Accuracy



Loss



شكل 27.3: منحنى بياني يوضح دقة وخسارة نموذج MobileNetV2 خلال فترة التدريب.

النتيجة :

```
In [110]: score = model.evaluate(validation_generator, steps=len(validation_generator))

accuracy = score[1] * 100
loss = score[0] * 100

print("Accuracy:", accuracy, "%")
print("Loss:", loss, "%")

7/7 [=====] - 2s 291ms/step - loss: 0.2711 - accuracy: 0.9045
Accuracy: 90.45225977897644 %
Loss: 27.105426788330078 %
```

شكل 28.3: تقييم أداء نموذج MobileNetV2: الدقة والخسارة على بيانات التحقق.

9.3 التعلم الإنتقالي : Inception-v3

كما إستخدمنا ايضا نموذج Inception-v3 [37] علاوة على النموذجين السابقين وهو الأخير يتبع نفس الخطوات السابقة في البناء، الإختلاف هنا كان فقط باستخدام نسبة تسرب أقل (0.2) في طبقة Dropout. واستخدام مُحسّن Adam بمعدل تعلم 0.00025 وباقي الخطوات تبقى كما هي.

```
In [86]: model = Sequential()
model.add(model_inceptionv3)
model.add(Flatten())
model.add(Dense(128, activation='relu'))
model.add(Dropout(0.2))#0.1 #0.15
model.add(Dense(4, activation='softmax'))
```


```
In [87]: model.summary()
```

Model: "sequential_8"


Layer (type)	Output Shape	Param #
inception_v3 (Functional)	(None, 5, 5, 2048)	21802784
flatten_8 (Flatten)	(None, 51200)	0
dense_16 (Dense)	(None, 128)	6553728
dropout_8 (Dropout)	(None, 128)	0
dense_17 (Dense)	(None, 4)	516
Total params: 28,357,028		
Trainable params: 6,554,244		
Non-trainable params: 21,802,784		

شكل 29.3: ملخص لبنية النموذج المستند على التعلم الإنتقالي بإستخدام Inception-v3.

Accuracy



Loss



شكل 30.3: منحنى بياني يوضح دقة وخسارة نموذج Inception-v3 خلال فترة التدريب.

```
In [44]: score = model.evaluate(validation_generator, steps=len(validation_generator))

accuracy = score[1] * 100
loss = score[0] * 100

print("Accuracy:", accuracy, "%")
print("Loss:", loss, "%")
```

7/7 [=====] - 2s 288ms/step - loss: 0.2454 - accuracy: 0.9347
Accuracy: 93.46733689308167 %
Loss: 24.538904428482056 %

شكل 31.3: تقييم أداء نموذج Inception-v3: الدقة والخسارة على بيانات التحقق.

10.3 التقييم

1.10.3 تقييم نتائج النماذج على مجموعة التحقق Accuracy & Loss :

لتقييم أداء نماذج التصنيف الأربعة المستخدمة في هذا المشروع، تم إجراء اختبار شامل باستخدام مجموعة بيانات التحقق. اعتمد الاختبار على مقياسي الدقة والخسارة لتحديد مدى فعالية كل نموذج في مهمة تصنيف الأعشاب الضارة. يوفر الجدول 3.3 ملخصاً للنتائج، مما يتيح مقارنة مباشرة لأداء النماذج ومن ثم تحديد النموذج الأمثل للمهمة المطروحة.

النموذج	النموذج الخاص	VGG-16	MobileNetV2	Inception-v3
الدقة	82.41%	88.94%	90.45%	93.46%
الخسارة	44.44%	26.25%	27.10%	24.53%

جدول 3.3: ملخص لنتائج تقييم النماذج الأربعة على بيانات التحقق

تظهر نتائج التقييم تفوق نموذج Inception-v3 بشكل ملحوظ مقارنة بالنماذج الأخرى. فقد حقق أعلى قيمة للدقة بلغت 93.46% وأقل قيمة للخسارة بلغت 24.53%. يشير هذا الأداء إلى قدرة Inception-v3 الفائقة على تعلم الأنماط المعقدة في البيانات وتصنيف صور الأعشاب الضارة بدقة عالية.

وعليه، بناءً على نتائج التقييم النهائية، يعتبر نموذج Inception-v3 الخيار الأمثل لمهمة تصنيف الأعشاب الضارة في هذا المشروع نظراً لأدائه المتفوق مقارنة بالنماذج الأخرى.


2.10.3 مصفوفة الخطأ Confusion Matrix :

لتحقيق تقييم موضوعي وشامل لأداء النماذج الأربعة، تم استخدام مجموعة بيانات اختبار مستقلة. تتكون هذه المجموعة من صور للأعشاب المدروسة بمشروعنا وقد تم جمعها مسبقاً من حقول البطاطا بمنطقة الشرقية (شرق مدينة قمار)، مما يضمن تمثيلاً واقعياً للتحديات والظروف التي قد تواجهها النماذج في بيئة التطبيق الفعلية.

من خلال تحليل مصفوفات الخطأ [35] الناتجة عن تطبيق النماذج على مجموعة الاختبار، يمكننا تحديد أنواع الأخطاء التي يرتكبها كل نموذج وفهم نقاط القوة والضعف لكل منها بشكل أفضل. هذا التحليل المعمق يساعد في اختيار النموذج الأمثل للمهمة ويوفر رؤية قيمة لتحسين أداء النماذج في المستقبل.


يرجى الرجوع إلى الأشكال الآتية لمزيد من التفاصيل حول أداء النماذج على مجموعة الاختبار.

• مصفوفة الخطأ للنموذج الخاص :




شكل 32.3: مصفوفة الخطأ للنموذج الخاص.

• مصفوفة الخطأ لنموذج VGG-16 :




شكل 33.3: مصفوفة الخطأ لنموذج VGG-16.

• مصفوفة الخطأ لنموذج MobileNetV2 :



شكل 34.3: مصفوفة الخطأ لنموذج MobileNetV2.

• مصفوفة الخطأ لنموذج Inception-v3 :



شكل 35.3: مصفوفة الخطأ لنموذج Inception-v3.

تحليل أداء نموذج Inception-v3 :

يوضح تحليل مصفوفة الخطأ لنموذج Inception-v3 قدرة النموذج على تصنيف أنواع الأعشاب الأربعة بدقة جيدة. تتجلى هذه الدقة في تركيز التوقعات الصحيحة على طول القطر الرئيسي للمصفوفة، مما يشير إلى نجاح النموذج في تعلم الأنماط المميزة لكل نوع.

ومع ذلك، يكشف التحليل أيضًا عن بعض التحديات، خاصة في تصنيف أعشاب النجم. حيث تم تصنيف حالتين من هذا النوع بشكل خاطئ على أنهما من نوع ذيل الفار، مما يشير إلى احتمال وجود تشابه بصري بينهما يربك النموذج. وهو في الواقع أمر بديهي لأن كلاهما متشابهان وينتميان إلى نفس العائلة عائلة النجاليات. من ناحية أخرى، يُظهر النموذج أداءً ممتازًا في تصنيف أنواع معينة، مثل المزريطة و الخبيز، حيث لم يسجل أي أخطاء في التصنيف.

بشكل عام، يُعد أداء نموذج Inception-v3 جيدًا، لكنه ومع ذلك يبقى قابلًا للتحسين، خاصة فيما يتعلق بتصنيف أعشاب النجم. يمكن تحقيق ذلك من خلال زيادة حجم البيانات التدريبية لهذا النوع، مما يساعد النموذج على تعلم تمييزه بشكل أفضل.

11.3 حفظ النموذج

1.11.3 حفظ النموذج بصيغة h5 :

تم حفظ نموذج Inception-v3 الذي حقق أفضل أداء باستخدام الأمر `model.save` لنتمكن من استخدامه لاحقًا على موقعنا "كشف".

```
In [93]: model.save('Projet_InceptionV3_model.h5')
```

شكل 36.3: حفظ نموذج InceptionV3 بالجهاز.

2.11.3 تحويل النموذج لصيغة tflite :

ولغرض توظيف النموذج أيضًا بتطبيق أندرويد تم تحويل النموذج من صيغة h5 إلى صيغة tflite. المُخصصة للأجهزة المحمولة الخفيفة. مما تضمن كفاءة في الأداء وسرعة في التحميل والاستجابة، وذلك عبر تقليص حجم النموذج بشكل كبير.

```
inceptionv3_model = tf.keras.models.load_model('Projet_InceptionV3_model.h5')
```

```
tflite_converter = tf.lite.TFLiteConverter.from_keras_model(inceptionv3_model)
```

```
tflite_model = tflite_converter.convert()
```

```
WARNING:absl:Found untraced functions such as _jit_compiled_convolution_op, _jit_compiled_convolution_op, _jit_compiled_convolution_op, _jit_compiled_convolution_op, _jit_compiled_convolution_op while saving (showing 5 of 94). These functions will not be directly callable after loading.
```

```
INFO:tensorflow:Assets written to: C:\Users\ADMINI~1\AppData\Local\Temp\tmpwe9ruxra\assets
```

```
INFO:tensorflow:Assets written to: C:\Users\ADMINI~1\AppData\Local\Temp\tmpwe9ruxra\assets
```

```
open("tf_lite_model.tflite", "wb").write(tflite_model)
```

```
113354088
```

شكل 37.3: تحويل النموذج من صيغة h5 إلى صيغة tflite.


12.3 توظيف النموذج بموقع ويب

قمنا بتطوير موقع ويب تفاعلي يعتمد على مكتبة Flask في Python للواجهة الخلفية (Backend)، بينما تم بناء واجهة المستخدم الأمامية (Frontend) باستخدام HTML، CSS و JavaScript [18]. يتيح الموقع للمستخدم رفع صورة لعشبة مشبوهة، ثم يقوم نموذج الذكاء الاصطناعي المدمج بتحليل الصورة وتحديد نوع العشبة فيعرض النوع مع دقة التنبؤ. لا يقتصر الموقع على التصنيف فحسب، بل يوفر أيضًا قسم "مكتبة" غني بالمعلومات. يقدم هذا القسم تفاصيل شاملة عن كل نوع من الأعشاب التي يتعرف عليها النموذج، بما في ذلك خصائصها وطرق مكافحتها. وبهذه الطريقة، يصبح الموقع بمثابة مرجع شامل للفلاحين، يساعد على اتخاذ قرارات مدروسة لإدارة الأعشاب الضارة وحماية محاصيلهم.


إستعراض الموقع :



يرجى إضافة صورة للكشف



شكل 38.3: الصفحة الرئيسية للموقع.



شكل 39.3: صفحة الكشف للموقع.



الرئيسية
كشف
مكتبة
عن مشروعنا



النتيجة: Malva (خبيز)

الدقة: 78.63%



كشف

لمزيد من المعلومات حول هذه العشبة يرجى الضغط [هنا](#)

شكل 40.3: إستعراض لنتيجة كشف عن عشبة خبيز.



الرئيسية
كشف
مكتبة
عن مشروعنا



مربطة
نجم
خبيز
ذيل الفار



Chenopodium murale
(مربطة)

العائلة الرمرامية Chenopodiaceae

نبات عشبي حولي، يتميز برائحة قوية غير مستحبة، السيقان مضلعة أو شبه أسطوانية، لونها يميل إلى الأحمر الأرجواني، وهي عارية ملساء. الأوراق متبادلة على الساق، شكلها مثلثي وذات حواف مسننة ملساء ولونها أخضر وقد يميل إلى الأحمر في بعض الأحيان. الأزهار صغيرة جدا تتجمع في نورات كثيفة تخرج من ابط الأوراق.

النمو والإزهار :

ينمو نبات المربطة كلما توفرت له الظروف المناسبة، حيث نجده تقريبا في معظم فصول السنة ناهيا في الحداثق وبين المزروعات. إلا أن فصل الربيع هو أهم الفصول التي يزدهر فيها

أماكن التواجد :

يزدهر في الحداثق والمرارح ومعظم الأماكن الرطبة، كما ينمو في مناطق الروابي والمرتفعات المحيطة بالأهواض والمزارع، ونادرا ما نجده في المناطق الرملية الجافة

الانتشار الجغرافي :

نبات عالمي الانتشار Cosmopolites فهو ينمو في معظم بقاع العالم.

ملاحظات :

- نبات ضار جدا، يصعب القضاء عليه إذا طغى على منطقة معينة، وذلك بسبب قدرته الهائلة على إنتاج البذور والتكاثر
- تشير بعض البحوث إلى إمكانية الحصول على مواد مبيدة للأفات الحشرية المصيبة للحبوب المحرزة، فقد لوحظ مثلا أن مستخلصات هذا النبات بواسطة الهكسان والإيثانول
- تمتلك خواص إبادة ضد الحشرات الضارة بالحبوب

رسم توضيحي للمربطة
Chenopodium murale L.
(الشكل 1)

الساق قائمة، مضلعة أو شبه أسطوانية، خضراء أو حمراء.



شكل 41.3: صفحة من صفحات المكتبة.



شكل 42.3: صفحة "عن مشروعنا".

13.3 توظيف النموذج بتطبيق أندرويد

تم تطوير تطبيق أندرويد بلغة البرمجة Java مع استخدام مكتبة Flutter لواجهة المستخدم [33]. يتيح هذا التطبيق للمستخدم إمكانية التعرف على أنواع الأعشاب التي تم تدريب النموذج عليها في مشروعنا. يمكن للمستخدم إما تحميل صورة عشبة من معرض الصور الخاص به أو التقاط صورة مباشرة باستخدام كاميرا الهاتف. بعد ذلك، يقوم نموذج الذكاء الاصطناعي المدمج في التطبيق بتحليل الصورة وتحديد نوع العشبة المعروضة، ومن ثم عرض اسمها للمستخدم.


إستعراض التطبيق :



شكل 43.3: أيقونة التطبيق.





(ب) الواجهة الرئيسية



(أ) واجهة الترحيب

شكل 44.3: واجهة التطبيق.



شكل 45.3: إستعراض لبعض نتائج التصنيف.

14.3 خاتمة

في هذا الفصل، خضنا تجربة عملية قيمة في بناء وتطبيق نموذج CNN لتصنيف صور الأعشاب الضارة. بدءاً من بناء نموذج بسيط من الصفر، وصولاً إلى الاستفادة من قوة التعلم الانتقالي، وقد أثبت نموذج Inception-v3 كفاءته في تحقيق دقة عالية في التصنيف. لم يقتصر الأمر على بناء النماذج فحسب، بل قمنا بتوظيف النموذج الأمثل لمهمتنا في موقع ويب وكذلك بتطبيق أندرويد للهاتف، مما يبرز الإمكانيات العملية لهذه التقنية في مساعدة الفلاحين على التعرف على أنواع الأعشاب الضارة والتعامل معها بشكل فعال. لقد رأينا كيف يمكن للذكاء الاصطناعي أن يكون أداة قوية في تحسين الإنتاج الزراعي.

الخاتمة

تُعد تقنية التعلم العميق، وتحديدًا شبكات CNNs، من الأدوات الفعالة في مجال تصنيف الصور، وذلك بفضل قدرتها على تحليل الصور المعقدة واستخراج الميزات المهمة منها. وقد برزت هذه التقنية كحل واعد لمشكلة تحديد وتصنيف الأعشاب الضارة، وتوظيفها مستقبلاً في روبوتات أو درونات ذكية.

تبدأ رحلة التعلم العميق مع جمع البيانات، حيث يتم تجميع صور للأعشاب الضارة المختلفة، وتُعتبر جودة الصور ودقتها من العوامل المؤثرة في أداء النموذج. ثم تأتي مرحلة بناء نموذج CNN، والتي يمكن تنفيذها من الصفر أو بالاستعانة بالتعلم الانتقالي. وفي هذه المذكرة، تم التطرق لكلا النهجين، حيث تم بناء نموذج بسيط من الصفر لفهم آلية عمل الشبكات، ومن ثم تم استخدام نماذج VGG-16 و MobileNetV2 و Inception-v3 المدربة مسبقاً للاستفادة من قوتهم في التصنيف وتوفير الوقت وتجنب الزيادة بحجم مجموعة البيانات.

يُشبه عمل نموذج CNN عملية التعرف على الوجه، حيث يتم تحويل الصور إلى مجموعة من الميزات الرقمية، والتي تُستخدم لتمييز الأعشاب الضارة عن بعضها البعض. ويُعتبر ضبط المعلمات الفائقة من العوامل المهمة التي تؤثر على دقة النموذج، حيث يتم اختيار القيم المناسبة لهذه المعلمات لتحقيق أفضل أداء.

ولإبراز الجانب التطبيقي لهذه التقنية، تم دمج النموذج الأمثل لمهمتنا والذي كان (Inception-v3) بموقع ويب ثم بتطبيق أندرويد، مما يتيح للفلاحين إمكانية التقاط صور للأعشاب الضارة والحصول على تصنيف فوري لها.

تُعد هذه المذكرة دليلاً على فعالية تقنية التعلم العميق في مواجهة تحديات القطاع الزراعي، وتحديدًا مشكلة الأعشاب الضارة. كما تفتح الباب أمام المزيد من الأبحاث والتطوير، بهدف تحسين دقة النماذج وتوسيع نطاق تطبيقاتها، لتشمل مجالات زراعية أخرى.

تتجاوز رؤيتنا المستقبلية مجرد الكشف عن الأعشاب الضارة، فنحن نطمح إلى تطوير نظام متكامل لإدارة الحقول الزراعية بالاعتماد على الذكاء الاصطناعي والدرونات الذكية. سيتمكن هذا النظام من مسح الحقول بشكل دوري وجمع البيانات الحيوية عن صحة المحاصيل، ومستويات الرطوبة، وغيرها من المؤشرات الهامة. وبناءً على هذه البيانات، ستقوم الدرونات بتوزيع المياه بشكل دقيق وفعال، والكشف عن الآفات والأمراض في مراحلها المبكرة، واتخاذ الإجراءات اللازمة للسيطرة عليها. هذا التكامل بين الذكاء الاصطناعي وتقنيات الدرونات سيُمكن الفلاحين من إدارة حقولهم بشكل أكثر فعالية واستدامة، مما يؤدي إلى زيادة الإنتاجية وتقليل التكاليف وتحقيق أرباح أكبر.

المصادر

[1] Yandex,google,bing.

[2] التطبيقات العملية في مبيدات الآفات. Distribution, and Publication for Group Yazouri .2016

[3] Agarap. Fred Abien *arXiv* (relu). units linear rectified using learning Deep .2018 ,*arXiv:1803.08375 preprint*

[4] Alshapiny. Atef Ahmed MR Alshapiny, Ahmed كتاب شامل عن انتاج وزراعة وتصدير المحاصيل الزراعية بوادي النطرون - جمهورية مصر العربية. Independent CreateSpace .2014 Platform, Publishing

[5] Rehalia. Arvind and Jolly, Singh Harman Arora, Eshaan of Prediction *International 3rd 2023 In cnn. and ann using disorder spectrum autism Sciences Computational in Advancements Technological on Conference* .2023 IEEE, .461--457 pages ,(ICTACS)

[6] Fei-Fei. Li and Li, Kai Li, Li-Jia Socher, Richard Dong, Wei Deng, Jia *IEEE 2009 In database. image hierarchical large-scale A Imagenet: recognition pattern and vision computer on conference* .255--248 pages ,.2009 leee,

[7] Monika and Dixit, Muskaan Sharma, Nikhil Kaushik, Yash Handa, Nishit *Advanced In networks. neural convolutional using classification Image Garg. ICAICR Conference, International 4th Research: Computing for Informatics Papers, Selected Revised ,2020 ,27--26 December India, Gurugram, ,2020* .2021 Springer, .517--510 pages ,4 I Part

- chemical of Journal* overfitting. of problem The Hawkins. M Douglas [8]
sciences computer and information ,12--1:(1)44 ,2004
- and Aljarah, Ibrahim Mirjalili, Seyedali Faris, Hossam Heidari, Asghar Ali [9]
 application and review, literature theory, optimizer: lion Ant Mafarja. Majdi
Optimizers: Nature-Inspired networks. neural perceptron multi-layer in
 .2020 ,46--23 pages ,*Applications and Reviews Literature Theories*,
- cnn on study A Faria. R Diego and Bird, J Jordan Hussain, Mahbub [10]
Computational in Advances In classification. image for learning transfer
on Workshop UK 18th the at Presented Contributions Systems: Intelligence
 pages ,UK Nottingham, ,2018 ,7-5 September *Intelligence, Computational*
 .2019 Springer, .202--191
- Flattened Culurciello. Eugenio and Dundar, Aysegul Jin, Jonghoon [11]
preprint arXiv acceleration. feedforward for networks neural convolutional
 .2014 ,*arXiv:1412.5474*
- Soft- Li. Z Stan and Liao, Shengcai Lei, Zhen Wang, Xiaobo Liang, Xuezhi [12]
Neural on Conference International In classification. deep for softmax margin
 .2017 Springer, .421--413 pages ,*Processing Information*
- and Akerman, J Colin Marris, Luke Santoro, Adam Lillicrap, P Timothy [13]
Reviews Nature brain. the and Backpropagation Hinton. Geoffrey
 .2020 ,346--335:(6)21 ,*Neuroscience*
- review: A Nemade. Bhushankumar and Mondal, Surajit Maharana, Kiran [14]
Transitions Global techniques. augmentation data and pre-processing Data
 .2022 ,99--91:(1)3 ,*Proceedings*
- Org. Agriculture & Food .*alfalfa East: Near the for Fodders* Marble. V.L. [15]
- Org. Agriculture & Food .انتاج الأعلاف في الشرق الأدنى : الفصة. Marble. V.L. [16]

- sign traffic based Cnn Vaidya. Bhaumik and Paunwala, Chirag Mehta, Smit [17]
on conference international 2019 In optimizer. adam using classification
 .2019 IEEE, .1293 page ,(ICCS) *systems control and computing intelligent*
- Rasyid, Al Harun Udin M Basofi, Arif Mufid, Robihul Mohammad [18]
 for python using model mvc an Design al. et Rochimansyah, Farhandika Indhi
Symposium Electronics International 2019 In development. framework flask
 .2019 IEEE, .219--214 pages ,(IES)
- Convolutional 3D and Imaging Hyperspectral Exploring* Noshiri. Nooshin [19]
 University thesis, PhD .*Plants in Classification Stress for Network Neural*
 .2023 Winnipeg, of
- techniques splitting Dataset Hasanah. Uswatun and Nurhopipah Ade [20]
Journal (Indonesian IJCCS images. cctv on classification face for comparison
 .2020 ,352--341:(4)14 ,*Systems) Cybernetics and Computing of*
- Yuhui and Yuan, Feng Khan, Asifullah Yi, Xiaokai Yu, Weijie Pan, Zhaoqing [21]
 A (gans): networks adversarial generative on progress Recent Zheng.
 .2019 ,36333--7:36322 ,*access IEEE survey.*
- .*approach practitioner's A learning: Deep* Gibson. Adam and Patterson Josh [22]
 .2017 Inc.", Media, O'Reilly "
- in augmentation data of effectiveness The Wang. Jason and Perez Luis [23]
 ,*arXiv:1712.04621 preprint arXiv learning. deep using classification image*
 .2017
- Feature Promrit. Nuttachot and Waijanya, Sajjaporn Prombut, Naris [24]
 speech thai for network conv2d and conv1d on based technique extraction
Conference International 5th 2021 the of Proceedings In recognition. emotion
 ,60--54 pages ,*Retrieval Information and Processing Language Natural on*

.2021

Karen Wang, Xiaosong Hadjiiski, M Lubomir Pezeshk, Aria Sahiner, Berkman [25]
Deep Giger. L Maryellen and Summers, M Ronald Cha, H Kenny Drukker,
46(1):e1- ,*physics Medical* therapy. radiation and imaging medical in learning
.2019 -e36,

and Zhmoginov, Andrey Zhu, Menglong Howard, Andrew Sandler, Mark [26]
bottlenecks. linear and residuals Inverted Mobilenetv2: Chen. Liang-Chieh
pattern and vision computer on conference IEEE the of Proceedings In
.2018 ,4520--4510 pages ,*recognition*

Muhammad, AbdulHafeez Malik, Mahmood Abid Hafiz Shah, Ali Asghar [27]
cnn 2d ensemble learning Deep Butt. Arif Zaeem and Alourani, Abdullah
,2987:(1)13 ,*reports Scientific* cancer. lung of detection the towards approach
.2023

Sequential Huang. Tiejun and Wang, Yaowei Tian, Yonghong Shi, Yemin [28]
IEEE cnn. three-stream with recognition action for descriptor trajectory deep
.2017 ,1520--1510:(7)19 ,*Multimedia on Transactions*

and Sutskever, Ilya Krizhevsky, Alex Hinton, Geoffrey Srivastava, Nitish [29]
networks neural prevent to way simple a Dropout: Salakhutdinov. Ruslan
,1958--1929:(1)15 ,*research learning machine of journal The* overfitting. from
.2014

text Generating Hinton. E Geoffrey and Martens, James Sutskever, Ilya [30]
international 28th the of Proceedings In networks. neural recurrent with
.2011 ,1024--1017 pages ,(ICML-11) *learning machine on conference*

computer for images resize to Learning Milanfar. Peyman and Talebi Hossein [31]
on conference international IEEE/CVF the of Proceedings In tasks. vision

- .2021 ,506--497 pages ,*vision computer*
- convolutional deep with vgg-16 using learning Transfer Tammina. Srikanth [32]
and Scientific of Journal International images. classifying for network neural
 .2019 ,150--143:(10)9 ,(*IJSRP*) *Publications Research*
- Pranali and Giri, Trishul Gala, Rushabh Shah, Nisha Tashildar, Aakanksha [33]
Research International flutter. using development Application Chavhan.
 -1262:(8)2 ,*Science and Technology Engineering in Modernization of Journal*
 .2020 ,1266-
- VanCleave. Janice [34] البيئة: مشاريع العلوم المدهشة أنشطة سهلة ومفيدة تزيد من متعة تعلم العلوم
 . المجموعة العربية للتدريب والنشر, 2019.
- Knaap. Der Van Esther and Ralescu, L Anca Ramsay, Brian Visa, Sofia [35]
 .2011 ,127--120:(1)710 ,*Maics* selection. feature matrix-based Confusion
- Deep Zhang. Yudong and Wang, Shuihua Peng, Yibin Zhou, Jin Wu, Meng [36]
on Conference International In review. a classification: image for learning
 Springer, .362--352 pages ,*Diagnosis Computer-Aided and Imaging Medical*
 .2023
- In classification. flower for Inception-v3 Nan. Bing and Xu, Cui Xia, Xiaoling [37]
 ,(*ICIVC*) *computing and vision image, on conference international 2nd 2017*
 .2017 IEEE, .787--783 pages
- graph A Yin. Hongmei and Yang, Min Ai, Tinghua Yan, Xiongfeng [38]
 using patterns building of classification for network neural convolutional
 ,*sensing remote and photogrammetry of journal ISPRS* data. vector spatial
 .2019 ,273--150:259
- [39] مركز الملك فيصل للبحوث والدراسات الإسلامية. مجلة الفيصل العدد 92. 1984.
- [40] حمزة الجبالي. التحديات البيئية في القرن الحادي والعشرين. Dar and Media Ausra Al Dar

.2016 Al-Thaqafa, Alam

- [41] خبير الحبوب. مكافحة الأعشاب الضارة. 2015.
- [42] منظمة الأغذية والزراعة للأمم المتحدة. مدونة السلوك الدولية بشأن استخدام الأسمدة وإدارتها على نحو مستدام. 2019 Org., Agriculture & Food.
- [43] منظمة الأغذية والزراعة للأمم المتحدة. موجز عن حالة الأغذية والزراعة التغلب على تحديات المياه في الزراعة. 2020 Org., Agriculture & Food.
- [44] منظمة الأغذية والزراعة للأمم المتحدة. دليل المزارع للمعاملات الزراعية الجيدة لزراعة البطاطا. Food 2021 Org., Agriculture &
- [45] منظمة الأغذية والزراعة للأمم المتحدة. لتدريب الزراعي المهني المعجل مقرّر منهاج وحدة إنتاج الأشجار المثمرة: التفاح. 2021 Org., Agriculture & Food.
- [46] منظمة الأغذية والزراعة للأمم المتحدة. دليل مدارس المزارعين الحقلية لإدارة سوسة النخيل الحمراء في اقليم الشرق الأدنى وشمال افريقيا. 2023 Org., Agriculture & Food.
- [47] الدكتور سعد الله نجم النعيمي. تلوث بيئة الانسان بالمعادن الثقيلة وطرق المعالجة. دار الكتب العلمية, 2020.
- [48] الدكتور سعد الله نجم النعيمي. التربة السليمة وصحة الغذاء. 2021.
- [49] جامعة ولاية بنسلفانيا. *Protection Plant of Journal Arab*. Plant for Society Arab 2010 Protection,
- [50] وصفي زكريا. زراعة المحاصيل الحقلية الجزء الأول. 2024.
- [51] وصفي زكريا. زراعة المحاصيل الحقلية الجزء الثاني. 2024.
- [52] دكتور باحث/ محمد طه عبد الرحمن زلمه. الاتجاهات الحديثة لدعم وتنمية نظام الحبوب العالمي إنتاج، استدامة، صون البيئة. 2023 ZALAMA, ABDELRAHMAN TAHA MOHAMED.
- [53] محمود موسي أبو عرقوب. المقاومة الحيوية لأمراض النبات - الجزء الأول. INC. ktab.
- [54] د.عبد الستار عارف علي. الادارة المتكاملة للآفات الزراعية. and Publishing for Beyrouni Distributing - دار البيروني للنشر والتوزيع, 2017.

[55] جامعة ميتشيغان. البيئة والتنمية. المنشورات التقنية, 2001.

[56] جامعة ميتشيغان. *al-Ta'āwunī wa al-Zirā'ī al-Taslīf Bank Nashrat*. 2008.

[57] حليس يوسف. الموسوعة النباتية لمنطقة وادي سوف. 2007.

إختصارات

<i>AI</i>	:	Artificial Intelligence	الذكاء الاصطناعي
<i>ML</i>	:	Machine Learning	تعلم الآلة
<i>DL</i>	:	Deep Learning	التعلم العميق
<i>CNNs</i>	:	Convolutional Neural Networks	الشبكات العصبية الالتقافية
<i>CNN</i>	:	Convolutional Neural Network	الشبكة العصبية الالتقافية
<i>RNN</i>	:	Recurrent Neural Network	الشبكة العصبية التكرارية
<i>GAN</i>	:	Generative Adversarial Network	الشبكة التوليدية التنافسية
<i>MLP</i>	:	Multi-Layer Perceptron	
<i>NLP</i>	:	Natural Language Processing	معالجة اللغة الطبيعية
<i>Conv2D</i>	:	Convolutional 2D	طبقة التقاف ثنائية الأبعاد
<i>VGG</i>	:	Visual Geometry Group	مجموعة الهندسة البصرية
<i>.h5</i>	:	Hierarchical Data Format version 5 (HDF5)	
<i>.tflite</i>	:	TensorFlow Lite	