



Université Mohamed Khider de Biskra
Faculté des Sciences Exactes et des Sciences de la Nature
et de la Vie
Département des Sciences Agronomiques

MÉMOIRE DE MASTER

Science de la Nature et de la Vie
Sciences Agronomiques
Spécialité : Production végétale

Réf. : Entrez la référence du document

Présenté et soutenu par :
GUETTALA Mohamed-Islam

Le : Lundi 10 juin 2024

Reconnaissance des variétés locales de piment (Capsicum annuum L.) moyennant l'approche du deep Learning

Jury :

Pr.	Mehaoua Mohammed Seghir	Pr	Université Mohamed Khider Biskra.	Président
Dr.	Bedjaoui Hanane	MCA	Université Mohamed Khider Biskra.	Rapporteur
Dr.	Laabassi Karim	MCB	Ecole nationale supérieure agronomique.	
Dr.	Djoudi I.	MCB	Université Mohamed Khider Biskra.	Examineur

Anne universitaire 2023/2024

Dédicace

Je dédie ce travail en ligne de respect, de reconnaissance et de gratitude :

A mes chers parents sans eux, je n'aurais jamais atteint la place où je suis sans leurs admirables rôles et qui m'ont apporté une aide essentielle, une motivation constante par leur soutien leur encouragement permanent, leur assistance et leur amour.

A mon frère et mes sœurs à l'ensemble de ma famille et à mes collègues qui ont été toujours un soutien appréciable.

Remerciements

«Qu'il me soit d'abord permis de remercier et d'exprimer ma gratitude envers le bon DIEU, qui m'a donné la patience et la santé pour que je puisse continuer ce travail. »

J'exprime mes sincères remerciements à **Dr. Hanane BEDJAOUI** et **Dr. Karim LAABASSI**, pour m'avoir fait l'honneur d'être rapporteurs du présent mémoire. Leurs conseils, avisés, leurs aides et encouragements m'ont toujours été précieux et aussi la confiance qu'elles m'ont toujours témoignée, a contribué à alimenter ma réflexion. Elles m'ont été d'un grand secours pour l'accomplissement de ce travail. Je leur en suis très reconnaissante. Qu'elles trouvent ici l'expression de ma sincère gratitude et de mon profond respect.

Je tiens à remercier profondément les membres de jury :

- **Dr. Djoudi .I.**, d'avoir accepté d'examiner ce travail
- **Pr. Mehaoua Mohammed Seghir**, d'avoir accepté d'examiner ce travail et de m'avoir honoré de présider le jury.

Je tiens aussi à exprimer ma profonde gratitude et mes remerciements à l'ensemble du personnel du Département d'agronomie de l'Université de Biskra : enseignants, personnel administratif chacun par son nom

Résumé

Le piment (*Capsicum annuum* L.) a une place importante dans l'alimentation algérienne, toutefois, la diversité génétique de nos variétés locales demeure peu explorée d'où l'intérêt de notre étude qui fait appel à des outils de classification plus discriminants. Notre objectif est de développer une approche de vision par ordinateur basée sur les techniques d'apprentissage profond (CNN) qui offre une grande précision dans la caractérisation variétale afin d'identifier et de classer les populations locales de piment sur la base d'images de feuilles et de fruits. Au total 11 variétés locales de piment et une variété hybride ont fait l'objet de notre étude. Nous avons réalisé deux expérimentations, la première utilise le DenseNet201, une architecture de CNN, pour la classification des images de fruits et de feuille et la deuxième consiste à déployer YOLOv8s d'Ultralytics pour la reconnaissance variétale basée sur le fruit. Les résultats obtenus ont permis d'atteindre une précision de 95 % pour la classification des images du fruit et une précision de 89 % pour la classification des feuilles (modèle DenseNet201). Le modèle YOLOv8s a montré une performance globalement solide et des niveaux élevés de précision, avec un mAP50 de 90% et un mAP50-95 de 80%, ce qui est très performant. Cette étude confirme en particulier la présence de diversité génétique estimable inter et intra variétale chez le piment en Algérie et ouvre des perspectives de classification et de caractérisation fiables de notre patrimoine génétique.

Mots-clés : Algérie, Apprentissage profond ; *Capsicum annuum* L ; CNN ; DenseNet201 ; Ressources génétiques ; YOLOv8s.

Abstract

The chili pepper (*Capsicum annuum* L.) holds a significant place in Algerian cuisine. However, the genetic diversity of our local varieties remains underexplored, which highlights the importance of our study that utilizes more discriminating classification tools. Our objective is to develop a computer vision approach based on deep learning techniques (CNN) that offers high precision in varietal characterization to identify and classify local chili pepper populations based on images of leaves and fruits. In total, 11 local varieties of chili peppers and one hybrid variety were included in our study. We conducted two experiments: the first using DenseNet201, a CNN architecture, for classifying images of fruits and leaves, and the second deploying Ultralytics' YOLOv8s for varietal recognition based on the fruit. The results achieved an accuracy of 95% for fruit image classification and an accuracy of 89% for leaf classification (DenseNet201 model). The YOLOv8s model demonstrated robust overall performance and high levels of precision, with a mAP50 of 90% and a mAP50-95 of 80%, which is very impressive. This study particularly confirms the presence of significant inter- and intra-varietal genetic diversity in chili peppers in Algeria and opens up prospects for reliable classification and characterization of our genetic heritage.

Key Words: *Capsicum annuum* L.; CNN; Deep learning; DenseNet201; Genetic resources; YOLOv8s.

ملخص

الفلفل (*Capsicum annum L.*) يحتل مكانة مهمة في المطبخ الجزائري. ومع ذلك، فإن التنوع الجيني لأنواعنا المحلية لا يزال غير مستكشف بشكل كافٍ، مما يبرز أهمية دراستنا التي تستخدم أدوات تصنيف أكثر تمييزًا. هدفنا هو تطوير نهج رؤية حاسوبية يعتمد على تقنيات التعلم العميق (CNN) الذي يوفر دقة عالية في التوصيف النوعي لتحديد وتصنيف الأصناف المحليين للفلفل على أساس صور الأوراق والثمار. شملت دراستنا ما مجموعه 11 نوعًا محليًا من الفلفل ونوعًا هجينًا واحدًا. أجرينا تجربتين: الأولى تستخدم DenseNet201، وهي بنية CNN، لتصنيف صور الثمار والأوراق، والثانية تعتمد على YOLOv8s من Ultralytics للتعرف على الأنواع بناءً على الثمرة. حققت النتائج دقة بنسبة 95% لتصنيف صور الثمار ودقة بنسبة 89% لتصنيف الأوراق (نموذج DenseNet201). أظهر نموذج YOLOv8s أداءً قويًا بشكل عام ومستويات عالية من الدقة، مع mAP50 بنسبة 90% و mAP50-95 بنسبة 80%، وهو أداء متميز. تؤكد هذه الدراسة بشكل خاص وجود تنوع جيني كبير بين الأنواع وداخل الأنواع في الفلفل في الجزائر وتفتح آفاقًا لتصنيف وتوصيف موثوق لتراثنا الجيني.

كلمات مفتاحية: الفلفل، يولو v8s، شبكة DenseNet201، الموارد الجينية، الفلفل الحار، الشبكة العصبية التلافيفية، التعلم العميق.

Table de matière

Table des matières.....	I
Liste des figures.....	II
Liste des tableaux.....	III
Liste des abréviations.....	VI
Introduction générale.....	1
Partie bibliographique	
Chapitre I : Présentation de la plante.....	3
I. 1 Généralités sur l'espèce.....	4
I.1.1 Genre capsicum.....	4
I.1.2. Origine et historique.....	4
I.1.3. Systématique.....	4
I.2 Présentation de la plante.....	5
I.2.1 Détermination des stades phénologiques à l'aide de l'échelle du piment BBCH.....	5
I.2.2 Morphologie de la plante.....	5
I.2.2.1. Appareil végétatif.....	6
I.2.2.2 Appareil reproducteur.....	7
I.3 Présentation de la culture.....	8
I.3.1 Exigences de la culture.....	8
I.3.2 Conduite de la culture.....	9
I.3.2.1 Préparation du sol.....	9
I.3.2.2 Fumure de fond.....	9
I.3.2.4 Travaux d'entretien.....	9
I.3.2.5 Protection phytosanitaire.....	10
I.3.3.1. Maladies.....	10
I.3.3.2. Ravageurs.....	11
Chapitre II : Outils d'étude de la diversité génétique.....	12
II.1 Approche conventionnelle (descripteurs IPGRI).....	13
II.1.1 Etude morphologique.....	13
II.1.2 Etude biochimique.....	14
II.2 Approche non conventionnelle basée sur l'intelligence artificielle (IA).....	15
II .2.1 Intelligence artificielle.....	15
II.2.1.1 Algorithme d'apprentissage automatique supervisé.....	15

II.2.1.2 Reconnaissance d'objet par la Vision par ordinateur.....	18
II.2.1.3 Construction et évaluation des modèles.....	19
II.2.1.4 Application des Réseau de neurones convolutifs (CNN) en agriculture.....	21
II.2.1.5 Algorithme YOLO pour la détection d'objets en agriculture.....	24
II.2.1.5.1 Métriques de détection d'objets (YOLO).....	26
II.2.1.6 Étude de cas pour la reconnaissance variétale.....	27
Partie expérimentale	
Chapitre III : Matériel et méthodes.....	31
III.1. Site d'expérimentation.....	32
III.2. Matériel végétal.....	32
III.3 Dispositif expérimental.....	34
III.4.1. Caractéristiques du dispositif expérimental.....	34
III.5. Conduite culturale.....	35
III.5.1. Pépinière.....	35
III.5.2. Calendrier cultural.....	36
III .6. Mise en place de la culture.....	36
III .6.1. Pré irrigation.....	36
III .6.2. Transplantation.....	37
III .6.3 Travaux d'entretien de la culture.....	37
III .7 La Création de base des données.....	43
III. 7.1 Collecte de données.....	43
III. 7.2. Classification d'images.....	43
III. 7.2.1 Paramètres utilisés.....	45
III. 7.2.2 Paramètres utilisés.....	47
III. 7.2.3 Entraînement de modèle DenseNet201.....	47
III. 7.2.4 Validation de modèle.....	47
III. 7.2.5 Tester le modèle.....	48
III. 7.3. Déployer reconnaissance d'objets YOLO.....	48
III. 7.3.1 Labellisation des données.....	48
III. 7.3.1 Paramètres utilisés.....	50
III. 7.3.2 Entraînement du modèle YOLOv8.....	50
III. 7.3.3 Évaluation du modèle.....	51
III. 7.4. Langage de programmation utilisé (Python).....	51
Chapitre VI : Résultats et discussion.....	52

VI. Résultats de la Classifications images.....	53
VI.1. Cas des Fruits.....	53
VI.1.1 Phase construction du model.....	54
VI.1.1.1 Configuration 01.....	55
VI.1.1.2 Configuration 02.....	56
VI.1.1.3 Configuration 03.....	57
VI.1.1.2.1 Configuration 01.....	60
VI.1.1.2.2 Configuration 02.....	60
VI.1.1.2.3 Configuration 03.....	61
VI.1.1.3.1 Configuration 01.....	64
VI.1.1.3.2 Configuration 02.....	64
VI.1.1.3.3 Configuration 03.....	65
VI.2. Cas de Feuille.....	67
VI.2.1. Phase construction du model.....	67
VI.2.1.1.1 Configuration 01.....	68
VI.2.1.1.2 Configuration 02.....	68
VI.2.1.1.3 Configuration 03.....	69
VI.2.1.2.1 Configuration 01.....	72
VI.2.1.2.2 Configuration 02.....	72
VI.2.1.2.3 configuration 03.....	72
VI.2.1.3.1 Configuration 01.....	75
VI.2.1.3.2 Configuration 02.....	75
VI.2.1.3.3 Configuration 03.....	75
V. Déployer reconnaissance d'objets YOLO.....	77
V.1. Résultats obtenus sur la reconnaissance de fruit.....	77
V.1.1 Batch d'Entraînement.....	77
V.1.2 Batch de Validation de prédiction.....	79
V.1.3 Matrice de confusion de confusion.....	80
V.1.3.1 Analyse des résultats.....	81
V.1.4.Evolution de diverses métriques de perte et de performance.....	81
V.1.4.1 Pertes d'entraînement (train loss)	82
V.2.5.1.2. Pertes de validation (validation loss)	82
Conclusion générale.....	84
Référence	86

Listes des Figures

Chapitre I : Présentation de la plante		
Figure I.1	Racines de piment (originale)	6
Figure I.2	Tige de piment (originale)	6
Figure I.3	Feuille de plante de piment (originale)	7
Figure I.4	Fleur de plante de piment	7
Figure I.5	Fruit de piment (originale)	8
Chapitre II : Méthodes et outils d'étude de la diversité génétique du piment		
Figure II.1	Techniques d'apprentissage automatique et apprentissage profond	17
Figure II.2	Facteurs clés pour choisir entre l'apprentissage profond et l'apprentissage automatique.	17
Figure II.3	Différence entre la classification des images et la détection des objets	19
Figure II.4	CNN architecture (El Sakka et al. 2024)	22
Figure II.5	Exemples des maladies des plantes de la base de données (Mecirdi, 2023)	23
Figure II.6	Détection de la Tache Bactérienne et des Parties Saines sur les Plants de Poivron (Mathew et Mahesh ,2022)	25
Figure II.7	Détection de maturité de fruit (cerise) (Hou et al. 2022)	26
Figure II.8	Utilisation de fond noir et naturel pour la prise des photos des feuilles de piment pour la classification variétale (Suwarningsih et al. 2022)	28
Figure II.9	Exemple des images utilisé (Khairul et al. 2019)	28
Figure II.10	Matrice de confusion (Khairul et al. 2019).	29
Figure II.11	Détection des images de variétés de laitue par utilisation de YOLO (Zhang et Daoliang ,2022).	30
Chapitre III : Matériel et méthodes		
Figure III.1	Localisation du site expérimental (originale)	32
Figure III. 2	Semences des populations de piment (originale)	33
Figure III. 3	Vue générale de la parcelle expérimentale (originale)	34
Figure III. 4	Plan de la serre (originale)	35
Figure III. 5	Semis en pépinière (originale)	35
Figure III. 6	Irrigation des plants en pépinière (originale)	35
Figure III. 7	Transplantation (originale)	37
Figure III. 8	Pucerons sur la feuille de piment (originale)	40
Figure III. 9	Dégâts de Noctuelle (originale)	40

Figure III. 10	Mouche blanche sur la feuille de piment (originale)	40
Figure III. 11	Exemple de quelques traitements utilisés (originale)	40
Figure III. 12	Palissage (originale)	41
Figure III. 13	Installation de paillage noir (originale)	42
Figure III. 14	Débris végétaux (originale)	42
Figure III. 15	Récolte (originale)	43
Figure III. 16	Exemples des images de notre base de données (originale)	44
Figure III. 17	Organisation de notre base de données (originale)	44
Figure III. 18	Entraînement de modèle DenseNet201 (originale)	47
Figure III. 19	Exemple de labélisation de fruit de piment (Labelling)	49
Figure III. 20	Entraînement de modèle YOLO (originale)	50
Figure III. 21	Schéma fonctionnel proposé (originale)	51
Chapitre VI : Résultats et discussion		
Figure VI. 1	Courbes d'évolutions de l'exactitude et de la perte d'apprentissage et de validation (a.confug01 , b.confug02 , c.confug03).	54
Figure VI. 2	Métriques (a.confug01 , b.confug02 , c.confug03).	59
Figure VI. 3	Matrice de confusion (a.confug01, b.confug02, c.confug03).	63
Figure VI. 4	Courbes d'évolutions de l'exactitude et de la perte d'apprentissage et de validation (a.confug01, b.confug02, c.confug03).	67
Figure VI. 5	Métriques (a.confug01, b.confug02, c.confug03).	71
Figure VI. 6	Matrices de confusion (a.confug01, b.confug02, c.confug03).	74
Figure VI. 7	Résultats de la reconnaissance d'objets utilisant le modèle YOLOv8s	77
Figure VI. 8	Notre base de données utilisée pour l'entraînement d'un modèle YOLOv8s	78
Figure VI. 9	Batch de validation pour l'évaluation des performances d'un modèle YOLOv8s	79
Figure VI. 10	Matrice de confusion	80
Figure VI. 11	Evolution de diverses métriques de perte et de performance au cours de l'entraînement du modèle YOLOv8s sur 400 epochès	81

Liste des Tableaux

Chapitre I : Présentation de la plante		
Tableau I.1	Stades de croissance phénologique du piment basés sur l'échelle BBCH (Andriessa Krause, Dotto et al. 2023).	5
Tableau I.2	Programme de fertilisation de piment (ITCMI, 2022).	10
Tableau I.3	Principales maladies, les symptômes qui touchent le piment (Fondio et al, 2009).	11
Tableau I.4	Principaux ravageurs qui touchent le piment.	11
Chapitre II : Méthodes et outils d'étude de la diversité génétique du piment		
Tableau II.1	Métriques d'évaluation d'un modèle.	
Chapitre III : Matériels et méthodes		
Tableau III.1	Codage de variétés étudiées.	33
Tableau III.2	Calendrier cultural.	36
Tableau III.3	Programme de Fertilisation.	38
Tableau III.4	Programme de traitement phytosanitaire.	39
Tableau III.5	Paramètres utilisés pour la classification des images de fruit (entraînement de modèle).	45
Tableau III.6	Paramètres utilisés pour la classification des images des feuilles (entraînement de modèle).	47
Tableau III.7	Répartition des données pour YOLO (Fruit).	49
Tableau III.8	Paramètres utilisé dans entraînement de modèle YOLOv8s.	50

Liste des Abréviations

ACP : Analyse en Composantes Principales.

Adam: Adaptive Moment Estimation.

BBCH: Biologische Bundesanstalt, Bundessortenamt und CHemische Industrie

CNN: Convolutional Neural Network.

Cls_loss: Classification loss.

DL: Deep Learning.

DenseNet: Densely Connected Convolutional Network.

GPU: Graphics Processing Unit.

FAO: Food and Agriculture Organization.

IA: Intelligence Artificielle.

IoU: Intersection over Union.

IPGRI: International Plant Genetic Resources Institute.

MAP50: Mean average precision.

MAP50-95: Mean Average Precision at Intersection over Union (IoU) thresholds ranging from 0.50 to 0.95.

Mg: Magnésium.

ML: Machine Learning.

P: Précision (Precision).

R: Recall.

RGB: Red, Green, Blue.

SGD: Stochastic Gradient Descent.

Val/box_loss: Validation box loss.

Val/df1_loss: Validation detection/false loss.

YOLO: You Only Look Once.

YOLO v8 : YOLO Version 8.

INTRODUCTION GENERALE

Le piment (*Capsicum annum* L.) fait partie des cultures maraichères les plus répandues à travers le monde, avec une importance croissante. Selon la FAO, la production mondiale s'élève à 19 millions de tonnes (Dhen et al. 2022).

Les variétés locales de piment sont des ressources génétiques précieuses car elles contiennent des pools génétiques distincts et agissent comme sources vitales de variété génétique pour la sélection et la préservation de la biodiversité (Bosland et al. 2012). D'autre part, le piment représente un élément essentiel de la nourriture de la population algérienne qui le consomme sous différentes formes, telles que la consommation fraîche, le mélange sec et la pâte

En Algérie, au cours des années et notamment après l'introduction de la plasticulture, les agriculteurs sont passés de la production des variétés locales de piments aux variétés hybrides afin de répondre aux besoins du marché conduisant à une érosion génétique sévère. Bien que les variétés locales de piment fassent partie du patrimoine génétique, elles demeurent parmi les plus menacées et très peu étudiées. Ces variétés portent toutes le même nom qui sont « piment arabe » ou « felfel arbi » pourtant des études ont montré l'existence de variation importante au sein de ces variétés à travers une étude de caractérisation morphologique moyennant l'analyse multivariée (Bedjaoui et al. 2022).

Étant donné l'ampleur de la diversité génétique exprimée par la divergence des caractéristiques, il subsiste une grande ressemblance phénotypique entre les populations locales de piment ce qui rend difficile de les distinguer par observation visuelle. Un besoin est donc apparu de concevoir des méthodes rapides et précises qui font appel à des instruments plus fiables permettant d'identifier et de reconnaître les variétés locales de cette espèce.

Parmi ces instruments, la vision par ordinateur, branche de l'intelligence artificielle qui permet aux systèmes d'extraire des informations pertinentes à partir d'images et de vidéos pour prendre des décisions ou fournir des recommandations (Ubbens et Stavness ,2017). Les réseaux de neurones convolutifs (CNN) ont démontré des performances exceptionnelles en matière d'image tâches de reconnaissance, telles que la détection d'objets. (Talaat et ZainEldin, 2023).

Dans des études récentes, les techniques d'apprentissage profond ont présenté de meilleures performances prédictives que les algorithmes de pointe dans de nombreux domaines, y compris la classification d'images (Krizhevsky et Hinton, 2012). Cet outil permet aux modèles informatiques composés de plusieurs couches de traitement d'apprendre des représentations de données à plusieurs niveaux (Bengio, 2009). Ces méthodes ont considérablement amélioré l'état

de l'art en matière de reconnaissance vocale, de reconnaissance visuelle d'objets et de détection d'objets. (Kelleher ,2019). D'autre part, l'algorithme You Look Once (YOLO) est l'un des algorithmes de détection d'objets basés sur les réseaux de neurones convolutifs (CNN) (Talaat et ZainEldin, 2023). La précision et la vitesse ont été améliorées avec la plus récente Version YOLO v8 (Goyal, 2023).

La reconnaissance variétale des plantes est une tâche essentielle en agriculture pour identifier différentes variétés de cultures et assurer une gestion précise et efficace des champs. L'apprentissage profond (en anglais : Deep Learning) offre des méthodes avancées pour cette tâche, grâce à ses capacités à traiter et analyser de grandes quantités de données visuelles complexes.

Notre étude est une collaboration scientifique qui s'inscrit dans le cadre des travaux de recherche l'intégration des nouvelles technologies dans le domaine agronomique, déjà entamée sur l'identification variétale du blé par l'approche d'apprentissage profond (Laabassi, 2021) et constitue une suite à la démarche d'identification des variétés locales de piment en Algérie soulevé pour la première fois par Bedjaoui et al. (2022). Dans cette optique, nous avons tracé notre objectif qui est de développer une approche de vision par ordinateur afin de reconnaître et d'identifier les populations locales de piment en utilisant la technique d'apprentissage profond et de classification se basant sur les images des feuilles et des fruits de piment.

Pour répondre à notre objectif, nous avons mené cette étude constituée de deux parties. La première partie est une étude bibliographique divisée en deux chapitres. Le premier chapitre est consacré à la présentation de piment et le deuxième à l'étude de la diversité génétique de piment. La partie expérimentale comporte deux chapitres, le premier concerne le matériel et méthodes utilisés durant notre expérimentation et le second l'essentiel des résultats que nous avons obtenus et leur discussion. Enfin nous présenterons une conclusion générale.

Partie bibliographique

CHAPITRE I

PRESENTATION DU PIMENT



I. 1 Généralités sur l'espèce

I.1.1 Genre capsicum

Le genre *Capsicum* compte environ 25 espèces différentes (Chambonnet et al. 1981). Ces plantes sont largement cultivées à travers le monde et sont parmi les légumes les plus consommés, étant notamment populaires en Afrique (Guillard ,1901). Le piment, appartenant au genre *Capsicum*, est en effet une plante herbacée annuelle ou vivace, appartient à la famille des Solanacées, qui est une famille de plantes à fleurs. Le *Capsicum annuum* est le plus cultivé dans le monde parmi les cinq espèces *Capsicum* domestiquées (*frutescens*, *annuum*, *baccatum*, *chinense* et *pubescens*) (Safa et al. 2022).

I.1.2. Origine et historique

Le genre *Capsicum* est issu d'Amérique centrale et d'Amérique du Sud, et le piment est issu du Nouveau Monde. Elle est populaire et intéressante depuis l'antiquité en raison de son avantage commercial. *Capsicum annuum* est la plus communément cultivée des cinq espèces de *Capsicum* domestiquées. Elle a une longue histoire de popularité et d'intérêt commercial, ayant été largement utilisée par différentes civilisations précolombiennes en Amérique centrale et du Sud (Guillard ,1901).

I.1.3. Systématique

Le piment (*Capsicum annum L.*), est une plante dicotylédone qui appartient à la famille des solanacées (Chambonnet, 1985).

Division : Maagnoliopyta.

Classe : Magnoliopsida

Ordre : Solanales

Famille : Solanacée

Genre : *Capsicum*

Espèce : *Capsicum annuum*

I.1.4. Ressources phylogénétiques

Le genre *Capsicum* compte 25 espèces qui sont réparties en fonction de leurs formes et de leurs utilisations du fruit. vingt espèces sont sauvages et possèdent des gènes de résistance aux

organismes nuisibles. Cinq autres espèces sont domestiquées, qui sont les plus couramment cultivées dans les régions du monde : *C. frutescens*, *C. annum*, *C. baccatum*, *C. pubescens* Ruiz & Pav., *C. chinense* Jacq (Meliani et Harche, 2020).

I.2 Présentation de la plante

I.2.1 Détermination des stades phénologiques à l'aide de l'échelle du piment BBCH

L'échelle BBCH (Biologische Bundesanstalt, Bundessortenamt und Chemische Industrie) est une méthode de codification largement utilisée pour déterminer les stades phénologiques des plantes, Cette échelle comprend généralement 10 étapes principales (0-9), elles-mêmes divisées en 10 stades de croissance secondaires (0-9) (Krause et al. 2023)

Tableau I.1: Stades de croissance phénologique du piment basés sur l'échelle BBCH .

Code BBCH	Description	Description
Stade principal de croissance 0		Germination
Stade principal de croissance 01		Développement des feuilles
Stade principal de croissance 02		Formation des pousses latérales
Stade principal de croissance 03		Début du développement des pousses
Stade principal de croissance 04		Développement des pousses des parties récoltables de la plante
Stade principal de croissance 05		Emergence de l'inflorescence
Stade principal de croissance 06		Floraison
Stade principal de croissance 07		Développement du fruit
Stade principal de croissance 08		Coloration ou maturation des fruits
Stade principal de croissance 09		Sénescence

(Krause et al. 2023).

I.2.2 Morphologie de la plante

Le piment est une plante herbacée annuelle qui peut atteindre différentes hauteurs en fonction de la variété et des conditions de croissance (Agbodan et al. 2020).

I.2.2.1. Appareil végétatif

a. Système racinaire

Les racines du piment (Figure I.1) sont généralement pivotantes avec des ramifications secondaires (Wang et al. 2019).



Figure I. 1 : Racines de piment (originale)

b. Tige

La tige du piment (Figure I.2) est généralement dressée, cylindrique et ramifiée, généralement verte et peut devenir ligneuse avec l'âge (Molot et al. 1982).



Figure I.2 : Tige de piment (originale)

c. Feuille

Les feuilles du piment sont généralement disposées de manière alternée le long de la tige, sont généralement lisses et de couleur verte (Meliani et Harche,2020) .




Figure I. 3 : Feuille de plante de piment (originale)

I.2.2 Appareil reproducteur

a. Fleurs

Les fleurs du piment sont généralement petites, axillaires et solitaires ou regroupées en petites inflorescences (Dumas et Pochard ,1974).



Figure I. 4 : Fleur de plante de piment (Dumas et Pochard 1974.)

b. Fruit

Fruits allongés, flexibles, coniques, globuleux à 3 ou 4 loges (lisses ou flexibles), sphériques ou plats côtelés. Ils sont de forme et de couleur très variées (à maturité toutefois, les colorations rouge ou jaune sont dominantes), ils peuvent contenir, en plus ou moins grande quantité de Capsaïcine, qui leur donne un goût pimenté. Ils contiennent également une quantité importante de vitamine C (Houimli et al. 2011).



Figure I. 5 : Fruit de piment (originale)

I.3 Présentation de la culture**I.3.1 Exigences de la culture**

Selon ITCMI (2022) les exigences de culture de piment sont :

a. Type de Sol : Le piment préfère les terres profondes, aérées, bien drainées et riches en humus. Les sols silico-argileux sont recommandés pour les cultures de primeur, tandis que les terres argilo-siliceuses conviennent aux cultures de saison.

b. Température : Cette plante est exigeante en chaleur et aime les climats tempérés. Les températures idéales sont de 20 à 30°C le jour et de 15 à 20°C la nuit.

b. Lumière : Le piment est une plante des jours longs et très exigeante en lumière pour son développement optimal.

d.PH du Sol : Le pH du sol optimal pour la culture du piment est de 6,5 à 7.

e. Salinité : Le piment est moyennement tolérant à la salinité, avec une plage recommandée de 1,92 à 3,2 g/l.

f. Humidité : Le sol doit maintenir une humidité de 80 à 85%, tandis que l'humidité de l'air optimale est de 60 à 70%.

I.3.2 Conduit de la culture

I.3.2.1 Préparation du sol

Un labour de 25 à 30 cm et passage à la herse et fraise rotative sont recommandés

I.3.2.2 Fumure de fond

La culture du piment nécessite une matière organique de l'ordre de 30 à 35 t/ha et une matière minérale de 180 à 200 unités de N/ha, 80 à 100 unités de P/ha et 200 à 250 unités de K/ha (ITCMI, 2018).

I.3.2.3 Semis et Plantation

Un semis en pépinière s'effectue vers la mi-Août ; et le repiquage est réalisé au début Octobre (Badache, 2015).

En plein champ période d'avril à mai

b. Distance

- **Entre Rangs :** Laissez une distance de 0,90 à 1 mètre entre les rangs.
- **Entre Plants :** Espacez les plants de 0,40 à 0,45 mètre.
- **Densité :** 20 000 à 25 000 plants / ha (ITCMI)

I.3.2.4 Travaux d'entretien

a. Tuteurage : permet d'éviter l'éclatement des branches en les maintenant par un fil de palissage.

b. Paillage : consiste à poser un film plastique noir permettant d'éliminer des mauvaises herbes, de réduire les pertes d'eau et d'obtenir des récoltes précoces ainsi que des rendements de meilleure qualité.

c. Aération : s'effectue tôt le matin pour renouveler l'air ambiant de la serre. Elle se pratique également dès que la température atteint 28°C.

d. Désherbage : le désherbage est très important car les piments sont très sensibles à la concurrence des mauvaises herbes (L'ITDAS).

e. Fertilisation : le piment est une culture qui a des exigences élevées en matière de fertilisation, voici le tableau montre programme de fertilisation de piment durant leur cycle :

Tableau I.2 : Programme de fertilisation de piment

Les apports	Quantité
1^{er} apport	40 unités de N avant floraison 30 unités de K
2^{ème} apport	40 unités de N nouaison 60 unités de K
3^{ème} apport	30 unités de N fructification 60 unités de K
4^{ème} apport	20 unités de N 60 unités de K après 1ère récolte

(ITCMI, 2022).

f. Irrigation

Selon ITDAS, La culture réclame des besoins de l'ordre de 7000 m³/ha afin de maintenir une humidité du sol régulière. Aussi, il est important de réduire les apports pendant la floraison évitant le développement végétatif excessif.

I.3.2.5 Protection phytosanitaire

Insecticide : Pucerons : Méthomyl ,Deltaméthrine ,Pyrimicarbe

Fongicide : Botrytis et Oïdium : Vinchlozoline ,exaconazole

I.3.2.6 Récolte :

Les périodes de la journée les plus favorables pour la récolte sont le matin de bonne heure ou le soir (ITIDAS).

I.3.3 Protection de la culture

I.3.3.1. Maladie

Le piment est particulièrement sensible aux maladies.

Le tableau I.3 indique les principales maladies, les symptômes qui touchent le piment.

Tableau I.3 : Principales maladies, les symptômes qui touchent le piment (Fondio et al, 2009).

Type de maladie	Maladie	Agent pathogène	Vecteur ou cause	Symptômes
Viroses	Mosaïque	<i>Cucumber Mosaic Virus (CMV)</i>	Pucerons	Décoloration, tâches et malformation des feuilles et des fruits Nanisme des plantes
	Panachure du piment	<i>Pepper Mottle Virus (PMV)</i>	Pucerons	Décoloration uniforme des feuilles
	Nécrose virale du piment	<i>Tomato Spotted Wilt Virus</i>	Thrips (<i>Thrips tabaci</i>)	Marbrure, décoloration et malformation des feuilles et fruits suivie de nécrose
Maladies fongiques	Alternariose	<i>Alternaria solani</i>	Semences non traitées aux fongicides	Taches marrons sur les fruits matures, puis nécrose des taches
	Fusariose	<i>Fusarium oxysporum</i>	Semences non traitées aux fongicides	Jaunissement du feuillage, puis flétrissement de la plante

(Fondio et al, 2009)

I.3.3.2 Ravageurs : le tableau suivant représente les principaux ravageurs qui touchent le piment :

Tableau I.4 : Principaux ravageurs du piment

Ravageurs	Symptômes
Noctuelle	Provoquent des perforations des folioles, trous sur fruits.
Pucerons	Crispation des feuilles Sécrétion de miellat puis fumagine. Vecteurs potentiels de virus.
Aleurodes	Présence de colonies à la face inférieure des feuilles Vecteurs potentiels de virus
Acarien	Déformation des feuilles

CHAPITRE II

METHODES ET OUTILS D'ETUDE DE LA DIVERSITE GENETIQUE DU PIMENT

II.1 Approche Conventionnelle (descripteurs IPGRI)

L'Institut international de recherche sur les ressources phylogénétiques (IPGRI) est une organisation scientifique internationale dédiée à la conservation et à l'utilisation des ressources phylogénétiques végétales (Bracho et al. 2018). Dans le cadre de cette mission, l'IPGRI collabore avec divers partenaires pour caractériser, évaluer et utiliser ces ressources de manière efficace (Maheswari, 2015).

'IPGRI' joue un rôle crucial dans la caractérisation des ressources phylogénétiques, y compris celles du piment (COSTA et al. 2019). La caractérisation morphologique implique l'identification et la description des traits physiques des plantes de piment, telles que la taille, la forme et la couleur des fruits, des feuilles et des fleurs (Silva, de Carvalho et al. 2013). Cette caractérisation fournit une base pour la classification et la comparaison des différentes variétés de piment (Silva et al. 2013).

L'IPGRI joue un rôle essentiel dans la caractérisation, l'évaluation et l'utilisation des ressources phylogénétiques de piment, en utilisant des approches morphologiques, biochimiques et moléculaires pour comprendre et exploiter la diversité génétique de cette culture importante.

II.1.1 Etude morphologique

Une étude morphologique consiste à examiner les caractéristiques physiques et externes d'une plante ou d'une espèce végétale. Dans le cas des piments, une étude morphologique impliquerait l'observation et la description des différentes parties de la plante, telles que les feuilles, les fleurs, les fruits et les tiges, ainsi que la mesure de divers paramètres quantitatifs tels que la taille, la forme, la couleur et la texture. Dans le monde, de nombreuses études ont été menées sur la morphologie du piment pour comprendre sa diversité et sa classification. Ces études comprennent la caractérisation des différentes formes, tailles, couleurs et autres caractéristiques morphologiques des fruits, des feuilles et des plantes de piment.

Une étude sur neuf variétés de piments cultivées dans la région du Haut-Sassandra en Côte d'Ivoire a permis de mettre en lumière des différences marquées dans leurs caractéristiques phénologiques et morphologique. Cette diversité observée souligne l'importance cruciale de caractériser ces ressources génétiques pour une utilisation optimale dans la sélection et l'amélioration des cultures de piments dans la région (Akaza et al. 2022).

En Algérie, les travaux sur la morphologie du piment sont également pertinents. Les chercheurs et les institutions agricoles ont mené des études pour identifier et documenter les variétés de

piment cultivées localement. Ces études incluent la description des caractéristiques morphologiques des différentes variétés de piment présentes dans différentes régions du pays.

A titre d'exemple nous citons l'étude de la variabilité des caractéristiques agro-morphologiques est importante pour l'amélioration des variétés et des programmes de sélection des plantes. Pour ce faire, 08 variétés locales de piment (*Capsicum annuum* L.) ont été recensées à travers les différentes wilayas d'Algérie (ChemlaL, 2018). Un autre travail sur la diversité agro-morphologique des accessions de la même espèce à l'aide de statistiques multivariées a été mené visant à réaliser une caractérisation agro-morphologique de 21 accessions. Une grande variation a été révélée parmi ces accessions collectées dans l'est et le sud de l'Algérie et qui ont été évaluées pour 24 critères morphologiques quantitatifs et 38 qualitatifs dans des conditions optimales sous serre dans la région de Biskra (Bedjaoui et al. 2022).

II.1.2 Etude biochimique

Une étude biochimique du piment implique l'analyse des composés chimiques présents dans la plante, en mettant généralement l'accent sur les fruits, car ils contiennent la majorité des composés actifs (Safa et al. 2022). Les principales classes de composés biochimiques d'intérêt dans les piments comprennent les capsaïcoides responsables de la saveur piquante, les caroténoïdes qui donnent la couleur, ainsi que d'autres composés comme les polyphénols, les vitamines et les minéraux (Michel et al. 2022).

Une étude sur la diversité biochimique : la capsaïcine, la dihydrocapsaïcine, le fer, le potassium, le magnésium, le sodium, le zinc, les flavonoïdes et les acides phénoliques présents dans une collection de piment provenant de diverses zones d'oasis en Tunisie (Gabès, Kbeli et Tozeur)(Safa et al. 2022). La caractérisation de ces éléments a été identifiée en utilisant la méthode HPLC et la spectrophotométrie d'absorption atomique. Une étude sur l'effet du stress salin sur deux variétés de poivron doux (*Capsicum annuum* L.), les analysé des paramètres morphologiques (nombre de feuilles, longueur de la tige et des racines), biochimiques (chlorophylle, proline, sucres solubles) et anatomiques sous différentes concentrations de NaCl comparées à un témoin. Les résultats montrent que le stress salin réduit les longueurs de tige et de racine ainsi que le nombre de feuilles, tandis qu'il augmente la proline et les sucres solubles. De plus, les coupes anatomiques révèlent une diminution de la taille des cellules parenchymateuses et du diamètre des vaisseaux de xylème sous les concentrations élevées de sel (Omara, 2019).

II.2 Approche non conventionnelle basée sur l'intelligence artificielle (IA)

L'approche non conventionnelle basée sur l'IA cherche à explorer de nouvelles frontières dans le domaine de l'intelligence artificielle, en repoussant les limites de ce qui est possible et en exploitant pleinement le potentiel des technologies émergentes pour résoudre des problèmes complexes.

II .2.1 Intelligence artificielle

L'Intelligence Artificielle (IA) est la science dont le but est de faire par une machine des tâches que l'homme accomplit en utilisant son intelligence. La terminologie d'Intelligence Artificielle est apparue en 1956 (Pastre, 2000).

Bien que l'IA suscite de plus en plus d'intérêt de la part du monde universitaire, de l'industrie et des institutions publiques, il n'y a pas de normes qui définissent précisément ce qu'est l'IA (Samoili et al. 2020). Plusieurs définitions désignent des machines qui agissent comme des êtres humains ou qui sont des machines, Aptes à réaliser des actions qui requièrent de l'intelligence (Ertel ,2018).

La science de l'Informatique se concentre sur le traitement de l'Information, l'IA se concentre sur tous les cas où ce traitement ne peut être réduit à une méthode simple, précise et détaillée (Fetzer ,1990). Un algorithme est une série de tâches organisées, clairement définies, qui peuvent être exécutées sur un ordinateur (Parada et Cyr ,2022).

II.2.1.1 Algorithme d'apprentissage automatique supervisé

Un algorithme d'apprentissage automatique supervisé classique est une méthode d'analyse de données qui implique la formation d'un modèle sur un ensemble de données étiquetées. Le modèle est entraîné à partir de paires d'entrées et de sorties connues, avec pour objectif d'apprendre une fonction qui mappe les entrées aux sorties. Cela implique souvent l'ajustement des paramètres du modèle pour minimiser une fonction de coût mesurant l'écart entre les prédictions et les sorties réelles (Matteis et al. 2022).

a. Classique (Machine Learning, ML)

L'apprentissage automatique (en anglais : Machine Learning, ML) est un domaine de l'intelligence artificielle qui se concentre sur la création de systèmes capables d'apprendre et de s'améliorer automatiquement à partir de l'expérience sans être explicitement programmés. Il utilise des algorithmes et des techniques pour permettre aux ordinateurs d'identifier des patterns

et des relations dans les données, et de faire des prédictions ou des décisions basées sur des analyses. L'apprentissage automatique a récemment suscité un intérêt. L'apprentissage automatique a récemment suscité un intérêt considérable en raison de sa capacité à prédire avec précision une grande variété de phénomènes complexes (Mahesh, 2020). Cependant, il y a une prise de conscience croissante que, au-delà des prédictions, les modèles de ML sont capables de produire des connaissances sur les relations entre les domaines contenus dans les données, souvent appelées interprétations. Ces interprétations ont trouvé des applications importantes, par exemple en médecine, agronomie, et bien d'autres domaines (Bell, 2022).

b. L'apprentissage profond (Deep Learning, DL)

L'apprentissage profond (en anglais : Deep Learning, DL) est une branche de l'intelligence artificielle qui se concentre sur la création et l'entraînement de réseaux neuronaux artificiels profonds, capables d'apprendre à partir de données non structurées ou semi-structurées. Ces réseaux de neurones sont composés de multiples couches, ce qui leur permet de comprendre et d'analyser des données complexes. En utilisant des algorithmes (Bengio et al. 2015).

Dans des études récentes, les techniques d'apprentissage profond ont présenté de meilleures performances prédictives que les algorithmes de pointe dans de nombreux domaines, y compris la classification d'images (Krizhevsky, Sutskever et Hinton, 2012). Le DL aborde le problème de la représentation des données en introduisant des représentations intermédiaires plus simples qui permettent de les combiner afin de construire des concepts complexes. Par conséquent, il n'est pas nécessaire d'appliquer de nombreuses techniques de prétraitement pour extraire des caractéristiques qui représentent les données d'image (Bengio, 2009).

Permet aux modèles informatiques composés de plusieurs couches de traitement d'apprendre des représentations de données à plusieurs niveaux. D'abstraction ces méthodes ont considérablement amélioré l'état de l'art en matière de reconnaissance vocale, de reconnaissance visuelle d'objets et de détection d'objets, et bien d'autres domaines tels que la découverte de médicaments et la génomique (Kelleher, 2019).

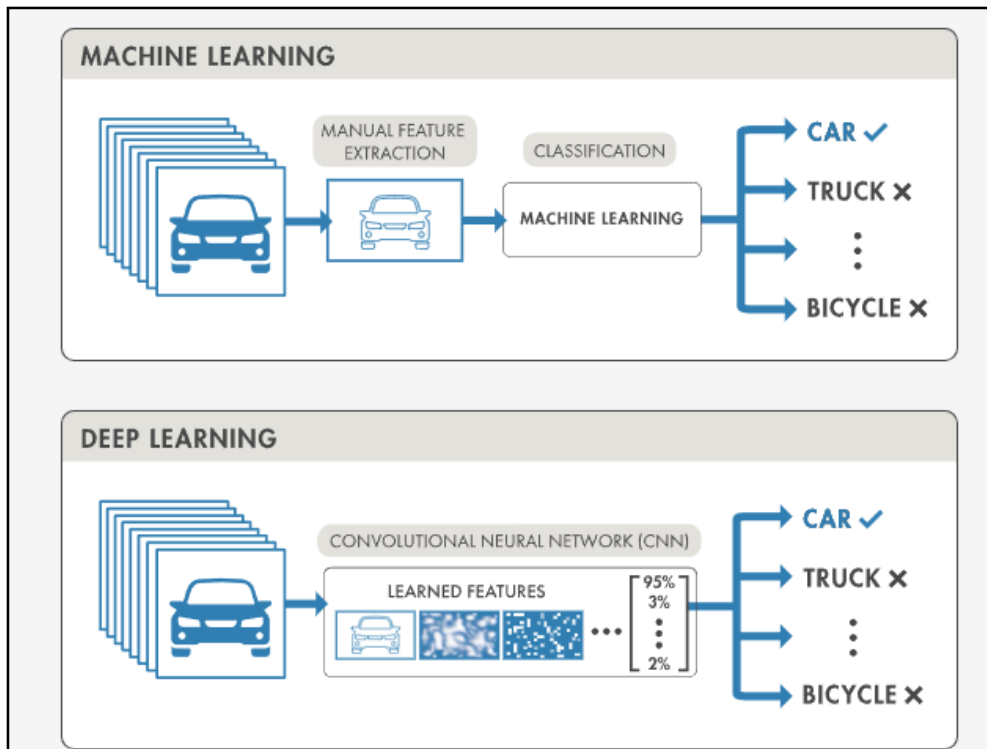


Figure II.1 : Techniques d'apprentissage automatique et apprentissage profond
(Necati Demir, 2022)

L'image (Figure II.3) compare deux approches de l'apprentissage automatique pour la classification d'images : l'apprentissage automatique classique et l'apprentissage profond. L'image illustre que l'apprentissage profond, en particulier les réseaux de neurones convolutifs, permet une automatisation complète du processus d'extraction et de classification des caractéristiques, surpassant souvent les méthodes d'apprentissage automatique classiques qui nécessitent une intervention humaine pour l'extraction des caractéristiques.

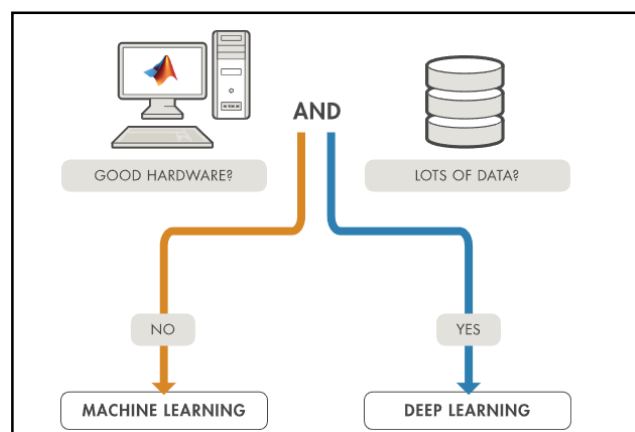


Figure II.2 : Facteurs clés pour choisir entre l'apprentissage profond et l'apprentissage automatique. (Source : <https://opencv.org/blog/computer-vision-and-image-processing/>)

II.2.1.2 Reconnaissance d'objet par la Vision par ordinateur

La vision par ordinateur, branche de l'intelligence artificielle, permet aux systèmes d'extraire des informations pertinentes à partir d'images et de vidéos pour prendre des décisions ou fournir des recommandations. Bien que similaire à la vision humaine, elle est plus rapide et utilise des caméras, des données et des algorithmes. La reconnaissance d'objets est une application de cette technologie, permettant aux machines de détecter, identifier et classer des objets dans des médias visuels. Cette discipline interdisciplinaire mêle l'informatique, l'apprentissage automatique et le traitement d'image pour interpréter le contenu visuel des médias numériques (Heraud et Monga 1995).

a. Classification des images

Le processus de classification d'images, complexe par nature, est influencé par divers éléments. La classification d'images se définit comme la tâche de catégoriser les images dans l'une des plusieurs classes prédéfinies. C'est un problème fondamental en vision par ordinateur, servant de base pour d'autres tâches telles que la localisation, la détection et la segmentation (Rawat et Wang, 2017).

En reconnaissance visuelle, la classification d'images est essentielle pour comprendre et classer une image dans son ensemble selon une étiquette précise. Contrairement à la détection d'objets, qui implique de classer et de localiser plusieurs objets dans une image, la classification d'images se concentre généralement sur les images contenant un seul objet, ce qui simplifie la tâche mais nécessite tout de même une analyse approfondie pour une classification précise. La récupération d'images est souvent utilisée lorsque la classification devient très détaillée ou à l'échelle de l'instance, ce qui nécessite également de rechercher des images similaires dans une base de données importante. Objets dans des images ou des vidéos. L'objectif est d'apprendre à un ordinateur à faire ce qui est naturel pour l'homme : acquérir un certain niveau de compréhension de ce que contient une image (Abdullahi et al. 2017).




Figure II.3 : Différence entre la classification des images et la détection des objets (<https://www.vroque.co/post/leaf-disease-detection-using-cnn-with-opencv>)

b. Détections d'objets

La reconnaissance d'objets est une technique de vision par ordinateur permettant d'identifier des La reconnaissance d'objets joue un rôle essentiel dans les véhicules autonomes, leur permettant de détecter les panneaux d'arrêt et de distinguer les piétons des lampadaires.

Elle est également précieuse dans divers domaines tels que le diagnostic de maladies en bio imagerie. (Horng et al. 2019). La reconnaissance d'objets est un résultat clé des algorithmes d'apprentissage profond et d'apprentissage automatique. Lorsque les humains regardent une photo ou regardent une vidéo, pouvons facilement repérer des personnes, des objets, des scènes et des détails visuels

II.2.1.3 Construction et évaluation des modèles

a. Séparation des données

Avant d'évaluer un modèle, les données sont généralement séparées en deux ensembles principaux (He et Li ,2020) :

- **Ensemble d'entraînement** : utilisé pour entraîner le modèle.
- **Ensemble de test** : utilisé pour évaluer la performance du modèle sur des données non vues.

Parfois, un ensemble de validation est également utilisé pour ajuster les hyper paramétrés du modèle avant l'évaluation finale.

b. Métriques d'évaluation : Le tableau représente les différentes métriques d'évaluations d'un modèle

Tableau II.1 : Métriques d'évaluation d'un modèle.

Métriques d'évaluation	Formule	Description
Exactitude (Accuracy)	$\frac{\text{Nombre total de prédictions}}{\text{Nombre de prédictions correctes}}$	Proportion de prédictions correctes parmi toutes les prédictions.
Précision (Precision)	$\frac{\text{Vrai Positif}}{\text{Vrai Positifs} + \text{faux Positifs}}$	Proportion des prédictions positives correctes parmi toutes les prédictions positives.
Rappel (Recall)	$\frac{\text{Vrai Positif}}{\text{Vrai Positifs} + \text{Faux négatifs}}$	Proportion des prédictions positives correctes parmi tous les cas réels positifs.
F1-Score	$2 \times \frac{\text{Précision} \times \text{Rappel}}{\text{Précision} + \text{Rappel}}$	Moyenne harmonique de la précision et du rappel.
Matrice de confusion	/	C'est un tableau récapitulatif des prédictions correctes et incorrectes par classe.

(Djouani, 2022).

c. Validation croisée (Cross-Validation)

Pour obtenir une évaluation plus robuste, la validation croisée est souvent utilisée. Le principe est de diviser les données en k sous-ensembles (folds) et de former et évaluer le modèle k fois, en utilisant chaque fois un sous-ensemble différent pour l'évaluation et les autres pour l'entraînement. La performance moyenne sur tous les folds est alors calculée (Massanes et Brankov 2017).

d. Analyse des courbes d'apprentissage

Les courbes d'apprentissage montrent la performance du modèle sur les ensembles d'entraînement et de validation en fonction de la taille des données d'entraînement. Elles aident

à identifier les problèmes de surapprentissage (overfitting) ou de sous-apprentissage (underfitting)(Jakubec et al. 2023).

e. Évaluation de la robustesse

Tester le modèle sur des données légèrement différentes ou sur des ensembles de test supplémentaires permet d'évaluer sa robustesse et sa capacité à généraliser.

II.2.1.4 Application des Réseau de neurones convolutifs (CNN) en agriculture

Les Réseaux de neurones convolutifs (En anglais Convolutional Neural Networks CNN) ont été pionniers par Yann Le Cun à la fin des années 1980. Initialement développés pour la classification d'images, ils ont depuis été adaptés à des tâches telles que la régression de séries temporelles (O'shea et Nash 2015). Les CNN sont devenus la méthode principale pour la classification d'images en raison de leur capacité à apprendre efficacement les caractéristiques et les classificateurs directement à partir des données. Ils ont également été étendus pour gérer des tâches plus complexes comme la détection d'objets et la segmentation d'images(Albawi et al. 2017). Dans ces cas, les CNN servent souvent de colonne vertébrale pré-entraînée pour des modèles plus complexes grâce à une technique appelée apprentissage par transfert, qui est particulièrement utile lorsque les données d'entraînement sont limitées (Yuan et al. 2024).

Un CNN se compose de trois couches principales : la couche de convolution, la couche de pooling et la couche entièrement connectée. La combinaison de ces couches permet de construire un modèle capable de reconnaître des objets et de classer des images. Plusieurs architectures de CNN ont été développées au fil des ans, telles que LeNet-5 (1998), AlexNet (2012), ZFNet (2013), GoogleNet (2014), VGGNet (2014) et ResNet (2015)(Briouya et al. 2024).

Les CNN sont particulièrement adaptés aux tâches de classification d'images en agriculture en raison de leur capacité à apprendre automatiquement des motifs et des caractéristiques hiérarchiques à partir d'images. Par exemple, dans l'agriculture, les CNN peuvent être utilisés pour identifier des maladies des plantes, classer des variétés de cultures, et détecter des parasites.

L'utilisation des CNN dans le domaine agricole permet une surveillance plus efficace et précise des cultures, aidant ainsi à optimiser les rendements et à réduire les pertes (El Sakka, et al. 2024).




Figure II.4 : CNN architecture (El Sakka et al. 2024)

a. Cas des Maladies

L'étape de classification est la plus importante de la détection des maladies des plantes à l'aide de la vision par ordinateur et du traitement d'image (Kumar et al. 2024). Compte tenu de son importance dans la détection des maladies, les performances de cette phase dépendent des étapes précédentes telles que l'acquisition des données, l'étape de prétraitement, la segmentation de la zone infectée et l'extraction et la sélection finales des caractéristiques. Dans les premiers travaux de recherche en agriculture intelligente, ils ont découvert des classifieurs classiques tels que les K-plus proches voisins et les classifieurs bayésiens (Kumar, et al. 2024).

De nombreux chercheurs utilisent des techniques de vision par ordinateur pour détecter des maladies à l'aide d'images de feuilles. Une étude diagnostique les maladies des plantes à l'aide de la méthode des réseaux neuronaux profonds (DNN) basée sur ces premiers symptômes. Plusieurs modèles de réseaux neuronaux convolutifs (CNN) tels qu'AlexNet, VGG16 et ResNet ont été utilisés, en plus d'un modèle personnalisé, pour identifier 17 classes avec 14 maladies. Construire une interface web pour le diagnostic de ces maladies en utilisant l'un de ces modèles (Mecirdi ,2023).

Les modèles CNN ont été entraînés sur un sous-ensemble de 24 377 images provenant de trois plantes (pomme de terre, tomate et raisin). cet ensemble de données fait partie d'un total de 54 306 images présentant 38 types de feuilles différentes, saines ou malades (**Figure II.6**), provenant de 14 espèces végétales (Mecirdi ,2023).




Figure II.5 : exemples des maladies des plantes de la base de données (Mecirdi, 2023)

c. Cas Évaluation de la qualité

L'évaluation de la qualité des fruits est un aspect crucial dans l'agriculture, permettant de réduire le gaspillage alimentaire et d'assurer que les consommateurs reçoivent des produits frais. L'application des réseaux de neurones (CNN) dans ce domaine a montré des résultats prometteurs pour la classification et l'évaluation des fruits (Darwish ,2020).

Les humains ont la capacité intrinsèque de déterminer si un fruit est frais. Cependant, il n'y a pas eu beaucoup d'intérêt dans la recherche en apprentissage profond visant à créer un système de classement des fruits basé sur des images numériques (Minh et Thinh ,2021). Une étude propose un modèle basé sur divers types de réseaux de neurones (CNN) pour évaluer rapidement et avec précision la qualité des fruits. Le modèle proposé a capturé efficacement des caractéristiques visuelles particulières, complexes et utiles pour la détection et la catégorisation (Minh et Thinh ,2021).

d. Cas de Maturité des fruits

L'évaluation de la maturité des fruits est essentielle pour garantir la qualité des produits agricoles et minimiser les pertes post-récolte. Les réseaux de neurones (CNN) offrent des capacités avancées pour l'analyse et la classification des images, ce qui les rend particulièrement adaptés pour cette tâche (Aherwadi et al. 2022).

Il est difficile de dénicher des données textuelles sur les niveaux de maturité en fonction du type de fruit, ce qui rend nécessaire la création d'un système de recherche utilisant l'image comme requête.

Dans le cadre de l'étude, il a été demandé de classer cinq catégories de fruits : carambole, mangue, melon, banane et tomate (Anatya, Mawardi et al. 2020). Dans chaque classe, on divise à nouveau les fruits en 52 sous-classes, qui incluent le type et le niveau de maturité, avec un total de 5030 images de données de formation. Le réseau neuronal convolutif (CNN) est une méthode employée pour classer et extraire les caractéristiques des images. Après avoir classé l'image, on procède à la recherche du fruit qui ressemble à l'image classée. Les 1294 images ont obtenu une précision de classification de 61 %. La valeur de précision de la récupération de 50 images est de 88,93 % (Anatya et al. 2020).

II.2.1.5 L'algorithme YOLO pour la détection d'objets en agriculture

L'algorithme YOLO (You Only Look Once) pour la détection d'objets en agriculture est une méthode populaire qui permet de détecter efficacement et en temps réel les objets d'intérêt dans des images agricoles (Zhao et al. 2024).

a. Maladie

L'algorithme YOLO (You Only Look Once) est un réseau neuronal convolutionnel de pointe pour la détection en temps réel d'objets dans des images (Mathew and Mahesh, 2022). En agriculture, il a été utilisé avec succès pour la détection des maladies des plantes grâce à ses capacités de traitement rapide et à sa précision. Yolo Représente un outil puissant pour la détection des maladies des plantes on application pourrait transformer la manière dont les agriculteurs surveillent et gèrent la santé de leurs plantations, aidant ainsi à améliorer les rendements et à réduire les pertes (Shetty et al. 2024).

Une étude pour Détecter la maladie de la tache bactérienne sur les plants de poivron à un stade précoce pour éviter la propagation et les pertes de rendement. Par Utilisation de YOLOv5, un algorithme de détection d'objets basé sur l'apprentissage profond, pour détecter la maladie de la tache bactérienne à partir des symptômes visibles sur les feuilles de poivron. Une Prélèvement aléatoire d'images de différentes parties du champ à l'aide d'un téléphone mobile. Le modèle suggéré est extrêmement bénéfique pour les responsables, car ils peuvent repérer les maladies des plantes dès leur apparition et ainsi prendre les mesures adéquates. actions visant à prévenir la diffusion de la maladie (Mathew et Mahesh, 2022).




Figure II.6 : Détection de la Tache Bactérienne et des Parties Saines sur les Plants de Poivron
(Mathew et Mahesh ,2022)

b. Qualité

Les agro-industries et les agriculteurs font face à une difficulté majeure en ce qui concerne la qualité. En outre, la séparation des graines après le battage nécessite un investissement considérable et des efforts considérables en utilisant des techniques traditionnelles telles que le tamisage, la cueillette manuelle, etc. Il est donc essentiel que la ségrégation des graines soit automatisée (Casado et al. 2020). Les méthodes d'apprentissage profond et d'apprentissage automatique ont été employées par les chercheurs pour la ségrégation autonome des graines sur le site de récolte en raison de leurs capacités à détecter, classer et reconnaître des formes d'objets (Zhang et Li,2022).

On observe un nombre restreint de travaux de recherche, qui se concentrent sur la catégorisation des semences de cultures cultivées dans le cadre de mélanges de cultures ainsi que des semences de différentes normes de qualité (Pérez-Porras et al. 2023).

Le système est construit à partir d'un ensemble de données qui inclut des images étiquetées de personnes en bonne santé et des graines de mil et de maïs malades. Il donne le meilleur rapport 99% de précision et de rappel. Le fait que le système soit efficace pour différencier les graines de mil et de maïs peut changer la donne dans l'industrie alimentaire (Kundu et al. 2021).

c. Maturité

La détection rapide, précise et non destructive de la maturité des cerises douces à grande échelle est cruciale pour déterminer la période optimale de récolte et pour un classement précis par maturité (Hou et al. 2022). Une étude sur un algorithme amélioré de détection de cibles basé sur YOLO v7, pour détecter rapidement et précisément les catégories de maturité des cerises douces dans des environnements complexes (Li et al. 2022). Ils ont collecté 2400 images haute résolution de cerises immatures, semi-mûres et mûres dans un verger. La méthode proposée dans cet article peut efficacement gérer des arrière-plans complexes tels que le chevauchement des fruits et l'occlusion par les branches et les feuilles, offrant ainsi une base de données et une référence technique pour d'autres problèmes similaires de détection de cibles (Li et al. 2022).




Figure II.7 : Détection de maturité de fruit (cerise)(Hou et al. 2022)

II.2.1.5.1 Métriques de détection d'objets (YOLO)

Les mesures de performance sont des outils clés pour évaluer la précision et l'efficacité des modèles de détection d'objets (Glenn, Munawar, Vina 2023)

a. Intersection sur Union (IoU) : L'IoU est une mesure qui quantifie le chevauchement entre une boîte de délimitation prédite et une boîte de délimitation de vérité terrain. Elle joue un rôle fondamental dans l'évaluation de la précision de la localisation des objets.

b. Précision moyenne (AP) : AP calcule la surface sous la courbe de précision-rappel, fournissant une valeur unique qui englobe les performances de précision et de rappel du modèle.

c. Précision moyenne (mAP) : mAP étend le concept de PA en calculant les valeurs moyennes de PA sur plusieurs classes d'objets. Cette méthode est utile dans les scénarios de détection d'objets multi-classes pour fournir une évaluation complète des performances du modèle.

d.mAP50-95 : La moyenne des précisions moyennes calculées à des seuils IoU variables, allant de 0,50 à 0,95. Elle offre une vue d'ensemble de la performance du modèle à travers différents niveaux de difficulté de détection.

e. Précision et rappel : La précision quantifie la proportion de vrais positifs parmi toutes les prédictions positives, évaluant la capacité du modèle à éviter les faux positifs. D'autre part, le rappel calcule la proportion de vrais positifs parmi tous les positifs réels, mesurant ainsi la capacité du modèle à détecter toutes les instances d'une classe.

f. Score F1 : Le score F1 est la moyenne harmonique de la précision et du rappel, fournissant une évaluation équilibrée des performances d'un modèle tout en tenant compte des faux positifs et des faux négatifs

II.2.1.6 Étude de cas pour la reconnaissance variétale

La reconnaissance variétale des plantes est une tâche essentielle en agriculture pour identifier différentes variétés de cultures et assurer une gestion précise et efficace des champs. L'apprentissage profond (Deep Learning) offre des méthodes avancées pour cette tâche, grâce à ses capacités à traiter et analyser de grandes quantités de données visuelles complexes.

a. Classification d'images CNN

La reconnaissance des variétés de piment de haute qualité, essentielle pour les tests et la certification des semences, se fait actuellement manuellement par des experts inspectant les feuilles tous les un à deux mois (Sabzi et al. 2020). Une méthode automatique utilisant l'apprentissage profond pourrait améliorer ce processus. Une étude évalue les performances de modèles CNN (AlexNet, VGG16, Inception-v3 et DenseNet-121) pour classer les variétés de piment à partir d'images de feuilles âgées de 10 jours. Ils ont travaillé avec 12 classes de feuilles de piment. Les précisions obtenues vont de 70,18 % à 78,37 %, DenseNet-121 ayant les meilleurs résultats avec une précision de 78,37 % .(Suwarningsih et al. 2022).



Figure II.8 : Utilisation de fond noir et naturel pour la prise des photos des feuilles de piment pour la classification variétale (Suwarningsih et al. 2022)

L'utilisation du réseau neuronal YOLO pour la classification et la reconnaissance des feuilles des plantes du Bangladesh, Grâce à l'emploi de réseaux neuronaux convolutifs profonds (CNN), les tâches de classification et de détection ont été réussies. Dans cette étude, on suggère d'utiliser le modèle YOLOv2 en tant que classificateur, équipé d'un ensemble de données de feuilles, afin de repérer et localiser les feuilles. L'utilisation de cette méthode d'apprentissage par transfert a donné lieu à une précision de classification d'environ 96 %, tout en garantissant une localisation précise des feuilles. Les conclusions sont encourageantes pour les botanistes et les analystes de plantes médicinales (Khairul et al. 2019).



Figure II.9 : Exemple des images utilisé (Khairul et al. 2019)

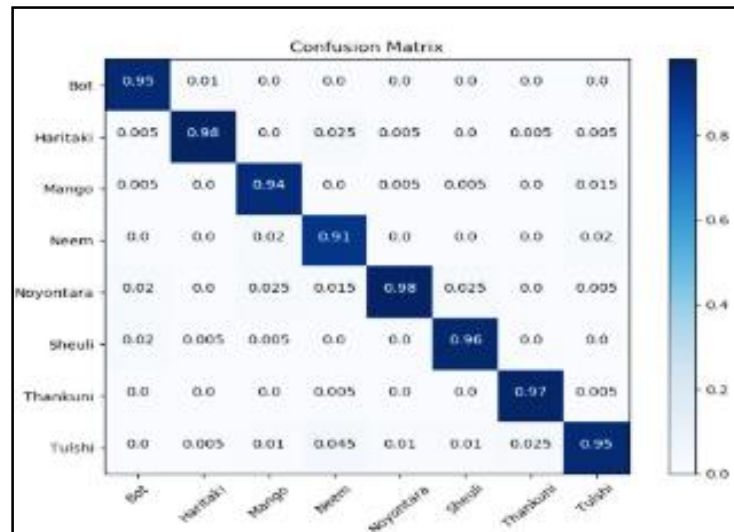


Figure II.10 : Matrice de confusion (Khairul et al. 2019).

c. Détection d'objets par YOLO

L'identification précise des variétés de cultures est cruciale pour l'agriculture intelligente, influençant la gestion des différences de cultures et les opérations automatisées dans des scénarios de plantation tels que les serres (Sozzi et al. 2022).

Une étude se concentre sur cinq variétés de laitue cultivées en serre et établit un modèle de classification des variétés à différents stades de croissance.

Élaboré un modèle de détection Par utilisation de Yolo. Cette méthode a été utilisée pour modéliser et analyser la classification des variétés de laitue au stade SP, obtenant des résultats excellents avec des précisions de 95,961 % (Val-acc), 93,452 % (Test-acc), 96,059 % (Recall), 96,014 % (Precision), et 96,039 % (F1-score). Les résultats démontrent que la méthode proposée est prometteuse pour l'identification précise des variétés au stade précoce de croissance des cultures (Zhang et Daoliang 2022).

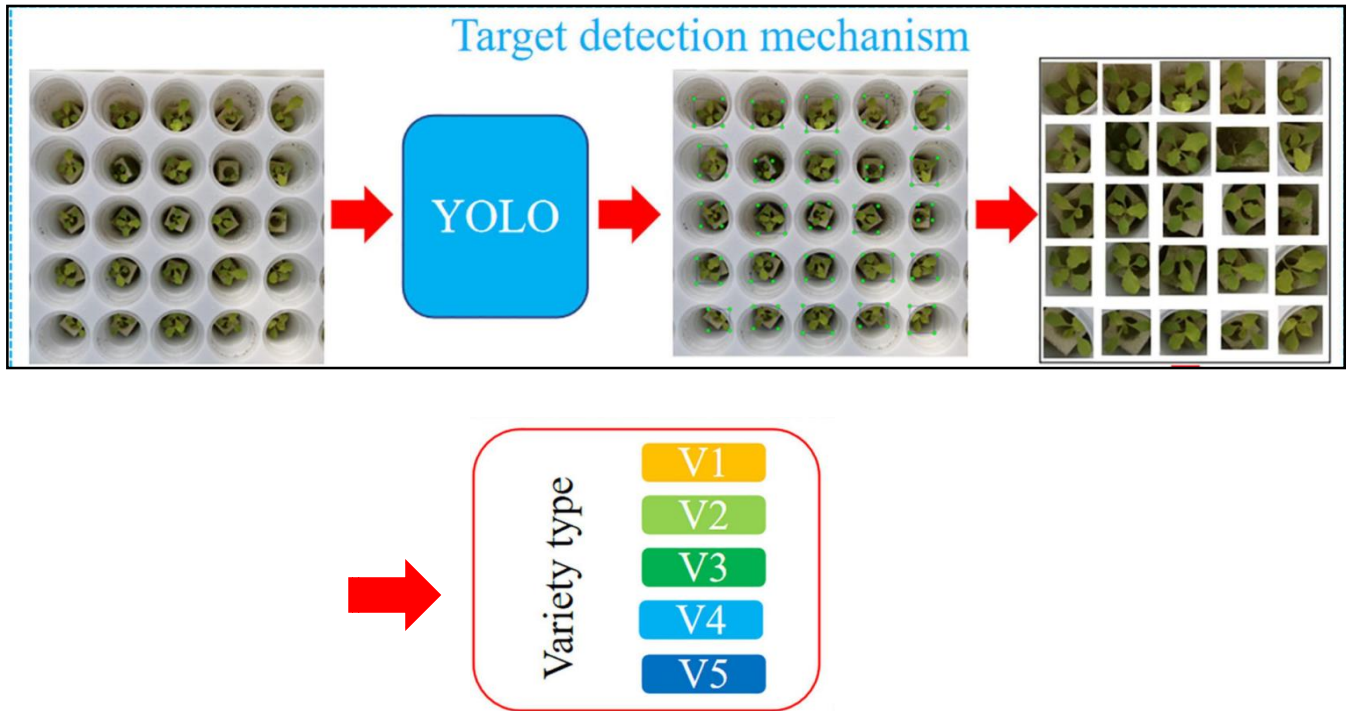


Figure II.11 : Détection des images de variétés de laitue par utilisation de YOLO (Zhang et Daoliang ,2022).

Partie expérimentale

CHAPITRE III

MATERIELS ET METHODES

Dans cette partie nous exposons le matériel utilisé dans notre expérimentation ainsi que la méthodologie suivie pour la collecte et la préparation des données et enfin l'expérimentation. Nous avons réalisé deux expérimentations, la première est une classification des images des feuilles et fruits de piment et une deuxième expérimentation est la détection des objets par l'utilisation de YOLO v8.

III.1. Site d'expérimentation

La zone où l'expérience a été menée est la région d'El-Hagf dans la commune d'Ain Naga, le long de la route nationale numéro 83, entre la wilaya de Biskra et la wilaya de Khenchela, passant par la commune de Zeribet El Oued. Le climat est aride, Le sol de la parcelle d'expérimentation est de texture argilo-sableux représentés par la faible teneur en matière organique.



(a)

(b)

Figure III. 1 (a) et (b) Localisation du site expérimental (originale)

III.2. Matériel végétal

Après avoir effectué des prospections dans les régions identifiées comme présentant la plus grande diversité de piment, nous avons entrepris de collecter directement auprès des agriculteurs des échantillons de graines provenant de 11 populations de piment cultivées localement (TOUGGOURT, EL OUED, OULED DJELAL, BATNA et BISKRA, ainsi que la variété hybride ATID).

Nous sommes convaincus que ces données constitueront une base solide pour notre analyse de la diversité génétique et des utilisations du piment dans la région étudiée.

Tableau III.1 : Codage de variétés étudiées

Codage	Variété	Région
V 01	Baage	EL OUAD
V02	Tolga	BISKRA
V03	Zeribet el oude	BISKRA
V04	Tougert	TOUGERT
V05	Mirza	BISKRA
V06	Barika	BATNA
V07	Ouled djalale	OLDJ
V08	Lioua	BISKRA
V09	Magren	EL OUAD
V10	ATID (Hybride)	Importée
V11	Lizerge	EL OUAD
V12	Sidi OUANE	EL OUAD

**Figure III.2** : Semences des populations de piment (originale)

III.3 Dispositif expérimental

Notre essai comporte 5 blocs, dans chaque bloc nous avons 11 populations et une Variété hybride réparties sur 6 lignes, dans chacune ligne 10 populations.



Figure III.3 : Vue générale de la parcelle expérimentale (originale)

III.4.1. Caractéristiques du dispositif expérimental

III.4.1.1 Serre

- A une superficie de 400 mètres carrés (8×50) divisée en 9 rangées
- Nous avons planté dans 6 rangées 90 cm entre eu
- Il se compose de 5 blocs, chaque bloc mesure 8 mètres de long, avec un espace de 1,5 m entre chaque bloc.
- Chaque rangée se compose de 10 variétés, avec un espacement de 40 cm entre chaque plante.
- Nous laissons 2 m de chaque côté des portes avant de commencer les mesures.

	L1	L2	L3	L4	L5	L6
BLOC 1	ATID	V11	V6	V1	ATID	V5
	V3	V4	V12	V7	V2	V9
BLOC 2	V4	V3	V5	ATID	V7	V11
	V11	V1	V9	V12	ATID	V3
BLOC 3	V1	V12	V2	V9	V4	V7
	V7	V5	V3	V6	V11	ATID
BLOC 4	V9	V8	V4	V5	V1	V12
	V6	V2	V7	V11	ATID	V3
BLOC 5	V2	ATID	ATID	V3	V5	V4
	V12	V7	V11	V8	V9	V1

Figure III.4 : Dispositif expérimental

III.5. Conduite culturale

III.5.1. Pépinière

Le 15 août, dans une serre semi contrôlée de la région de Mziraa, nous avons installé notre pépinière. Notre tâche consiste à remplir tous les pots de semis, chacun équipé de 105 trous. Ensuite, nous plantons soigneusement un grain de piment dans chaque trou de ces pots. Chaque jour, nous prenons le temps d'arroser méticuleusement les pots de semis pour assurer leur croissance optimale.



Figure III.5 : Semis dans les plaques alvéole (originale).




Figure III.6 : irrigation dans la pépinière (originale).

III.5.2. Calendrier cultural

Les différents travaux effectués au cours de notre expérimentation ont été notés dans le tableau suivant :

Tableau III .2 : Calendrier cultural

Date	Techniques appliquées
15 /08 /2023	Labour du terrain et semis de la semence dans la pépinière
02 /10 /2023	Nivellement du terrain, traçage des lignes de semis
04 /10 /2023	Ajouter de fumier organique et de l'engrais de fond 12 q (Fumier ovin et poulet)
05 /10 /2023	Mélangez le sol avec du fu Figure III. 6 : Irrigation dans la pépinière (originale).
10 /10/2023	Installation du système d'irrigation (goute a goutte).
11 ; 12 /10/2023	Irriguez le sol avant de la couverture la serre.
13/ 10 /2023	Couverture de la serre.
14 /10 /2023	Traçage le plan de plantation.
15 /10 /2023	Transplantation.
30/10/2023	Engrais de démarrage
05/11/2023	Traitement phytosanitaire
07/11/2023	Fertilisation
08 /11 /2023	Désherbage.
10/11/2023	Palissage
28 /11 /2023	Désherbage.
05/01/2024	Installation de paillage
02/02/2024	La taille
16/02/2024	1 ère récolte
28/03/2024	2 -ème récolte
21/05/2024	3 -ème récolte

III .6. Mise en place de la culture

III .6.1. Pré irrigation

Un pré irrigation a été réalisé le jour avant du semis, dont le but est d'ameublir le sol afin de faciliter la mise en culture.

III .6.2. Transplantation

La transplantation des plantules de piment été réalisée manuellement le 15/10/2014, après l'installation du système d'irrigation.



Figure III.7 : Transplantation (originale)

III .6.3 Travaux d'entretien de la culture

Tout au long du cycle de culture, différents travaux d'entretien ont été réalisés dans le but de maintenir la culture en bon état. Ces opérations comprennent : l'irrigation, la fertigation, les traitements phytosanitaires, le paillage, le palissage, la taille et l'aération de serre.

III .6.3.1 Irrigation

L'irrigation a été effectuée à l'aide d'un système de goutte à goutte, en fonction des conditions Pédoclimatiques et des besoins de la plante à différents stades phénologiques.

III .6.3.2 Fertigation

Le piment, une plante à croissance rapide, requiert des niveaux élevés d'éléments fertilisants, comme toutes les plantes de la famille des Solanacées. Nous avons choisi d'assurer sa nutrition en utilisant un système de fertigation via un système venturi, administrant les nutriments de manière régulière, en moyenne toutes les deux semaines.

Tableau III. 3 : Notre Programme de Fertilisation

Apports	Epoques	Quantité	Type d'engrais
1-er apport	Avant la transplantation	2,5 kg	Engrais de fond (MAP -00- 61)
2 -ème apport	Stade 7 feuilles	150 g.	Matière organique (humus star)
3 -ème apport	Avant floraison	50 g + 100 g +200 +100g.	Engrais de démarrage (mg, urée, potasse, MAP)
4 -ème apport	Stade de floraison	100 g + 170 g +400g +200g + 30 g.	Engrais de couverture (mg,urée, potasse, MAP, Oligoélément)
5 -ème apport	Nouaison	100 g + 170 g +400g +200g + 50 g.	Engrais de couverture (mg,urée, potasse, MAP, Oligo élément)
6 -ème apport	Grossissement de fruit	100 g + 170 g +400g +200 g + 50 g.	Engrais de couverture (mg, urée, potasse, MAP, Oligo élément)
7eme apport	Maturation de fruit	200 g	Calcium

III .6.3.3 Traitement phytosanitaire

Pendant le cycle de culture, divers traitements insecticides et fongicides ont été appliqués pour prévenir, contrôler ou éliminer les organismes nuisibles, garantissant ainsi la santé des cultures et la qualité des récoltes.

Tableau III .4 : Programme des traitements phytosanitaires

Ennemi de culture	Nom commerciale	La date d'application	Intervalle d'application	Préventif /curatif	Mode d'application
Ver de terre	Alpha_side	20 /10/2023	Une seule fois	Préventif	Avec irrigation
Acarien	Vertimac Apolo Acarole	25/10/2023	Chaque semaine/15 j	Curatif	Pulvérisateur
Puceron	Parkinze	15/12/2023	Chaque 15 jours	Curatif	Pulvérisateur
Noctuelle (<i>spodoptera littoralis</i>)	Avent	19/11/2023	2 fois	Curatif	Pulvérisateur
Mouche blanche	Bioact 1 Bioact 2	/	Chaque 15 jours	Préventif	Pulvérisateur

Les images ci-dessous illustrent quelques exemples des diverses attaques subies pendant le cycle végétatif de la culture étudiée :



Figure III .8 : Puceron sur la feuille de piment (originale, auteur)



Figure III .9 : Dégâts de Noctuelle (*spodoptera littoralis*) (originale, auteur)



Figure III .10 : La mouche blanche sur la feuille de piment (originale, auteur)



Figure III .11 : Exemple de certains traitements utilisés (originale)

III .6.3.4 Aération de la serre

L'aération de la serre se fait chaque jour tôt le matin en fonction des conditions climatiques en ouvrant les portes, afin de renouveler l'air, de réduire la température et l'humidité, surtout pendant les périodes chaudes (dans des conditions des hautes températures).

III .6.3.5 Désherbage

Les mauvaises herbes sont arrachées à la main entre les rangs pour prévenir les maladies et la compétition qui résulte de leur présence, en plus de leur concurrence pour l'eau et les éléments nutritifs.

III .6.3.6 Palissage

Le palissage pour le piment vise à soutenir la croissance des plantes, à protéger les fruits, à faciliter la récolte et à optimiser l'exposition à la lumière pour une production optimale.



Figure III .12 : Palissage (originale)

II.6.3.7 Paillage

Le paillage plastique dans les serres aide à créer un environnement favorable à la croissance des plantes en contrôlant les mauvaises herbes, en conservant l'humidité du sol, en régulant la température et en réduisant l'érosion du sol. On a installé le paillage début Janvier.



Figure III .13 : Installation de paillage noir (originale)

III .6.3.8 Taille

La taille sur le piment est une pratique importante pour encourager une croissance saine, augmenter la production de fruits et prévenir les maladies, tout en contrôlant la forme et la taille de la plante.



Figure III .14 : Les débris végétaux
(après la taille) (originale)

III.6.3.9 Récolte

La récolte est réalisée à la main lorsque le fruit atteint une taille bien déterminée et présente une peau lisse (on a fait 3 récoltes).



Figure III .15 : Piments récoltés (originale)

III .7 La Création de base des données

La création de bases de données est l'une des tâches les plus importantes dans l'apprentissage automatique car la qualité des données ont un impact direct sur la performance et la précision des modèles. Une base de données bien conçue et bien structurée permet de former des modèles plus robustes et fiables, facilitant ainsi des prédictions et des analyses plus précises.

III. 7.1 Collecte de données

Rassemblez des images de différentes parties de plantes par téléphone portable (iPhone) (feuilles, fruits) à différents stades de croissance pour assurer une variété suffisante pour une classification précise des populations. Les images ont été prises sur un fond noir pour améliorer le contraste et la facilité de détection des objets.

La capture des photos dans notre expérimentation est effectuée de manière aléatoire, et nous nous efforçons de recueillir autant d'informations que possible concernant les images des feuilles et des fruits et a à différents stades de croissance

Notre base de données regroupe 6074 images des différentes parties de la plante (feuille et fruit), incluant 3510 images de fruits (9 classes correspondant à 9 variétés) et 2564 images de

feuilles (12 classes correspondant à 12 variétés). Les images sont en format RGB et de taille 1:1 (carrée).



Figure III .16 : Exemples des images de notre base de données (originale)

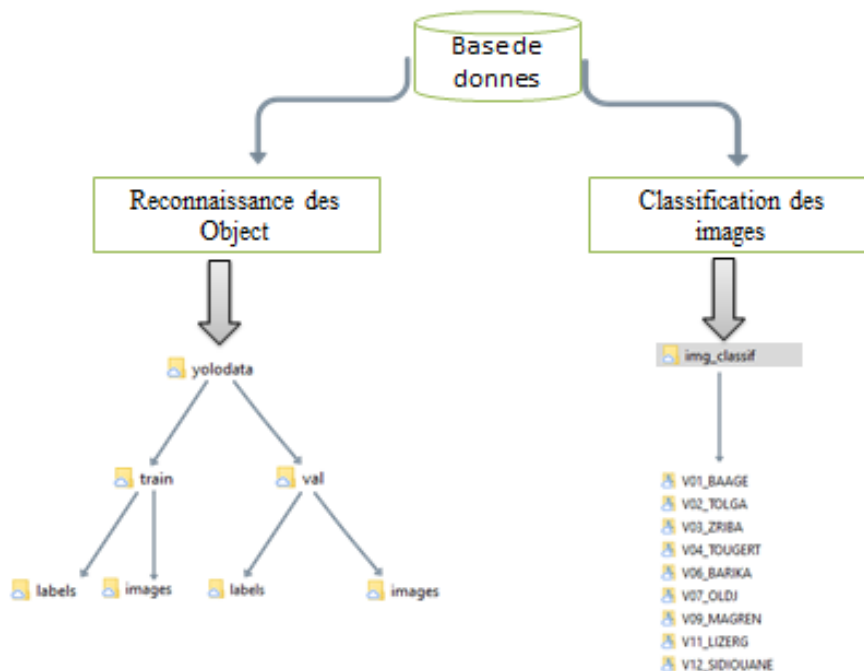


Figure III. 17 : Organisation de notre base de données (originale)

Les images collectées ont été stockées dans le cloud sur un compte Google Drive. Des dossiers spécifiques ont été créés pour organiser les données de manière à faciliter le processus de classification et de détection et après effectuer prétraitement et le nettoyage des données.

III. 7.2. Classification d'images

Nous avons utilisé le modèle DenseNet201, une architecture de réseau neuronal convolutif (CNN), qui fait partie de la famille des réseaux DenseNets. Pour obtenir les meilleurs résultats, diverses configurations et paramètres ont été explorés (Tableau III.1), (Tableau III.), tirés de la littérature existante sur des travaux similaires, avec une distribution des données comme suit : 80% entraînement, 10% validation, 10% test (split folder) pour obtenir les meilleurs résultats. L'objectif est de classer les populations de piment en se basant sur deux parties de la plante : la feuille et le fruit.

III. 7.2.1 Paramètres utilisés

Tableau III. 5 : Paramètres utilisés pour la classification des images de fruit (entraînement de modèle).

Configurations	Config 01	Config 02	Config 03
Nombre d'époques (epochs)	40	30	40
Nom de l'optimiseur (optimizer)	"SGD"	"SGD"	"Adam"
Taux d'apprentissage (Learning rate)	0.001	0.001	0.0001
Patience	20	20	20
Taille du lot (batch size)	64	32	64
Exactitude (Accuracy)	85%	93%	95%

a.Nombre d'époques

Le nombre d'époques correspond au nombre de fois où l'ensemble des données d'entraînement est affichée sur le réseau pendant l'entraînement (Djouani,2022).

b. Optimiseur Adam

Adam, également connu sous le nom d'estimation adaptative du moment, est un algorithme d'optimisation qui peut être employé dans le domaine de l'apprentissage profond afin de mettre à jour les poids des réseaux en fonction des données d'apprentissage (Djouani, 2022).

c. Optimiseur SGD (Stochastic Gradient Descent)

SGD est une méthode d'optimisation itérative qui ajuste les paramètres du modèle pour minimiser une fonction de perte en utilisant des mises à jour basées sur des échantillons ou petits lots d'échantillons. Contrairement à la descente de gradient traditionnelle, elle ne nécessite pas l'ensemble complet des données pour chaque mise à jour, ce qui la rend plus efficace pour les grands ensembles de données.

d. Taux d'apprentissage (Learning rate)

Le taux d'apprentissage définit la rapidité avec laquelle un réseau met à jour ses paramètres.

e. Taille du lot (Batch size)

La taille du mini-lot correspond au nombre de sous-échantillons transmis au réseau, après quoi la mise à jour des paramètres a lieu (Radhakrishnan, 2017)

f. Patience

Patience est le nombre d'itérations ou d'époques pendant lesquelles l'algorithme continue de s'entraîner sans amélioration significative de la performance du modèle sur les données de validation avant d'arrêter prématurément l'entraînement pour éviter le sur-apprentissage (overfitting).

- ***Sur-apprentissage (Overfitting)***

Dans le cas du sur-apprentissage, le modèle CNN apprend par cœur les données et fonctionne donc bien sur les données d'entraînement. Mais il effectue de mauvaises prédictions sur les données de validation, car il ne sait pas généraliser à des données inconnues.

- ***Sous-apprentissage (Underfitting)***

En sous-apprentissage, le modèle CNN n'arrive pas à déduire des informations de l'ensemble de données et n'apprend donc pas assez. Il fait de mauvaises prédictions sur les données d'entraînement car il n'arrive pas à capter la relation entre ces données et leurs labels (Djouani, 2022).

III. 7.2.2 Paramètres utilisés

Tableau III. 6 : Paramètres utilisés pour la classification des images des feuilles (entraînement de modèle).

Configurations	Config 01	Config 01	Config 01
Nombre d'époques (epochs)	40	35	40
Nom de l'optimiseur (optimizer)	"SGD"	"Adam"	"Adam"
Taux d'apprentissage (Learning rate)	0.001	0.0001	0.00007
Patience	20	10	10
Taille du lot (batch size)	64	64	128
Exactitude (Accuracy)	80%	86%	89%

III. 7.2.3 Entraînement de modèle DenseNet201

Le modèle DenseNet201 a été entraîné sur des images des différentes parties de la plante (fruit et feuille) en utilisant trois configurations différentes.

```

Epoch 2: val_loss improved from 2.34170 to 2.30589, saving model to /kaggle/working/results/DenseNet201_SGD_ep2_valloss2.306.keras
31/31 ————— 25s 448ms/step - accuracy: 0.1875 - loss: 2.3482 - val_accuracy: 0.1639 - val_loss: 2.3059
Epoch 3/40
31/31 ————— 0s 13s/step - accuracy: 0.2590 - loss: 2.2313
Epoch 3: val_loss improved from 2.30589 to 2.13286, saving model to /kaggle/working/results/DenseNet201_SGD_ep3_valloss2.133.keras
31/31 ————— 513s 15s/step - accuracy: 0.2602 - loss: 2.2297 - val_accuracy: 0.3490 - val_loss: 2.1329
Epoch 4/40
1/31 ————— 5:29 11s/step - accuracy: 0.4219 - loss: 2.0849
Epoch 4: val_loss improved from 2.13286 to 2.07778, saving model to /kaggle/working/results/DenseNet201_SGD_ep4_valloss2.078.keras
31/31 ————— 23s 396ms/step - accuracy: 0.4219 - loss: 2.0849 - val_accuracy: 0.2951 - val_loss: 2.0778
Epoch 5/40

```

Figure III. 18 : Exemple d'entraînement de modèle DenseNet201 (originale)

III. 7.2.4 Validation de modèle

Après avoir entraîné le modèle DenseNet201 sur les différentes parties de la plante (feuilles et fruits), une validation rigoureuse a été effectuée pour évaluer la performance du modèle.

III. 7.2.5 Tester le modèle

Une fois le modèle DenseNet201 entraîné sur les différentes parties de la plante, il a été évalué sur un ensemble de données distinct pour évaluer sa performance en termes de précision, de rappel et de F-score pour la classification des images de piments une (évaluation finale).

La précision mesure la proportion d'images de piments correctement classées parmi toutes les images classées comme telles. Le rappel quant à lui évalue la proportion d'images de piments correctement identifiées parmi toutes les images réellement des piments. Enfin, le F-score est une mesure qui combine à la fois la précision et le rappel en un seul score, fournissant une indication globale de la performance du modèle.

La matrice de confusion a également été générée pour fournir un aperçu détaillé des performances du modèle. Cette matrice présente les prédictions du modèle par rapport aux véritables étiquettes de classe, permettant d'identifier les erreurs de classification spécifiques, telles que les faux positifs et les faux négatifs.

III. 7.3. Déployer reconnaissance d'objets YOLO

La deuxième partie de notre expérimentation consiste à déployer Yolo (v8) pour la reconnaissance d'objets. Cette expérimentation comprend l'annotation des données et l'entraînement d'un modèle Yolo basé le fruit de piment.

De nos jours, l'algorithme le plus couramment employé pour détecter simultanément des objets est l'algorithme YOLO (You Only Look Once). YOLO se base sur l'utilisation de réseaux de neurones convolutifs (Karakaya et al. 2022).

III. 7.3.1 Labellisation des données

Les images des fruits ont été annotées à l'aide de l'outil (Labelling) (Figure III. 19).




Figure III. 19 : Exemple de labélisation de fruit de piment (Labelling) (originale)

Le modèle YOLO a été configuré pour la détection d'objets sur les images des fruits. Des dossiers distincts ont été créés pour l'entraînement et la validation du modèle.

Tableau III. 7 : Répartition des données pour YOLO (Fruit)

Partie de la plante	Nombre images	Nombre de labels
Fruit	Entraînement : 3060	Entraînement : 3060
	Validation : 450	Validation : 450

III. 7.3.2 Paramètres utilisés

Tableau III.8 : Paramètres utilisés dans l'entraînement de modèle YOLOv8s

Paramètres (arguments)	Le nom Ou nombre de Paramètres
Nombre d'époques (epochs)	400
Nom de l'optimiseur (optimizer)	SGD
Taux d'apprentissage (Learning rate)	Taux d'apprentissage 0 : 0.007 Taux d'apprentissage finale : 0.0003
Patience	250
Taille du lot (batch size)	128
Taille de l'image (image size)	448
Workers	8

III.7.3.3 Entraînement du modèle YOLOv8

La version la plus récente de YOLO (You Only Look Once), YOLO v8, a considérablement amélioré à la fois la précision et la vitesse par rapport à ses prédécesseurs. Le modèle YOLOv8 a été entraîné sur les données labellisées pour la détection des variétés de piments basé sur le fruit.

```
Starting training for 400 epochs...
```

Epoch	GPU_mem	box_loss	cls_loss	dfl_loss	Instances	Size
1/400	14.2G	0.9498	4.992	1.234	194	448: 100% ██████████ 24/24 [00:22:00:00, 1.06it/s]
Class	Images	Instances	Box(P)	R	mAP50	mAP50-95): 100% ██████████ 2/2 [00:04:00:00, 2.18s/it]
all	450	450	0.29	0.273	0.111	0.0974
Epoch	GPU_mem	box_loss	cls_loss	dfl_loss	Instances	Size
2/400	14G	0.6376	1.871	1.042	211	448: 100% ██████████ 24/24 [00:21:00:00, 1.12it/s]
Class	Images	Instances	Box(P)	R	mAP50	mAP50-95): 100% ██████████ 2/2 [00:02:00:00, 1.29s/it]
all	450	450	0.22	0.54	0.332	0.288
Epoch	GPU_mem	box_loss	cls_loss	dfl_loss	Instances	Size
3/400	14G	0.6167	1.313	0.9942	233	448: 100% ██████████ 24/24 [00:21:00:00, 1.11it/s]
Class	Images	Instances	Box(P)	R	mAP50	mAP50-95): 100% ██████████ 2/2 [00:02:00:00, 1.26s/it]
all	450	450	0.271	0.597	0.383	0.325
Epoch	GPU_mem	box_loss	cls_loss	dfl_loss	Instances	Size
4/400	14G	0.5964	1.07	0.9843	210	448: 100% ██████████ 24/24 [00:21:00:00, 1.11it/s]
Class	Images	Instances	Box(P)	R	mAP50	mAP50-95): 100% ██████████ 2/2 [00:02:00:00, 1.26s/it]
all	450	450	0.304	0.638	0.452	0.388
Epoch	GPU_mem	box_loss	cls_loss	dfl_loss	Instances	Size
5/400	14G	0.6256	0.9715	0.9931	222	448: 100% ██████████ 24/24 [00:21:00:00, 1.12it/s]
Class	Images	Instances	Box(P)	R	mAP50	mAP50-95): 100% ██████████ 2/2 [00:02:00:00, 1.27s/it]
all	450	450	0.324	0.489	0.338	0.298

Figure III. 20 : Exemple d'entraînement de modèle YOLO v8 (originale)

III. 7.3.4 Évaluation du modèle

Le modèle YOLOv8 a été évalué sur un ensemble de données de validation pour mesurer sa précision, son rappel et sa F-score en termes de détection d'objets.

III. 7.3.5 Test de modèle

Test le modèle sur des nouvelles images.

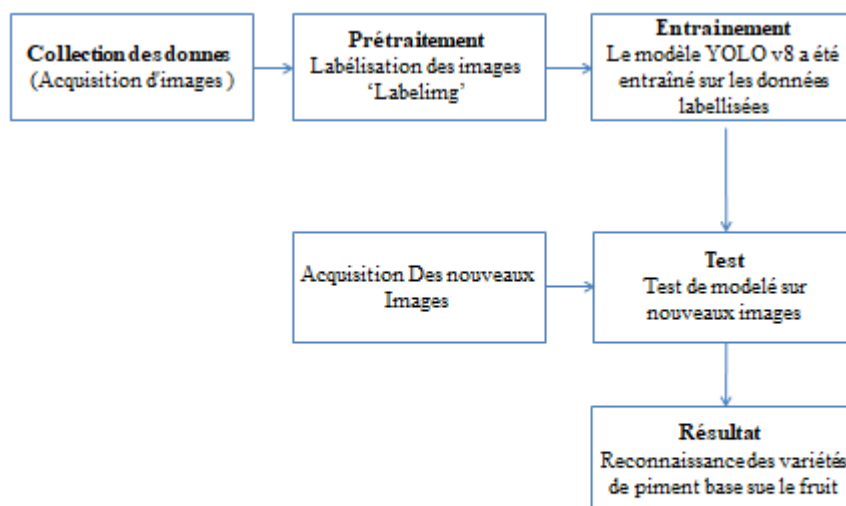


Figure III. 21 : Schéma fonctionnel propose (originale)

III. 7.4. Langage de programmation utilisé (Python)

Python est le langage de programmation utilisé dans notre expérimentation. Python est largement employé, en particulier dans le domaine du Deep Learning et de l'Intelligence Artificielle.

III. 7.5 Utilisation de Kaggle

Pour l'entraînement des modèles, la plateforme Kaggle a été utilisée comme machine virtuelle. Kaggle offre un environnement intégré et flexible permettant de gérer efficacement les tâches liées au deep learning. Nous avons utilisé GPU T4 x2 comme accélérateurs sur la plateforme Kaggle.

CHAPITRE V

RESULTATS ET DISCUSSION

VI. Résultats de la Classifications images


Notre étude consiste à faire la classification des images de différentes parties de la plante (feuille et fruit) en utilisant le modèle DenseNet201 et de faire trois configurations.

VI.1. Cas des Fruits


Nous avons atteint une exactitude de 95 % après plusieurs essais de différentes configurations (nombre d'époques, taille de lot, taux d'apprentissage, etc.).

VI.1.1 Phase construction du model


Ces courbes montrent d'évolutions de l'exactitude (Accuracy) de la perte d'apprentissage et de validation :



(a)



(b)



(c)

Figure VI.1 : Courbes d'évolutions de l'exactitude et de la perte d'apprentissage et de validation (a.confug01, b.confug02, c.confug03).

VI.1.1.1. Configuration 01

a. Graphique de l'évolution de la perte (training and validation loss)

Ce graphique montre l'évolution de la perte (loss) pendant les 40 époques d'entraînement (Figure VI.1).

- **Courbe bleue (Training Loss)** : la perte d'entraînement diminue de manière constante, ce qui indique que le modèle s'améliore au fur et à mesure des époques.
- **Courbe orange (Validation Loss)** : la perte de validation suit une tendance générale à la baisse, bien qu'elle présente des fluctuations. La présence de ces fluctuations indique une certaine variabilité dans la performance du modèle sur les données de validation.

b. Graphique de l'évolution de l'exactitude (training and validation Accuracy)

Ce graphique montre l'évolution de L'exactitude pendant les 40 époques d'entraînement (Figure V.1).

- **Courbe bleue (Training Accuracy)** : L'exactitude d'entraînement augmente régulièrement, atteignant une précision élevée vers la fin de l'entraînement. Cela indique que le modèle apprend bien les données d'entraînement.
- **Courbe orange (Validation Accuracy)** : L'exactitude de validation augmente également, mais avec plus de fluctuations que la courbe de précision d'entraînement. Ces fluctuations peuvent indiquer des problèmes de sur apprentissage (overfitting).

c. Analyse globale

- Une exactitude globale de 85% est un bon résultat, indiquant que le modèle classifie correctement les populations de piment local dans 85% des cas
- **Sur apprentissage** : Les fluctuations dans la courbe de validation (perte et exactitude) suggèrent qu'il pourrait y avoir un léger surapprentissage.
- **Stabilité** : La perte et L'exactitude d'entraînement montrent une tendance stable et constante, ce qui est un signe positif de convergence.

Les résultats montrent que le modèle DenseNet201 est performant pour la classification des populations de piment local avec une exactitude de 85%, bien qu'il y ait quelques signes de surapprentissage à surveiller.

VI.1.1.2 Confugration 02

Deuxième tentative après avoir amélioré la configuration du modèle DenseNet201

a. Graphique de l'évolution de la perte (training and validation loss)

Ce graphique montre l'évolution de la perte (loss) pendant les 30 époques d'entraînement (**Figure VI.1**).

- **Courbe bleue (Training Loss)** : La perte d'entraînement diminue de manière constante et atteint presque zéro vers la fin des époques. Cela indique que le modèle s'améliore continuellement dans la classification des données d'entraînement.
- **Courbe orange (Validation Loss)** : La perte de validation suit également une tendance à la baisse, montrant une réduction régulière avec moins de fluctuations que dans la tentative précédente. Cela indique une meilleure généralisation du modèle.

b. Graphique de l'évolution de l'exactitude (training and validation Accuracy)

Ce graphique montre l'évolution de l'exactitude (accuracy) pendant les 30 époques d'entraînement (**Figure VI.1**).

- **Courbe bleue (Training Accuracy)** : L'exactitude d'entraînement augmente rapidement et se stabilise autour de 100%, ce qui montre que le modèle apprend très bien les données d'entraînement.
- **Courbe orange (Validation Accuracy)** : L'exactitude de validation atteint environ 90% et se stabilise avec des fluctuations minimales. Cela indique une performance robuste sur les données de validation.

c. Analyse globale

- Une exactitude de 93% est un excellent résultat, indiquant que le modèle classe correctement les populations de piment local dans 93% des cas.
 - **Surapprentissage réduit** : La réduction des fluctuations dans la courbe de perte de validation et la courbe de exactitude de validation suggèrent que les modifications apportées à la configuration du modèle ont réduit le surapprentissage par rapport à la tentative précédente.
- a. **Stabilité** : Les courbes montrent une convergence stable et rapide, ce qui est un signe positif de la performance du modèle.

Les modifications apportées à la configuration du modèle ont significativement amélioré sa performance, comme en témoigne une exactitude accrue à 93% et une meilleure stabilité des courbes de perte et de précision.

VI.1.1.3 Configuration 03

Troisième tentative après avoir encore amélioré la configuration du modèle DenseNet201:

a. Graphique de de l'évolution de la perte (training and validation loss)

Ce graphique montre l'évolution de la perte (loss) pendant les 40 époques d'entraînement (**Figure VI.1**).

a. Courbe bleue (Training Loss) : La perte d'entraînement diminue de manière constante et atteint presque zéro vers la fin des époques, ce qui montre que le modèle continue de s'améliorer dans la classification des données d'entraînement.

b. Courbe orange (Validation Loss) : La perte de validation diminue également de manière régulière avec quelques fluctuations, surtout vers la fin des époques.

- **Graphique de l'évolution de l'exactitude (training and validation Accuracy)**

Ce graphique montre l'évolution de L'exactitude pendant les 40 époques d'entraînement (**Figure VI.1**).

a. Courbe bleue (Training Accuracy) : L'exactitude d'entraînement augmente rapidement, atteignant presque 100% et se stabilisant, ce qui indique que le modèle apprend très bien les données d'entraînement.

b. Courbe orange (Validation Accuracy) : L'exactitude de validation atteint environ 95% avec des fluctuations minimales. Cela montre que le modèle performe très bien sur les données de validation.

- **Analyse globale**

a. L'exactitude : Une exactitude de 95% est un excellent résultat, indiquant que le modèle classe correctement les populations de piment local dans 95% des cas.

b. Surapprentissage : Bien que les fluctuations dans la courbe de perte de validation vers la fin puissent indiquer un début de surapprentissage, l'utilisation de l'optimiseur Adam et du mécanisme d'arrêt précoce avec une patience de 10 semble avoir bien régulé l'apprentissage.

c. Stabilité : Les courbes montrent une bonne convergence et une performance robuste, bien que l'entraînement aurait pu être arrêté un peu plus tôt pour éviter un potentiel surapprentissage.

- **Améliorations ajoutée**

a. Optimiseur Adam : L'utilisation de l'optimiseur Adam avec un taux d'apprentissage plus faible (0.0001) a contribué à une convergence plus rapide et plus stable.

Les modifications apportées à la configuration du modèle ont conduit à une exactitude accrue de 95%, avec une meilleure stabilité et une généralisation robuste, bien que des signes légers de surapprentissage.

Ces tableaux représentent les rapports de classification (métriques), basés sur des tests effectués sur de nouveaux dossiers

	precision	recall	f1-score	support
V01_BAAGE	0.94	0.84	0.89	38
V02_TOLGA	0.77	0.87	0.82	46
V03_ZRIBA	0.93	0.96	0.94	26
V04_TOUGERT	0.94	0.94	0.94	47
V06_BARIKA	0.90	0.77	0.83	48
V07_OLDJ	0.86	0.69	0.77	26
V09_MAGREN	0.69	0.92	0.79	37
V11_LIZERG	0.86	0.91	0.88	33
V12_SIDIOUANE	0.88	0.79	0.83	47
accuracy			0.85	348

(a)

	precision	recall	f1-score	support
V01_BAAGE	0.93	1.00	0.96	38
V02_TOLGA	0.85	0.89	0.87	46
V03_ZRIBA	1.00	0.92	0.96	25
V04_TOUGERT	0.94	0.98	0.96	47
V06_BARIKA	0.91	0.85	0.88	48
V07_OLDJ	0.92	0.88	0.90	26
V09_MAGREN	0.93	1.00	0.96	37
V11_LIZERG	0.92	1.00	0.96	33
V12_SIDIOUANE	0.97	0.83	0.90	47
accuracy			0.93	347

(b)

	precision	recall	f1-score	support
V01_BAAGE	0.90	1.00	0.95	38
V02_TOLGA	0.93	0.89	0.91	46
V03_ZRIBA	0.96	0.96	0.96	26
V04_TOUGERT	0.98	1.00	0.99	47
V06_BARIKA	0.94	0.94	0.94	48
V07_OLDJ	1.00	0.92	0.96	26
V09_MAGREN	0.90	0.97	0.94	37
V11_LIZERG	0.97	1.00	0.99	33
V12_SIDIOUANE	0.95	0.85	0.90	47
accuracy			0.95	348

(c)

Figure V.2 : Métriques (a.confug01, b.confug02, c.confug03).

VI.1.1.2.1 Configuration 01

a. Précision, Rappel et F1-score

Les métriques de précision, rappel et F1-score sont globalement bonnes.

Les valeurs de précision varient de 0.69 (V09_MAGREN) à 0.94 (V01_BAAGE, V04_TOUGERT).

Le rappel (recall) varie de 0.69 (V07_OLDJ) à 0.96 (V03_ZRIBA).

Les scores F1 suivent une tendance similaire, indiquant une performance robuste dans la plupart des catégories (**Figure VI.2**).

b. Support

Le support indique le nombre d'instances de chaque classe dans les données de test. La classe avec le plus d'instances est V04_TOUGERT (47 instances), tandis que la classe avec le moins d'instances est V03_ZRIBA (26 instances)

c. Points Positifs

- *Performance élevée pour certaines classes* : Les classes comme V01_BAAGE, V03_ZRIBA, et V04_TOUGERT montrent des métriques très élevées, indiquant que le modèle les identifie bien.
- *Équilibre des scores* : Les scores de précision, rappel et F1 sont assez équilibrés, ce qui montre que le modèle est bien calibré et qu'il ne favorise pas une métrique au détriment des autres.

Les résultats de premier essai avec le modèle DenseNet201 sont prometteurs, avec une exactitude de 85%. En se concentrant sur l'amélioration des classes sous-performantes (V09_MAGREN et V07_OLDJ) en ajustant certains hyperparamètres.

VI.1.1.2.2 configuration 02

Les résultats de deuxième essai montrent une amélioration significative par rapport au premier :

a. Précision, Rappel et F1-score

Les métriques de précision, rappel et F1-score sont toutes améliorées.

La précision varie de 0.85 (V02_TOLGA) à 1.00 (V03_ZRIBA).

Le rappel (recall) varie de 0.83 (V12_SIDIOUANE) à 1.00 (V01_BAAGE, V09_MAGREN, V11_LIZERG).

Les scores F1 sont également élevés, avec la plupart des classes atteignant ou dépassant 0.90 (Figure VI.2).

b. Support

Le support reste similaire au premier essai.

- ***Performance élevée et équilibrée*** : Toutes les classes ont maintenant des scores de précision, rappel et F1 très élevés. Les classes précédemment problématiques, telles que V09_MAGREN et V07_OLDJ, montrent maintenant des performances excellentes.
- ***Amélioration Générale*** : L'augmentation de la précision globale à 93% montre que les ajustements apportés ont eu un impact positif.

Le deuxième essai montre une amélioration substantielle avec une exactitude de 93%, et des métriques équilibrées pour toutes les classes. Les ajustements apportés (réduction du nombre d'époques, diminution de la taille de batch) ont clairement eu un impact positif sur la performance du modèle.

VI.1.1.2.3 Configurations 03

Troisième essai montre des résultats encore plus impressionnants :

a. Précision, Rappel et F1-score

Les métriques de précision, rappel et F1-score sont toutes élevées.

La précision varie de 0.90 (V01_BAAGE et V09_MAGREN) à 1.00 (V07_OLDJ).

Le rappel (recall) varie de 0.85 (V12_SIDIOUANE) à 1.00 (V01_BAAGE, V04_TOUGERT, V07_OLDJ).


Les scores F1 sont également élevés, avec la plupart des classes atteignant ou dépassant 0.90 (Figure VI.2).

b. Support

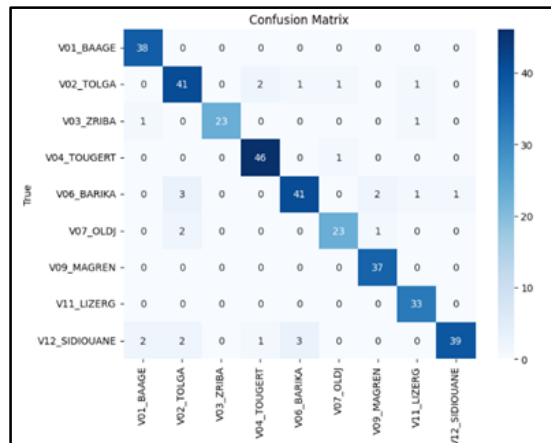
La taille de l'ensemble de données de test est stable et constant avec 348 instances au total.

Troisième configuration montre une amélioration significative, atteignant une exactitude de 95% montrant une amélioration par rapport aux essais précédents (85% et 93%). Les ajustements apportés, tels que l'augmentation de la taille du batch, l'utilisation de l'optimiseur Adam et l'ajustement du taux d'apprentissage, ont clairement eu un impact positif sur la performance globale du modèle. Ces résultats sont très prometteurs et indiquent que le modèle est désormais très performant pour la classification des populations de piment local basée sur les fruits.


Ces figures sont des matrices de confusion, basées sur des tests effectués sur de nouveaux dossiers :



(a)



(b)



(c)

Figure V.3 : Matrice de confusion (a.confug01, b.confug02, c.confug03).

VI.1.1.3.1 configuration 01

a. Haches

L'axe vertical représente les véritables étiquettes (populations réelles).

L'axe horizontal représente les étiquettes prédites (populations prédites).

b. Cellules

Les cellules diagonales (du coin supérieur gauche au coin inférieur droit) représentent les classifications correctes.

Les cellules hors diagonale représentent des erreurs de classification. Plus les valeurs ne sont élevées le long de la diagonale, meilleures sont les performances du modèle, car elles indiquent des instances correctement classées.

VI.1.1.3.2 Observations clés

Les populations telles que V01_BAAGE, V02_TOLGA, V04_TOUGERT, V06_BARIKA, V09_MAGREN, V11_LIZERG et V12_SIDIOUANE présentent des nombres relativement élevés le long de la diagonale (32, 40, 44, 37, 34, 30, 37 respectivement), indiquant une bonne précision de classification pour ces populations (**Figure V.3**).

VI.1.1.3.3 Erreurs de classification

Certaines populations présentent des erreurs de classification importantes. Par exemple :

V06_BARIKA (vrai) est parfois classé comme V02_TOLGA (6 instances).

V12_SIDI_OUANE (vrai) est parfois classé à comme BAAGE (4 instances).

Dans l'ensemble, le modèle fonctionne assez bien avec un taux exactitude de 85 %, ce qui indique qu'il est généralement efficace pour classer les populations de piment en fonction de leurs fruits. Cependant, des progrès restent à faire pour réduire les erreurs de classification, en particulier parmi certaines paires de populations.

VI.1.1.3.2 Configuration 02

a. Observations clés

Les valeurs le long de la diagonale sont élevées, ce qui est bon signe (Figure V.3). Les classifications correctes sont les suivantes : V01_BAAGE : 38, V02_TOLGA : 41....

Cela indique que le modèle identifie correctement la plupart des échantillons pour chaque population.

b. Erreurs de classification :

Les erreurs de classification ont globalement diminué, mais certaines existent toujours. Par exemple :

V12_SIDI_OUANE (vrai) est parfois classé comme BAAGE (2 instances), comme BARIKA (3 instances).

c. Amélioration par rapport à la première config :

Il y a moins de valeurs hors diagonale par rapport à la première matrice de confusion, ce qui indique de meilleures performances.

Le modèle s'est considérablement amélioré, comme en témoigne l'augmentation de l'exactitude à 93 % et la plus grande prédominance des classifications correctes le long de la diagonale. Les erreurs de classification ont diminué.

VI.1.1.3.3 Configuration 03

a. Performance globale :

La précision du modèle a augmenté jusqu'à 95 %, ce qui indique une nouvelle amélioration par rapport aux tentatives précédentes.

b. Domination diagonale :

Les valeurs élevées le long de la diagonale représentent des classifications correctes. Cela suggère que le modèle identifie correctement la majorité des populations.

VI.1.1.3.3.2. Erreurs de classification :

Les erreurs de classification ont encore diminué mais existent toujours. Par exemple :

V12_SIDI_OUANE (vrai) est parfois classé à comme BAAGE (4 instances). ce que montre la ressemblance entre les fruits de ces 2 populations

VI.1.1.3.3.3. Amélioration par rapport aux tentatives précédentes :

Par rapport aux tentatives précédentes, on constate une amélioration notable de la précision de la classification.

Les populations présentent des erreurs de classification réduites, indiquant une meilleure discrimination entre ces populations.

La troisième tentative montre une amélioration substantielle avec une exactitude de 95 %. L'introduction de l'optimiseur Adam et un taux d'apprentissage plus faible semblent avoir contribué à cette amélioration. Les performances globales du modèle se sont améliorées, avec davantage d'instances correctement classées et moins d'erreurs de classification.

Après avoir examiné les résultats de trois configurations et obtenu une exactitude de 95 %, nous confirmons en particulier non seulement la présence d'une variation génétique au sein des variétés de piment ainsi qu'entre elles sur la base des caractéristiques du fruit mais aussi l'observation d'un degré de variation important.

Des études ultérieures basées sur la morphologie des variétés locales du piment utilisant l'analyse multivariée traitant 52 paramètres des parties végétatives et reproductives (Bedjaoui et al. 2022) ont montré que l'analyse en composantes principales (ACP) a révélé que les variables les plus discriminantes sont celles liées aux caractéristiques du fruit essentiellement la longueur et la largeur du fruit ainsi que les détails décrivant la forme du calice.

D'autre part, la ressemblance morphologique révélée par nos résultats entre les fruits de certaines populations pourrait s'expliquer par le rapprochement géographique des sites de collecte des semences. En effet, les variétés V12_SIDI_OUANE et V01_BAAGE proviennent d'El Oued, tandis que les variétés V06_BARIKA et V02_TOLGA viennent respectivement de Barika (Batna) et Tolga (Biskra).

D'une manière globale, nos résultats concordent avec ceux trouvés par d'autres études. Concernant la classification des 9 variétés locales de piment sur la base du fruit, nous avons obtenu une exactitude de 95 % après plusieurs essais de différentes configurations. Un modèle d'apprentissage profond basé sur CNN, ResNet pour classer les images de fruits à l'aide de l'ensemble de données Fruit 360. ResNet-50 a prouvé sa robustesse dans des tâches de classification d'images variées, atteignant une exactitude de 99% (Senbagavalli et al ,2023)

DenseNet-201, avec plus de couches, a également montré une grande performance, atteignant une exactitude de 95%. L'architecture de DenseNet, avec ses connexions denses, aide à capturer des caractéristiques complexes nécessaires pour différencier les variétés de piment. (Senbagavalli et al, 2023)

VI.2. Cas de Feuille

Nous avons atteint une exactitude de 89 % après plusieurs essais de différentes configurations (nombre d'époques, taille de lot, taux d'apprentissage, etc.).

VI.2.1. Phase construction du model

Ces courbes montrent d'évolutions de l'exactitude (Accuracy) de la perte d'apprentissage et de validation

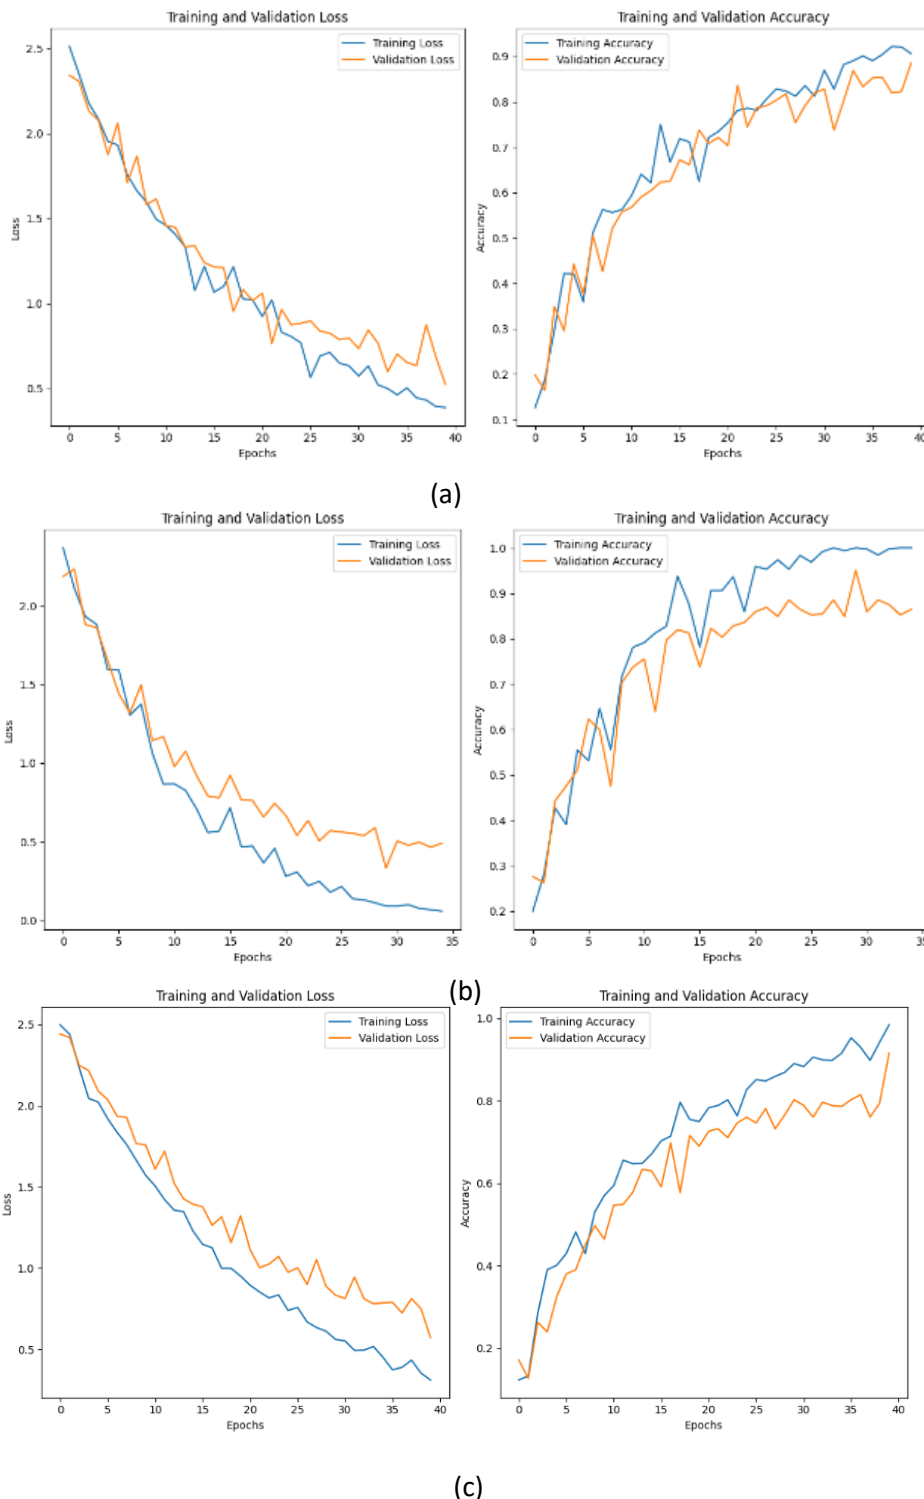


Figure VI.4 : Courbes d'évolutions de l'exactitude et de la perte d'apprentissage et de validation (a.config01, b.config02, c.config03).

VI.2.1.1. Configuration 01

Ce graphique montre l'évolution de la perte (loss) pendant les 40 époques d'entraînement (Figure VI.4)

a. Graphique de de l'évolution de la perte (loss)

- **Courbe bleue (Training Loss)** : La perte d'apprentissage diminue régulièrement tout au long des 40 époques, atteignant presque 0 vers la fin. Cela montre que le modèle s'adapte bien aux données d'entraînement.
- **Courbe orange (Validation Loss)** : La perte de validation diminue également de manière constante, bien qu'elle reste légèrement plus élevée que la perte d'apprentissage.

b. Graphique de l'évolution de l'exactitude (Accuracy)

Ce graphique montre l'évolution de l'exactitude (accuracy) pendant les 40 époques d'entraînement

- **Courbe bleue (Training Accuracy)** : l'exactitude d'apprentissage augmente progressivement, atteignant presque 0,9 (90%) vers la fin des 40 époques.
- **courbe orange (Validation Accuracy)** : l'exactitude de validation suit une tendance similaire, bien qu'elle fluctue légèrement plus que la précision d'apprentissage, atteignant environ 0,8 (80%) à la fin.

c. Analyse globale

La proximité des deux courbes indique que le modèle a une bonne capacité de généralisation, car la précision sur les données de validation est proche de celle des données d'entraînement.

VI.2.1.2 Configuration 02

Deuxième tentative après avoir amélioré la configuration du modèle DenseNet201

a. Graphique de de l'évolution de la perte (loss)

Ce graphique montre l'évolution de la perte (loss) pendant les 35 époques d'entraînement (Figure VI.4)

- **Courbe bleue (Training Loss)** : La perte d'apprentissage diminue de façon constante, atteignant presque 0 à la fin des 35 époques. Cela indique que le modèle apprend très bien sur les données d'entraînement.

- **Courbe orange (Validation Loss)** : La perte de validation diminue également de manière régulière mais reste légèrement plus élevée que la perte d'apprentissage, ce qui est attendu car les données de validation sont des données nouvelles pour le modèle.

b. Graphique de l'évolution de l'exactitude (Accuracy)

Ce graphique montre l'évolution de la précision (accuracy) pendant les 35 époques d'entraînement.

- **Courbe bleue (Training Accuracy)** : l'exactitude d'apprentissage augmente régulièrement et atteint presque 1,0 (100%) à la fin des 35 époques, montrant que le modèle est capable de bien classer les données d'entraînement.
- **courbe orange (Validation Accuracy)** : l'exactitude de validation augmente également, bien qu'elle fluctue plus que la précision d'apprentissage, atteignant environ 0,86 (86%) à la fin des 35 époques.

c. Analyse globale

La proximité des deux courbes indique que le modèle a une bonne capacité de généralisation, car l'exactitude sur les données de validation est proche de celle des données d'entraînement.

VI.2.1.3 configuration 03

Troisième tentative après avoir amélioré la configuration du modèle DenseNet201 et le changement de la distribution des données (**80% d'entraînement, 15 % validation et 2% test**)

a. Graphique de de l'évolution de la perte (loss)

Ce graphique montre l'évolution de la perte (loss) pendant les 40 époques d'entraînement (**Figure VI.4**)

- **Courbe bleue (Training Loss)** : La perte d'entraînement diminue régulièrement tout au long des époques, ce qui indique que le modèle apprend bien sur les données d'entraînement.
- **Courbe orange (Validation Loss)** : La perte de validation suit également une tendance à la baisse, bien qu'elle soit légèrement plus fluctuante que la perte d'entraînement. Cela montre que le modèle généralise assez bien sur les données de validation.

c. Graphique de l'évolution de l'exactitude (Accuracy)

Ce graphique montre l'évolution de l'exactitude (accuracy) pendant les 40 époques d'entraînement

- **Courbe bleue (Training Accuracy)** : l'exactitude d'entraînement augmente de manière régulière et atteint plus de 90 % vers la fin de l'apprentissage, ce qui montre une bonne capacité d'apprentissage du modèle.
- **courbe orange (Validation Accuracy)** : l'exactitude de validation, bien qu'un peu plus variable, suit également une tendance ascendante. Cela indique que le modèle conserve une bonne performance sur des données non vues pendant l'entraînement.

Les résultats obtenus sont optimaux après plusieurs essais de différentes configurations. Les graphiques montrent une bonne convergence du modèle avec une amélioration continue de la perte et de la précision tant pour l'entraînement que pour la validation. La légère fluctuation dans les courbes de validation est normale et indique que le modèle n'est pas en surapprentissage (overfitting) significatif. Les paramètres utilisés (nombre d'époques, taux d'apprentissage, taille du lot, etc.) semblent bien choisis pour cette tâche spécifique de classification des populations de piment locales basent sur la feuille de plante.

Ces tableaux représentent les rapports de classification (métriques), basés sur des tests effectués sur de nouveaux dossier

	precision	recall	f1-score	support
ATID_V10	0.89	0.85	0.87	20
BAAGE_V01	0.78	0.88	0.82	24
BARIKA_V06	1.00	0.61	0.76	23
LIOUA_V08	0.80	0.60	0.69	20
LIZERG_V11	0.83	0.90	0.86	21
MAGREN_V09	0.68	0.93	0.78	27
MZIRAA_V05	0.95	0.91	0.93	22
OLDJ_V07	0.68	0.62	0.65	21
SIDIOUANE_V12	0.80	0.73	0.76	22
TOLGA_V02	0.74	0.95	0.83	21
TOUGERT_V04	0.80	0.80	0.80	20
ZRIBA_V03	0.77	0.74	0.76	23
accuracy			0.80	264
macro avg	0.81	0.79	0.79	264
weighted avg	0.81	0.80	0.79	264

(a)

	precision	recall	f1-score	support
ATID_V10	0.82	0.90	0.86	20
BAAGE_V01	0.91	0.88	0.89	24
BARIKA_V06	1.00	0.70	0.82	23
LIOUA_V08	0.77	0.85	0.81	20
LIZERG_V11	0.76	0.90	0.83	21
MAGREN_V09	0.89	0.89	0.89	27
MZIRAA_V05	0.88	0.95	0.91	22
OLDJ_V07	0.79	0.71	0.75	21
SIDIOUANE_V12	0.85	0.77	0.81	22
TOLGA_V02	1.00	0.95	0.98	21
TOUGERT_V04	0.77	1.00	0.87	20
ZRIBA_V03	1.00	0.87	0.93	23
accuracy			0.86	264
macro avg	0.87	0.86	0.86	264
weighted avg	0.87	0.86	0.86	264

(b)

	precision	recall	f1-score	support
ATID_V10	0.60	0.75	0.67	4
BAAGE_V01	0.83	1.00	0.91	5
BARIKA_V06	1.00	0.80	0.89	5
LIOUA_V08	1.00	0.80	0.89	5
LIZERG_V11	0.83	1.00	0.91	5
MAGREN_V09	1.00	0.86	0.92	7
MZIRAA_V05	1.00	1.00	1.00	6
OLDJ_V07	0.80	0.80	0.80	5
SIDIOUANE_V12	1.00	0.80	0.89	5
TOLGA_V02	0.80	0.80	0.80	5
TOUGERT_V04	0.83	1.00	0.91	5
ZRIBA_V03	1.00	1.00	1.00	5
accuracy			0.89	62
macro avg	0.89	0.88	0.88	62
weighted avg	0.90	0.89	0.89	62

(c)

Figure VI.5 : Métriques (a.confug01, b.confug02, c.confug03).

VI.2.1.2.1 Configuration 01

a. Métriques globales

Les résultats obtenus avec ces paramètres montrent une précision globale de 80 %, ce qui est un bon point de départ. La performance varie entre les différentes classes, certaines ayant des scores de précision, de rappel et de F1-score plus élevés que d'autres. La classe "BARIKA_V06" montre une précision parfaite mais un rappel plus bas, ce qui peut indiquer un certain déséquilibre ou une mauvaise généralisation pour cette classe particulière. Pour améliorer ces résultats, il pourrait être bénéfique de continuer à ajuster les hyperparamètres.

VI.2.1.2.2 Configuration 02

Deuxième essai a conduit à une amélioration notable par rapport au premier essai.

a. Optimiseur : Le passage de l'optimiseur SGD à Adam semble avoir eu un impact positif. L'optimiseur Adam, avec un taux d'apprentissage de 0.0001, est connu pour ses bonnes performances sur divers jeux de données et architectures.

b. Taux d'apprentissage : Une réduction du taux d'apprentissage à 0.0001 permet des mises à jour plus fines des poids, ce qui peut contribuer à une meilleure convergence.

Les ajustements des paramètres ont conduit à une amélioration de l'exactitude atteignant 86%. L'utilisation de l'optimiseur Adam avec un taux d'apprentissage plus bas a permis d'obtenir de meilleurs résultats.

VI.2.1.2.3 configuration 03

a. Précision, Rappel et F1-score :

Les métriques de précision, rappel et F1-score sont globalement bonnes.

Les valeurs de précision varient de 0.6 (V10_ATID) à 1.00 (V03_ZRIBA).

Le rappel (recall) varie de 0.75 (V10_ATID) à 1.00 (V03_ZRIBA).

Les scores F1 de varie de 0.67 (V10_ATID) à 1.00 (V03_ZRIBA).

b. Support


Le support indique le nombre d'instances de chaque classe dans les données de test. On changer nombre des images de test a 2%.

a. Taux d'apprentissage : Réduire le taux d'apprentissage à 0.00007 a permis des mises à jour plus fines et plus stables des poids, ce qui a contribué à une meilleure convergence du modèle.

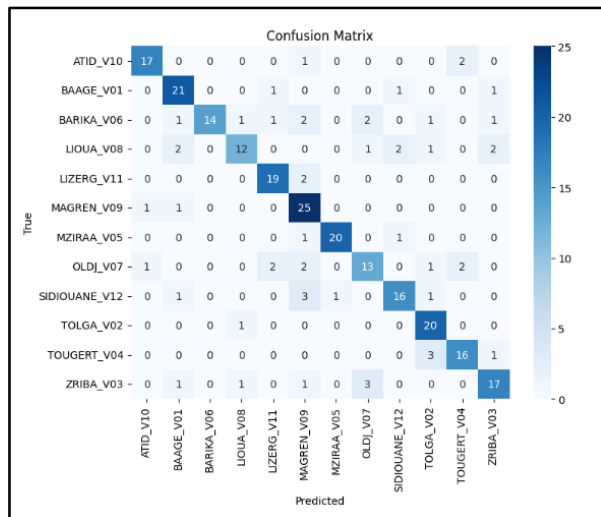
b. Optimiseur : L'optimiseur Adam continue de montrer son efficacité, particulièrement avec un taux d'apprentissage plus bas, en s'adaptant bien aux différents gradients de l'erreur.

La variété (V10_ATID) montre des résultats bas peut être a causé nombre petite de images dans notre base de donnes par a pour l'autre variété et cette variété est la seule variété hybride dans cette expérimentation.


Ces figures sont des matrices de confusion, basées sur des tests effectués sur de nouveaux dossiers :



(a)



(b)



(c)

Figure VI.6 : Matrices de confusion (a.confug01, b.confug02, c.confug03).

VI.2.1.3.1 Configuration 01

Dans l'ensemble, la matrice de confusion indique que même s'il existe plusieurs prédictions correctes, il existe également des erreurs de classification. Ces erreurs de classification peuvent donner un aperçu des classes qui sont confondues les unes avec les autres et pourraient aider à affiner davantage le modèle ou à comprendre les similitudes inhérentes entre les variétés mal classées.

VI.2.1.3.2 Configuration 02

a. Amélioration des prédictions correctes : le nombre de prédictions correctes s'est généralement amélioré dans la plupart des classes. Par exemple, ATID_V10 est passé de 17 à 18, BARIKA_V06 de 14 à 16 et MAGREN_V09 de 25 à 24.

b. Réduction des erreurs de classification : les erreurs de classification ont été réduites ou restent stables dans de nombreuses catégories. Par exemple, les erreurs de classification de BARIKA_V06 à LIOUA_V08 ont été réduites.

c. Ajustements du modèle : le passage à l'optimiseur Adam et la réduction du taux d'apprentissage semblent avoir eu un impact positif sur les performances du modèle, conduisant à des prédictions plus précises.

Dans l'ensemble, la deuxième tentative montre une amélioration notable des performances du modèle, ce qui suggère que les modifications apportées à l'optimiseur et au taux d'apprentissage, ainsi qu'au nombre d'époques, ont été bénéfiques.

VI.2.1.3.3 Configuration 03

a. Réduction des erreurs de classification : le nombre d'erreurs de classification a été réduit dans cette tentative. La plupart des classes ont très peu ou pas d'erreurs de classification.

b. Stabilité du modèle : l'utilisation d'un taux d'apprentissage plus faible et d'une taille de lot plus grande semble avoir contribué à des prédictions plus stables et plus précises.

La troisième tentative a donné les meilleurs résultats, avec une grande précision et une réduction des erreurs de classification. Les ajustements du taux d'apprentissage, de la taille des lots et de la patience semblent efficaces.

En ce qui concerne la classification basée sur la feuille, nos résultats correspondent à ceux trouvés par d'autres études. En effet, concernant la classification des 12 variétés de piment sur la base de la feuille, nous avons obtenu une exactitude de 89% après avoir réalisé trois expérimentations.

Nous n'avons pas trouvé, dans nos recherches sur le piment, des travaux connexes utilisant le modèle DenseNet-201. Toutefois, une étude évaluant les performances de modèles CNN (AlexNet, VGG16, Inception-v3 et DenseNet-121) pour classer les variétés de piment à partir d'images de feuilles âgées de 10 jours a été réalisée par Khotimah et al. (2022). Ces auteurs ont travaillé avec 12 classes de feuilles de piment. Les précisions obtenues vont de 70,18 % à 78,37 %, DenseNet-121 ayant les meilleurs résultats avec une précision de 78,37 % et un rappel de 74,83 %.

Utilisation de DenseNet-201 montre une amélioration notable de la précision (89%) par rapport à DenseNet-121 (78,37%). Cela peut être attribué à la plus grande capacité du modèle DenseNet-201 à apprendre des représentations plus détaillées et complexes grâce à ses couches supplémentaires. Les résultats suggèrent que DenseNet-201 pourrait être une option plus efficace pour la classification des variétés de piment à partir d'images de feuilles, en raison de sa meilleure performance en termes de précision.

V. Déployer reconnaissance d'objets YOLO

La deuxième partie de Notre expérimentation consiste à déployer YOLOv8s pour la reconnaissance d'objets pour classifier 9 populations de piments .Cette expérimentation comprend l'annotation des données et l'entraînement d'un modèle Yolo basé le fruit de piment.

V.1. Résultats obtenus sur la reconnaissance de fruit

Le modèle YOLOv8s a montré une performance globalement solide avec un mAP50-95 moyen de 0.814. Certaines classes comme "Tougre_t_clyx" et "Oldj_frt" ont des mAP50-95 très élevés, indiquant une bonne précision et rappel. Cependant, des classes comme "Zriba_frt" et "Lizerg_clyx" montrent des performances inférieures, suggérant une variabilité dans la détection selon les classes (Figure VI.7).

```

1s/it]

```

Class	Images	Instances	Box(P	R	mAP50	mAP50-95): 100%	2/2 [00:03<00:00, 1.7
all	450	450	0.845	0.853	0.9	0.814	
Baage_frt	450	26	0.756	0.962	0.882	0.747	
Baage_clyx	450	24	0.706	0.875	0.847	0.679	
Tolga_frt	450	24	0.882	0.875	0.97	0.809	
Tolga_clyx	450	26	0.942	0.923	0.965	0.846	
Zriba_clyx	450	26	0.876	0.813	0.919	0.856	
Zriba_frt	450	25	0.712	0.793	0.779	0.629	
Tougre_t_clyx	450	25	0.897	1	0.992	0.933	
Tougre_t_frt	450	25	0.948	0.96	0.941	0.875	
Barika_clyx	450	26	0.953	0.787	0.855	0.81	
Barika_frt	450	23	0.768	0.87	0.913	0.892	
Oldj_clyx	450	23	0.948	0.785	0.949	0.911	
Oldj_frt	450	27	0.979	0.926	0.958	0.933	
Magren_clyx	450	26	0.894	0.652	0.859	0.774	
Magren_frt	450	25	0.863	0.76	0.904	0.879	
Lizerg_clyx	450	26	0.774	0.922	0.909	0.849	
Lizerg_frt	450	23	0.612	0.696	0.73	0.629	
Sidiouane_clyx	450	26	0.856	0.885	0.933	0.774	
Sidiouane_frt	450	24	0.841	0.875	0.897	0.835	

Speed: 0.1ms preprocess, 2.7ms inference, 0.0ms loss, 0.9ms postprocess per image
Results saved to runs/detect/train

Figure VI.7 : Résultats de la reconnaissance d'objets utilisant le modèle YOLOv8s

V.1.1 Batch d'Entraînement

Notre base de données est utilisée pour l'entraînement d'un modèle YOLOv8s pour la détection d'objets (**Figure VI.8**), en particulier pour la classification de neuf populations de piments locaux. L'ensemble de données contient plusieurs images de piment avec des cadres englobants et des étiquettes indiquant leur classification.



Figure VI.8 : Notre base de données utilisée pour l'entraînement d'un modèle YOLOv8s

a. Annotations et étiquettes : Chaque image de fruit est annotée d'un cadre de sélection et d'une étiquette. Les étiquettes correspondent à différentes populations ou parties de fruit de piment, avec des numéros allant de 1 à 18.

b. Boîtes englobantes : Les boîtes englobantes sont codées par couleur, ce qui aide à différencier les différentes classes de piment. Par exemple, les cases orange indiquent la variété (TOLGA_V02), les cases vertes claires indiquent la variété (TOUGERT_V04)

V.1.2 Batch de Validation de prédiction

Batch de validation est utilisé pour évaluer la précision du modèle en comparant les étiquettes et les cadres de délimitation prédits à la vérité terrain. Des scores de confiance élevés et des prédictions correctes sur l'ensemble de validation indiquent de bonnes performances du modèle (chaque image de notre base de données contient le nom de variété).



Figure VI.9 : Batch de validation pour l'évaluation des performances d'un modèle YOLOv8s

a. Annotations et prédictions : Les étiquettes incluent un score de précision, qui indique la précision du modèle dans sa prédiction, allant de 0,8 à 1,0 dans ce cas.

b. Boîtes englobâtes : les boîtes englobâtes sont codées par couleur bleue, ce qui peut être utilisé pour différencier les prédictions lors de la validation.

c. Scores de confiance : Un score de 1,0 signifie que le modèle est totalement correct quant à sa prédiction. Les scores de 0,8 à 0,9 indiquent un niveau de confiance élevé mais légèrement moins certain que 1,0.

d. Classes prévues

Les classes incluent diverses étiquettes telles que "Lizerg_clyx", "Oldj_clyx", "Magren_clyx", "Magren_frt", "Tougrete_clyx". Ceux-ci correspondent à différents types de à différentes parties de piment (fruit, calice).

e. Analyse

Le modèle affiche des prédictions cohérentes avec des scores de confiance élevés sur différentes images (nom d'image contient la variété), indiquant qu'il a appris à reconnaître efficacement les différentes classes de piment (si en compare le nom d'images en haut et les étiqués on trouve que toutes les prédictions dans la photo est correcte.

La plupart des prédictions ont des scores de confiance élevés (0,9 et plus), ce qui suggère que le modèle fonctionne bien sur l'ensemble de validation.

Le modèle semble fonctionner correctement sur l'ensemble de validation, avec des scores de confiance élevés indiquant une forte capacité prédictive. La variété des images de validation permet de garantir que le modèle est robuste et peut bien se généraliser à différentes instances des classes de piment sur lesquelles il a été formé.

V.1.3 Matrice de confusion




Figure VI.10: Matrice de confusion

V.1.3.1 Analyse des résultats

Le modèle montre une bonne performance globale avec une majorité de prédictions correctes pour la plupart des classes.

Quelques confusions sont observées, principalement entre les classes similaires comme les différentes parties des mêmes populations de piments (fruits et calices).

Ces résultats suggèrent que le modèle fonctionne bien.

V.1.4.L'évolution de diverses métriques de perte et de performance

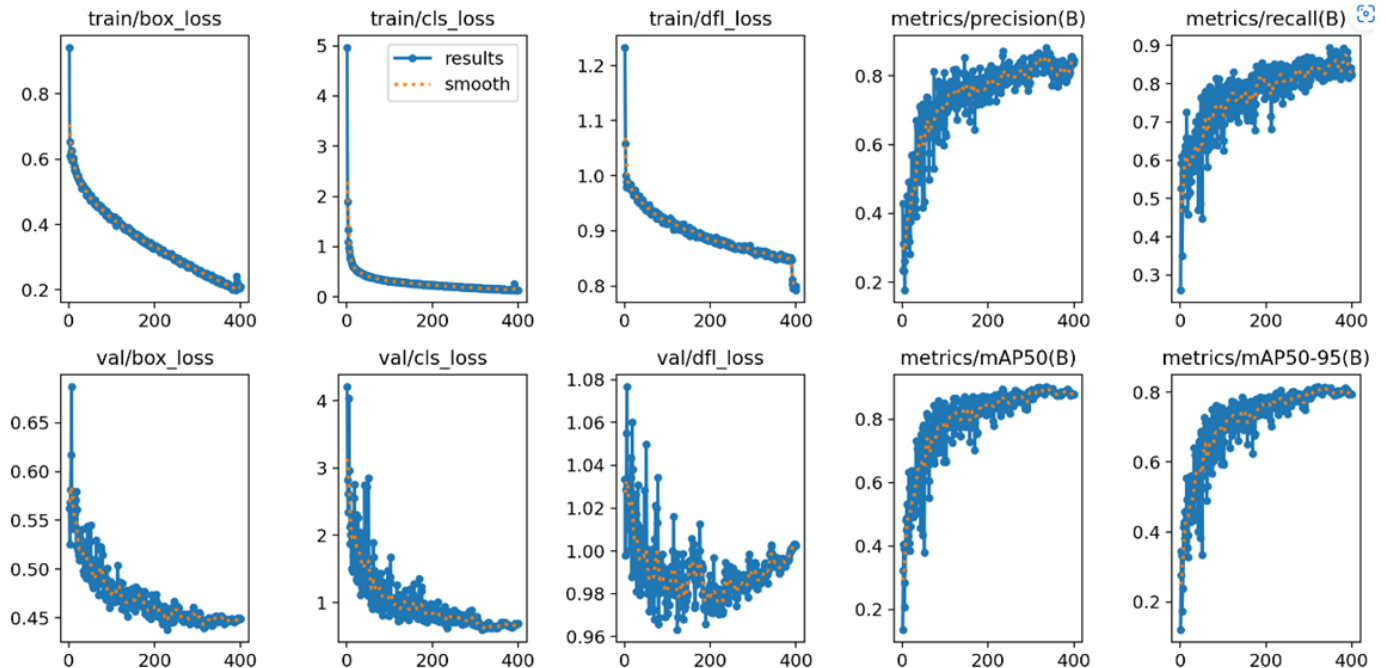


Figure VI.11 : Evolution de diverses métriques de perte et de performance au cours de l'entraînement du modèle YOLOv8s sur 400 epochs

Les graphiques affichés montrent l'évolution de diverses métriques de perte et de performance au cours de l'entraînement du modèle YOLOv8s sur 400 epochs.

V.1.4.1 Pertes d'entraînement (train loss) :

a. Train/box_loss : La perte de la boîte englobant (box loss) diminue de manière constante de 0.8 à environ 0.2, montrant que le modèle s'améliore dans la localisation des boîtes au cours du temps.

b. Train/cls_loss : La perte de classification (classification loss) diminue de 5 à environ 0.5, indiquant que le modèle devient de plus en plus précis dans la classification des objets.

c. Train/dfl_loss : La perte de la distance de distribution (distribution focal loss) diminue de 1.2 à environ 0.8, ce qui montre une amélioration continue dans l'alignement des prédictions avec les vraies valeurs.

V.2.5.1.2. Pertes de validation (validation loss) :

a. Val/box_loss : La perte de la boîte englobant de validation suit une tendance à la baisse similaire à celle de l'entraînement, indiquant que le modèle généralise bien à la validation.

b. Val/cls_loss : La perte de classification de validation diminue également de manière significative, bien qu'elle montre des fluctuations plus importantes, ce qui est normal pour les ensembles de validation.

c. Val/dfl_loss : La perte de la distance de distribution de validation diminue, mais présente aussi des fluctuations, reflétant la complexité de l'alignement des prédictions sur les données de validation.

V.2.5.1.3. Métriques de performance :

a. Metrics/precision : La précision augmente de manière constante pour atteindre environ 0.8, montrant que le modèle devient de plus en plus précis dans ses prédictions correctes par rapport à toutes les prédictions.

b. Metrics/recall : Le rappel augmente également pour atteindre environ 0.8, indiquant que le modèle identifie correctement une proportion croissante des objets présents dans les images.

c. Metrics/mAP50 : Le mAP à 50% d'IoU augmente pour atteindre environ 0.9, montrant une amélioration significative dans la précision moyenne des prédictions avec un seuil de 50% d'IoU.

d. Metrics/mAP50-95 : Le mAP moyen sur les IoU de 50% à 95% augmente de manière régulière pour atteindre environ 0.8, ce qui est un bon indicateur de la performance globale du modèle sur une large gamme de seuils d'IoU.

Les graphiques montrent que le modèle s'améliore constamment au cours des 400 epochs, tant en termes de réduction des pertes que d'augmentation des métriques de précision et de rappel. Les pertes de validation suivent de près les pertes d'entraînement, indiquant une bonne généralisation. Les valeurs élevées de mAP50 et mAP50-95 montrent une performance robuste du modèle dans la détection et la classification des différentes populations de piments. Ces résultats suggèrent que le modèle est bien entraîné et performant.

La reconnaissance est d'abord basée sur le fruit pour toutes les cultures c'est la confirmation que le fruit est l'organe qui renferme le plus la variation.

Une étude utilisant l'algorithme YOLOv4 pour la reconnaissance visuelle du piment, intégrant des améliorations telles que les données Mosaic et le mécanisme d'attention CBAM a été réalisée par (Liyang et al. 2023). Ces ajustements ont renforcé la capacité d'apprentissage du modèle, réduisant les interférences et accentuant l'attention sur les caractéristiques pertinentes. Le réseau ainsi amélioré a été entraîné, validé et testé sur un ensemble de données spécifiques, démontrant une amélioration significative de la précision de détection du poivre sous lumière naturelle. Enfin, l'amélioration a conduit à une augmentation notable de la précision moyenne (mAP) de l'algorithme YOLOv4, passant de 88,95 % à 98,36 %.

L'algorithme YOLOv4 amélioré atteint une précision moyenne très élevée de 98,36%, grâce à des techniques d'amélioration spécifiques. Pour notre travail, YOLOv8 a également atteint des niveaux élevés de précision, avec un mAP50 de 90% et un mAP50-95 de 80% lors des trois expérimentations réalisées, ce qui est très performant.

Conclusion Générale

Le développement de la science et de la technologie du traitement numérique des images ainsi que la vision par ordinateur fournissent une grande précision de discrimination pour les différentes variétés. Notre approche a fait appel à des modèles de classification des images et de reconnaissance d'objets pour reconnaître les populations locales de piments sur la base de leurs fruits.

Pour la classification des images des fruits de 09 variétés de piment étudiées utilisant le modèle DenseNet201, nous avons obtenu une amélioration continue des résultats de l'exactitude qui étaient de 85% pour la 1^{ère} configuration, de 93% pour la deuxième et, bien entendu, la meilleure précision a été obtenue lors de la dernière expérimentation où nous avons atteint une exactitude de 95 %.

Les résultats de la classification suivant le même modèle DenseNet201 basée sur les images de feuilles de 12 variétés étudiées ont révélé une performance légèrement inférieure avec une exactitude estimée à 89 % lors de la troisième configuration. Ceci montre la capacité du modèle dans la discrimination des différentes variétés de piment malgré les fortes similitudes phénotypiques au niveau des feuilles comparées aux fruits.

De plus, l'utilisation du modèle YOLOv8s pour la reconnaissance d'objets a également montré une performance remarquable, avec un mAP50 de 90 % et un mAP50-95 de 80 %. Ces performances indiquent que YOLOv8s est efficace pour la classification des populations de piments basées sur les fruits.

Notre approche de vision par ordinateur et d'apprentissage profond offre une solution rapide, objective et précise pour la classification et la conservation des variétés locales de piment en Algérie.

Après avoir examiné les résultats de trois configurations pour la classification d'images, nous confirmons en particulier la présence d'une variation génétique au sein des variétés de piment ainsi qu'entre elles, présentant un degré de variation important. Cela ouvre des perspectives pour leur classification et caractérisation fiables. Avec une exactitude de 95 % pour la classification des fruits et de 89 % pour les feuilles, nous confirmons que le fruit est l'organe qui renferme le plus de variations.

D'autre part, nous observons une ressemblance morphologique entre les fruits de certaines populations, ce qui pourrait s'expliquer par la proximité géographique des sites de collecte des semences. En effet, les variétés Sidi Ouane et Baadje proviennent toutes les deux d'El Oued, tandis que les variétés collectées des régions de Barika et de Tolga viennent respectivement de Barika (Batna) et Tolga (Biskra).

En règle générale, la reconnaissance des variétés est d'abord basée sur le fruit pour toutes les cultures, ce qui confirme que le fruit est l'organe le plus discriminant de toute la plante. La reconnaissance de la diversité génétique au sein des variétés de piment est un outil puissant pour son étude, en effet, la caractérisation variétale est la première étape de l'étude des ressources génétiques et c'est elle qui permet leur évaluation et valorisation antérieures. En effet, l'amélioration génétique est fondée sur la présence de traits agronomiquement intéressants d'où leur utilisation en sélection. Ceci est le premier pas vers l'assurance de la sécurité alimentaire en garantissant un approvisionnement durable en cultures résilientes et adaptées aux besoins changeants des populations et des environnements.

References

- Abdullahi, H. S., R. Sheriff, et al. (2017). Convolution neural network in precision agriculture for plant image recognition and classification. 2017 Seventh International Conference on Innovative Computing Technology (INTECH), Ieee New York.
- Abed, S. B., N. Dhen, et al. (2022). "Etude comparative des composés biochimiques de 12 accessions locales de piment (*Capsicum annuum* L.) des oasis tunisiennes." Journal of Oasis Agriculture and Sustainable Development **4**(2): 79-86.
- Agbodan, K., S. Akpavi, et al. (2020). "Description agromorphologique et détermination du potentiel antioxydant des variétés sous-utilisées et nouvellement introduites de maïs, manioc, niébé et piment dans la région maritime-Est du Togo." African Journal of Food, Agriculture, Nutrition and Development **20**(3): 15936-15953.
- Aherwadi, N., U. Mittal, et al. (2022). "Prediction of fruit maturity, quality, and its life using deep learning algorithms." Electronics **11**(24): 4100.
- Akaza, J. M., G. A. K. Yao, et al. (2022). "Caractérisation phénologique et morphologique de 18 accessions de piment piquant (*Capsicum* spp.) collectées dans la région du Haut-Sassandra en Côte d'Ivoire." International Journal of Innovation and Applied Studies **36**(1): 170-180.
- Albawi, S., T. A. Mohammed, et al. (2017). Understanding of a convolutional neural network. 2017 international conference on engineering and technology (ICET), Ieee.
- Anatya, S., V. C. Mawardi, et al. (2020). Fruit maturity classification using convolutional neural networks method. IOP Conference Series: Materials Science and Engineering, IOP Publishing.
- Andriessa Krause, P., M. Dotto, et al. (2023). "Phenological growth stages of biquinho pepper according to the BBCH scale." Acta Scientiarum: Biological Sciences **45**.
- AYA, D. (2022). "Une approche Deep Learning pour le diagnostic préalable de la tuberculose."
- Badache, S., 2015. Caractérisation des populations locales de piment (*Capsicum frutescens* L.) dans les conditions hydro-pédologiques des Ziban. moyennant des descripteurs quantitatifs.
- Bekele, F. and D. Butler "Source: Working procedures for cocoa germplasm evaluation and selection. Proceedings of the CFC/ICCO/IPGRI Project Workshop, Montpellier, France, 1-6 February, 1998 Proposed short list of cocoa descriptors for characterization."
- Bell, J. (2022). "What is machine learning?" Machine Learning and the City: Applications in Architecture and Urban Design: 207-216.

- Bracho-Gil, M., L. Pereira-Dias, et al. (2018). "Genetic diversity analysis and phylogenetic relationship among a representative collection of Spanish pepper (*Capsicum annuum*) landraces."
- Briouya, H., A. Briouya, et al. (2024). "Exploration of image and 3D data segmentation methods: an exhaustive survey." TELKOMNIKA (Telecommunication Computing Electronics and Control) **22**(2): 413-426.
- Casado-García, A., A. Del-Canto, et al. (2020). "LabelStoma: A tool for stomata detection based on the YOLO algorithm." Computers and Electronics in Agriculture **178**: 105751.
- CHEMLAL, A. (2018). Caractérisation agro-morphologique de huit variétés locales de piment (*Capsicum annuum* L.) cultivées sous abri-serre.
- COSTA, G., D. NASCIMENTO, et al. (2019). "Selection of pepper accessions with ornamental potential." Revista Caatinga **32**: 566-574.
- Darwish, M. (2020). Fruit Classification Using Covolutional Neural Network, PhD dissertation, Dept. Comp. Eng., Near East University.
- DE MATTEIS, L., S. Janny, et al. (2022). Introduction à l'apprentissage automatique.
- de Vault, R. D., D. Chambonnet, et al. (1981). "Culture in vitro d'anthères de piment (*Capsicum annuum* L.): amélioration des taux d'obtention de plantes chez différents génotypes par des traitements à + 35° C." Agronomie **1**(10): 859-864.
- Dumas de Vault, R. and E. Pochard (1974). Essai d'induction de la parthenogenese haploide par action du protoxyde d'azote sur les fleurs de piments (*Capsicum Annum* L.). Annales de l'amelioration des plantes.
- El Sakka, M., J. Mothe, et al. (2024). "Images and CNN applications in smart agriculture." European Journal of Remote Sensing **57**(1): 2352386.
- Ertel, W. (2018). Introduction to artificial intelligence, Springer.
- ETTARID, P. M., P. I. SEBARI, et al. (2021). "Apport des algorithmes d'apprentissage supervisé pour la cartographie intelligente des zones irriguées à partir des images satellite à haute résolution spatiale."
- Fetzer, J. H. (1990). What is artificial intelligence?, Springer.
- Fondio . L et all ,2009 - Bien cultiver le piment Ed, centre technique national de recherche agronomique,Coted Ivoire.
- Guillard, F. (1901). Les piments des solanées: Etude historique et botanique des piments du genre capsicum, imprimerie et lithographie L. Declume.

- Glenn J., Rizwan M., Abirami V, 2023. <https://docs.ultralytics.com/fr/guides/yolo-performance-metrics>.
- He, Y. and T. Li (2020). A lightweight CNN model and its application in intelligent practical teaching evaluation. MATEC Web of Conferences, EDP Sciences.
- HIROSE, T. and Y. FUJIME (1980). "ETUDE DE LA PRODUCTION DE SEMENCES PAR UN HYBRIDE PROVENANT D'UNE LIGNEE MALE STERILE CHEZ LE PIMENT (*CAPSICUM ANNUUM* L.). I. MORPHOLOGIE ET TRANSMISSION HEREDITAIRE."
- Horaud, R. and O. Monga (1995). Vision par ordinateur: outils fondamentaux, Editions Hermès.
- Horng, G.-J., M.-X. Liu, et al. (2019). "The smart image recognition mechanism for crop harvesting system in intelligent agriculture." IEEE Sensors Journal **20**(5): 2766-2781.
- Hou, C., X. Zhang, et al. (2022). "Detection and localization of citrus fruit based on improved You Only Look Once v5s and binocular vision in the orchard." Frontiers in Plant Science **13**: 972445.
- Islam, M. K., S. U. Habiba, et al. (2019). Bangladeshi plant leaf classification and recognition using YOLO neural network. 2019 2nd International Conference on Innovation in Engineering and Technology (ICIET), IEEE.
- ITCM., 2010 .fiches techniques valorisées des maraîchères et industrielles.
- ITCM., 2022. La culture du PIMENT / POIVRON.
- Jakubec, M., E. Lieskovská, et al. (2023). "Comparison of CNN-based models for pothole detection in real-world adverse conditions: overview and evaluation." Applied Sciences **13**(9): 5810.
- Karakaya, M., M. F. Celebi, et al. (2022). "Discovery of agricultural diseases by deep learning and object detection." Environmental Engineering & Management Journal (EEMJ) **21**(1).
- Kelleher, J. D. (2019). Deep learning, MIT press.
- Kumar, M., M. Aeri, et al. (2024). Federated Learning CNN for Smart Agriculture: A Modeling for Soybean Disease Detection. 2024 IEEE International Conference on Interdisciplinary Approaches in Technology and Management for Social Innovation (IATMSI), IEEE.
- Kundu, N., G. Rani, et al. (2021). Seeds classification and quality testing using deep learning and YOLO v5. Proceedings of the International Conference on Data Science, Machine Learning and Artificial Intelligence.

- LeCun, Y., Y. Bengio, et al. (2015). "Deep learning." nature **521**(7553): 436-444.
- Li, Z., X. Jiang, et al. (2022). "A real-time detection algorithm for sweet cherry fruit maturity based on YOLOX in the natural environment." Agronomy **12**(10): 2482.
- Lu, W., X. Wang, et al. (2019). "Adaptive minirhizotron for pepper roots observation and its installation based on root system architecture traits." Plant Methods **15**: 1-14.
- Maaouia-Houimli, S. I., M. Denden, et al. (2011). "Caractéristiques de la croissance et de la production en fruits chez trois variétés de piment (*Capsicum annuum* L.) sous stress salin." Tropicultura **29**(2): 75-81.
- Mahesh, B. (2020). "Machine learning algorithms-a review." International Journal of Science and Research (IJSR).[Internet] **9**(1): 381-386.
- Maheswari, R. (2015). Evaluation of long pepper (Piper longum L) genotypes for growth flowering and yield, Department of Plantation Crops and Spices, College of Horticulture, Vellanikkara.
- Massanes, F. and J. G. Brankov (2017). Evaluation of CNN as anthropomorphic model observer. Medical Imaging 2017: Image Perception, Observer Performance, and Technology Assessment, SPIE.
- Mathew, M. P. and T. Y. Mahesh (2022). "Leaf-based disease detection in bell pepper plant using YOLO v5." Signal, Image and Video Processing: 1-7.
- MECIRDI, Y. (2023). "PLANT DOCTOR développement d'un système intelligent pour le diagnostic des maladies des plantes."
- Meliani, S. and M. K. Harche (2020). "Etude de la germination, morphologie et physiologie de quatre variétés de piment (*Capsicum annuum* L.)(Piment piquillo, Piment grec, Poivron california wonder, Peperone quadrato d'asti rosso)." International Journal of Innovation and Applied Studies **29**(4): 1064-1076.
- Michel, N. A., A. B. Justine, et al. (2022). "Comparative Study of the Physicochemical Properties, of the minerals of two varieties of *Capsicum annuum*: The Hot Pepper and the Sweet Pepper cultivated in Korhogo in the North of Côte d'Ivoire." International Journal of Environment, Agriculture and Biotechnology **7**: 2.
- Minh Trieu, N. and N. T. Thinh (2021). "Quality classification of dragon fruits based on external performance using a convolutional neural network." Applied Sciences **11**(22): 10558.

- Molot, P. M., P. Mas, et al. (1982). "La résistance du piment (*Capsicum annuum*) à *Phytophthora capsici*. IX. Distribution spatio-temporelle du capsidiol dans les tiges infectées." Agronomie **2**(9): 865-869.
- O'shea, K. and R. Nash (2015). "An introduction to convolutional neural networks." arXiv preprint arXiv:1511.08458.
- Parada, A. and H. Cyr (2022). "Normativité et intelligence artificielle." Communitas **3**(1).
- Pastre, D. (2000). "L'INTELLIGENCE ARTIFICIELLE DEFINITION-GENERALITES-HISTORIQUE-DOMAINES." Intelligence artificielle, Université Paris **5**.
- Pérez-Porras, F. J., J. Torres-Sánchez, et al. (2023). "Early and on-ground image-based detection of poppy (*Papaver rhoeas*) in wheat using YOLO architectures." Weed Science **71**(1): 50-58.
- Rigal, L., J. Chopin, et al. (2020). "Apprentissage profond et localisation d'objets: deux exemples d'applications en agriculture." RJCIA: 93.
- Sabzi, S., R. Pourdarbani, et al. (2020). "A computer vision system for the automatic classification of five varieties of tree leaf images." Computers **9**(1): 6.
- Safa, B. A., D. Najla, et al. (2022). "Comparative study of the biochemical compounds of 12 local pepper accessions (*Capsicum annuum* L.) of Tunisian oases."
- Shetty, K. U., R. J. Kutty, et al. (2024). Plant Disease Detection for Guava and Mango using YOLO and Faster R-CNN. 2024 IEEE International Conference on Interdisciplinary Approaches in Technology and Management for Social Innovation (IATMSI), IEEE.
- Silva, W. C., S. I. C. de Carvalho, et al. (2013). "Identification of minimum descriptors for characterization of *Capsicum* spp. germplasm." Horticultura Brasileira **31**: 190-202.
- Sozzi, M., S. Cantalamessa, et al. (2022). "Automatic bunch detection in white grape varieties using YOLOv3, YOLOv4, and YOLOv5 deep learning algorithms." Agronomy **12**(2): 319.
- Suwarningsih, W., P. H. Khotimah, et al. (2022). "Ide-cabe: chili varieties identification and classification system based leaf." Bulletin of Electrical Engineering and Informatics **11**(1): 445-453.
- Tan, Z., Chen, B., Sun, L., Xu, H., Zhang, K., Chen, F. (2023). Pepper Target Recognition and Detection Based on Improved YOLO v4. Information Technology and Control, **52**(4), 878-886. <https://doi.org/10.5755/j01.itc.52.4.34183>

- Yuan, X., L. Huang, et al. (2024). "Quality prediction modeling for industrial processes using multiscale attention-based convolutional neural network." IEEE Transactions on Cybernetics.
- Zhang, P. and D. Li (2022). "EPSA-YOLO-V5s: A novel method for detecting the survival rate of rapeseed in a plant factory based on multiple guarantee mechanisms." Computers and Electronics in Agriculture **193**: 106714.
- Zhang, P. and D. Li (2022). "YOLO-VOLO-LS: a novel method for variety identification of early lettuce seedlings." Frontiers in Plant Science **13**: 806878.
- Zhao, H., Z. Tang, et al. (2024). "Real-time object detection and robotic manipulation for agriculture using a YOLO-based learning approach." arXiv preprint arXiv:2401.15785.