



**HAL**  
open science

# Système d'aide pour améliorer la qualité des récoltes de café et du cacao à l'aide de l'intelligence artificielle

Kacoutchy Jean Ayikpa

► **To cite this version:**

Kacoutchy Jean Ayikpa. Système d'aide pour améliorer la qualité des récoltes de café et du cacao à l'aide de l'intelligence artificielle. Traitement du signal et de l'image [eess.SP]. Université Bourgogne Franche-Comté; Université Félix Houphouët-Boigny (Abidjan, Côte d'Ivoire), 2023. Français. NNT : 2023UBFCK069 . tel-04607767

**HAL Id: tel-04607767**

**<https://theses.hal.science/tel-04607767v1>**

Submitted on 11 Jun 2024

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



**THESE DE DOCTORAT DE L'UNIVERSITE BOURGOGNE FRANCHE-COMTE  
PREPAREE A UNIVERSITE DE BOURGOGNE**

Ecole doctorale n° 131571

Ecole doctorale Sciences Pour l'Ingénieur et Microtechniques

Doctorat de Instrumentation et Informatique de l'Image

Par

M. AYIKPA Kacoutchy Jean

Système d'aide pour améliorer la qualité des récoltes de café et du cacao à l'aide de  
l'intelligence artificielle

Thèse présentée et soutenue à Abidjan, le 17/08/2023

Composition du Jury :

M. ORIA Vincent	Professeur, NEW JERSEY INSTITUTE OF TECHNOLOGY USA	Président
M. JACQUIR Sabir	Professeur, Université PARIS SACLAY	Rapporteur
M. AHOUANDJINOU Martial	Maître de Conférence, Université ABOMEY-CALAVI	Rapporteur
M. DIABY Moustapha	Maître de Conférence, ESATIC Abidjan - Côte d'Ivoire	Examineur
M. GOUTON Pierre	Professeur, Université de BOURGOGNE	Directeur de thèse
M. ADOU Kablan Jérôme	Professeur, Université FÉLIX HOUPHOUËT-BOIGNY	Codirecteur de thèse
M. MAMADOU Diarra	Maître Assistant, Université FÉLIX HOUPHOUËT-BOIGNY	Encadrant

## **Dédicace**

Je dédie cette thèse à :

À mes parents, qui m'ont toujours soutenu et encouragé dans mes études, et qui ont été une source constante de force et de motivation tout au long de ce parcours. Leur amour et leur soutien inconditionnels ont été la clé de ma réussite, et je leur suis éternellement reconnaissant.

À ma merveilleuse épouse, KOUASSI Adjoua Patricia, qui a été mon plus grand soutien tout au long de cette aventure. Son amour inconditionnel, sa patience et son encouragement ont été essentiels pour me permettre de réaliser ce projet.

À mes chers enfants, dont l'amour et la présence ont illuminé mes journées et m'ont donné la motivation de continuer, même dans les moments les plus difficiles.

## Remerciements

Ce travail ne peut être considéré comme le fruit d'un travail individuel, car il a bénéficié de l'apport et de la contribution de nombreuses personnes. En effet, plusieurs in ont apporté leur expertise, leur soutien et leur encouragement tout au long de la réalisation de ce projet. Par conséquent, je souhaite exprimer ma reconnaissance envers :

les Présidents des Universités Félix Houphouët-Boigny, de Bourgogne Franche-Comté et de Bourgogne pour avoir établi la convention de cotutelle de thèse entre ces deux universités, qui a permis la réalisation de ce travail dans des conditions optimales ;

les membres du jury qui ont accepté de juger ce travail et dont les remarques et les critiques constructives ont permis d'enrichir et de consolider les résultats de cette recherche ;

le Professeur KONE Tiémoman, Directeur Général de l'Université Virtuelle de Côte d'Ivoire (UVCI), pour son dévouement et son soutien constant tout au long de cette thèse ;

mes Directeurs de thèse, les Professeurs GOUTON Pierre, ADOU Kablan Jérôme ainsi que mon encadrant MAMADOU Diarra, pour leur expertise, leur encadrement rigoureux et leurs précieux conseils qui ont été déterminants dans la réussite de mon travail ;

le Professeur KOUAME Fernand, Directeur académique de l'UVCI, pour ses conseils éclairés et son soutien indéfectible ;

les Sous-Directeurs, Responsables de laboratoires et Responsables de spécialité de l'UVCI pour leur contribution et leur collaboration fructueuse ;

les collègues enseignants-chercheurs, les doctorants et le personnel administratif et technique des Universités de Bourgogne, Félix Houphouët-Boigny et de l'UVCI pour leur aide précieuse ;

M. Abou Bakary BALLO pour sa contribution à la mise en place des bases de données et pour son expertise précieuse qui a grandement amélioré la qualité de cette thèse ;

M. et Mme AHO, qui ont été des sources d'inspiration, de soutien et d'encouragement, qui ont été essentiels pour ma réussite.

Enfin, toutes les personnes qui ont participé, même de manière indirecte, à la réalisation de ce travail, et dont les contributions ont été déterminantes.

## Résumé

Cette thèse propose six contributions importantes dans le domaine de l'analyse de données pour les cultures de café et de cacao. Les résultats ont été présentés lors de conférences internationales et publiés dans des revues à comité de lecture.

Premièrement, une méthode de classification et de reconnaissance de maladies des feuilles de café a été développée en utilisant des techniques de Machine Learning et de Deep Learning. Une base de données d'image publique de maladies de feuilles de café a été prétraitée pour être utilisée dans les algorithmes, permettant ainsi aux producteurs de café de mieux protéger leurs cultures.

Deuxièmement, des bases de données dédiées au cacao ont été créées, comprenant des images couleur et multispectrales du cacao. Ces bases de données permettent de stocker et de récupérer efficacement des informations sur les caractéristiques du cacao, facilitant ainsi l'analyse et la compréhension.

Troisièmement, des techniques de Deep Learning ont permis de détecter et extraire les cabosses de cacao en milieu naturel. Cela permet une séparation efficace des cabosses de cacao des autres éléments présents dans l'environnement, ainsi qu'une détection précoce de maladies qui pourraient affecter les cabosses. Les agriculteurs peuvent ainsi maximiser la production de cacao tout en minimisant les pertes causées par les maladies et les erreurs de cueillette.

Quatrièmement, une méthode hybride a été proposée pour classer les fèves de cacao en fonction de leur degré de fermentation. Cette méthode combine des réseaux de neurones à convolution, des machines à vecteur de support et de l'analyse en composantes principales pour permettre une sélection efficace des meilleures fèves pour obtenir des produits de qualité supérieure.

Cinquièmement, une méthode de fusion des espaces de couleur a été développée pour déterminer l'état de maturité des cabosses de cacao. Des espaces de couleur différents tels que RGB (Red, Green, Blue) et HSV (Hue, Saturation, Value) ont été combinés pour obtenir une représentation plus complète de l'image, permettant une classification efficace de l'état de maturité.

Enfin, une autre méthode pour classifier la maturité des cabosses de cacao à partir d'une base de données d'images a été développée en utilisant des extracteurs de caractéristiques basés sur la texture et sur le Deep Learning. Cette méthode a été évaluée en utilisant des mesures de similarités dans différents espaces couleurs afin de déterminer sa

performance. Les résultats obtenus ont permis de comparer les différentes expériences et de déterminer la méthode la plus efficace pour classifier la maturité des cabosses de cacao à partir d'images.

Ces contributions ont permis d'utiliser les techniques les plus avancées de Machine Learning et de Deep Learning pour analyser et comprendre les cultures de café et de cacao, facilitant ainsi la prise de décisions pour les producteurs de ces cultures.

**Mots-clés:** Machine Learning; Deep Learning; Cacao; Café; Espaces couleurs; Agriculture intelligente.

## Abstract

This thesis proposes six essential contributions to the field of data analysis for coffee and cocoa crops. The results have been presented at international conferences and published in peer-reviewed journals.

First, a method for classifying and recognizing coffee leaf diseases was developed using machine learning and deep learning techniques. A public database of coffee leaf diseases has been pre-processed for use in the algorithms, allowing coffee growers to protect their crops better.

Second, databases dedicated to cocoa have been created, including color and multispectral images of cocoa. These databases allow efficient storage and retrieval of information on cocoa characteristics, facilitating analysis and understanding.

Third, deep learning techniques were used to detect and extract cocoa pods in the wild. This allows efficient separation of cocoa pods from other environmental elements and early detection of diseases that could affect the pods. Farmers can thus maximize cocoa production while minimizing losses caused by disease and picking errors.

Fourth, a hybrid method has been proposed to classify cocoa beans according to their degree of fermentation. This method combines convolutional neural networks, support vector machines, and principal component analysis to efficiently select the best beans to obtain superior products.

Fifth, a color space fusion method was developed to determine the ripeness status of cocoa pods. Different color spaces such as RGB (Red, Green, Blue) and HSV (Hue, Saturation, Value) have been combined to achieve a complete image representation, enabling efficient classification of maturity status.

Finally, another method to classify the maturity of cocoa pods from an image database was developed using texture-based feature extractors and Deep Learning. This method has been adapted using similarity measures in different color spaces to determine its performance. The results made it possible to compare the different experiments and select the most effective method for classifying the maturity of cocoa pods from images.

These contributions have made it possible to use the most advanced machine learning and deep learning techniques to analyze and understand coffee and cocoa crops, thus facilitating decision-making for the producers of these crops.

**Keywords:** Machine Learning, Deep Learning, Cocoa, Coffee, Color space, Smart Agriculture.

## Liste des tableaux

<b>Tableau 1</b> : Répartition du jeu de données .....	36
<b>Tableau 2</b> : Hyperparamètres des algorithmes du CNN.....	49
<b>Tableau 3</b> : Résultats de l'apprentissage et validation des modèles pour chaque K-Folds.....	51
<b>Tableau 4</b> : Résultats de la phase de test.....	51
<b>Tableau 5</b> : Courbe ROC et la matrice de confusion de chaque modèle .....	52
<b>Tableau 6</b> : Performance de chaque CNN pour validation et test.....	54
<b>Tableau 7</b> : Illustration des courbes de pertes, de précisions et des matrices de confusion....	55
<b>Tableau 8</b> : Mesures de performances des algorithmes d'apprentissage automatique .....	56
<b>Tableau 9</b> : Mesures de performances des algorithmes de réseau de neurones convolutifs ...	57
<b>Tableau 10</b> : Résumé des données sur les cabosses de cacao .....	62
<b>Tableau 11</b> : Résumé des données sur les fèves de cacao.....	69
<b>Tableau 12</b> : Description des images multispectrales .....	71
<b>Tableau 13</b> : Longueur d'onde des caméras du visible et du proche infrarouge .....	71
<b>Tableau 14</b> : Mesure spectrale des échantillons des fèves la catégorie 1. ....	76
<b>Tableau 15</b> : Mesure dans l'espace Lab des échantillons des fèves la catégorie 1.....	77
<b>Tableau 16</b> : Mesure spectrale des échantillons des fèves la catégorie 2 .....	78
<b>Tableau 17</b> : Mesure dans l'espace Lab des échantillons des fèves la catégorie 2.....	79
<b>Tableau 18</b> : Mesure spectrale des échantillons des fèves la catégorie 3 .....	81
<b>Tableau 19</b> : Mesure dans l'espace Lab des échantillons des fèves la catégorie 3.....	82
<b>Tableau 20</b> : Performance de la phase d'entraînement et de validation .....	91
<b>Tableau 21</b> : Courbe Accuracy et Loss de chaque modèle lors de l'étape d'apprentissage.....	92
<b>Tableau 22</b> : Récapitulatif des résultats des métriques lors de la phase de test du modèle.....	93
<b>Tableau 23</b> : Echantillons des résultats de test.....	94
<b>Tableau 24</b> : Description de l'architecture du CNN .....	102
<b>Tableau 25</b> : Performance générale du classificateur Softmax .....	106
<b>Tableau 26</b> : Performances générales du SVM.....	108
<b>Tableau 27</b> : Performances générales du CNN avec SVM .....	110
<b>Tableau 28</b> : Performances générales du PCA avec SVM.....	112
<b>Tableau 29</b> : Comparaison des performances des méthodes .....	114
<b>Tableau 30</b> : Comparaison avec d'autres travaux .....	115
<b>Tableau 31</b> : Comparaison des performances des différentes méthodes utilisées .....	122
<b>Tableau 32</b> : Courbe ROC et matrice de confusion .....	123
<b>Tableau 33</b> : Comparaison avec les autres travaux .....	124
<b>Tableau 34</b> : Evaluation des performances des algorithmes en RGB avec le CNN-MobileNet .....	138
<b>Tableau 35</b> : Evaluation des performances des algorithmes en RGB avec le GCLM .....	139
<b>Tableau 36</b> : Evaluation des performances des algorithmes en HSV avec le CNN-MobileNet .....	141
<b>Tableau 37</b> : Evaluation des performances des algorithmes en HSV avec le GCLM .....	142
<b>Tableau 38</b> : Evaluation des performances des algorithmes en Luv avec le CNN-MobileNet .....	143
<b>Tableau 39</b> : Evaluation des performances des algorithmes en Luv avec le GCLM.....	145
<b>Tableau 40</b> : Evaluation des performances des algorithmes en Lab avec le CNN-MobileNet .....	146
<b>Tableau 41</b> : Evaluation des performances des algorithmes en Lab avec le GCLM .....	147



<b>Tableau 42:</b> tableau qui synthétise les résultats de nos caractéristiques dans différents espaces de couleurs.....	149
<b>Tableau 43 :</b> Comparaison des travaux .....	150

## Liste de figures

<b>Figure 1</b> : Image des cafés Arabica et Robusta .....	15
<b>Figure 2</b> : Zone de production du café en Côte d'Ivoire.....	17
<b>Figure 3</b> : Images des cabosses de cacao.....	18
<b>Figure 4</b> : Représentation de la production de cacao en Côte d'Ivoire.....	21
<b>Figure 5</b> : Cube représentant les composantes du RGB .....	24
<b>Figure 6</b> : Cône représentant les composantes du HSV .....	24
<b>Figure 7</b> : Représentation des composantes de l'espace Lab.....	25
<b>Figure 8</b> : Image aérienne de plantation .....	28
<b>Figure 10</b> : Image satellitaire.....	29
<b>Figure 10</b> : Image multispectrale.....	30
<b>Figure 11</b> : Image thermique de culture .....	31
<b>Figure 12</b> : Échantillons d'images des différentes maladies de la feuille de café : (a) Cercospora ; (b) Healthy ; (c) Leaf rust ; (d) Phoma.....	36
<b>Figure 13</b> : L'architecture de MobileNet applique notre étude .....	44
<b>Figure 14</b> : L'architecture de VGG-19 applique notre étude.....	44
<b>Figure 15</b> : L'architecture d'Inception-V3 applique notre étude.....	45
<b>Figure 16</b> : Architecture de DenseNet-201 appliquée notre étude .....	46
<b>Figure 17</b> : Architecture de ResNet-50 appliquée notre étude .....	46
<b>Figure 18</b> : Architecture du CNN personnalisé .....	47
<b>Figure 19</b> : Architecture générale de notre méthodologie d'étude .....	47
<b>Figure 20</b> : Illustration de la validation croisée (K-Fold).....	48
<b>Figure 21</b> : Images de cabosses de Amelonado (A) : cabosse de Amelonado mûres ; (B) : cabosses de Amelonado non mûres.....	60
<b>Figure 22</b> : Images de cabosses de Angoleta (A) : cabosses de Angoleta mûres ; (B) : cabosses de Angoleta non mûres.....	60
<b>Figure 23</b> : Images de cabosses de Guyane (A) : Cabosses de Guyane mûres ; (B) : Cabosses de Guyane immatures.....	61
<b>Figure 24</b> : Structure du jeu de données d'images couleurs des cabosses de cacao. ....	61
<b>Figure 25</b> : Histogramme du résumé des données sur le cacao.....	62
<b>Figure 26</b> : Schéma du processus d'amélioration de l'image.....	63
<b>Figure 27</b> : Conversion d'images RGB en images Lab. ....	64
<b>Figure 28</b> : Séparation des différents canaux des images Lab. ....	64
<b>Figure 29</b> : Image et histogramme du canal L avant et après application de l'algorithme CLAHE.....	65
<b>Figure 30</b> : Fusion des canaux L, a et b pour obtenir une nouvelle image dans l'espace colorimétrique Lab. ....	65
<b>Figure 31</b> : Conversion des images de l'espace colorimétrique Lab vers l'espace colorimétrique RGB .....	66
<b>Figure 32</b> : Annotation de cabosse de cacao. (A) image annotée. (B) Document XML.....	66
<b>Figure 33</b> : Fèves de la catégorie 1.....	67
<b>Figure 34</b> : Fèves de la catégorie 2.....	68
<b>Figure 35</b> : Fèves de la catégorie 3.....	68
<b>Figure 36</b> : Structure du jeu de données d'images couleurs des fèves de cacao .....	69
<b>Figure 37</b> : L'histogramme du résumé des fèves .....	69
<b>Figure 38</b> : Quelques images dans diverses longueurs d'onde .....	70

<b>Figure 39</b> : Avant et après recadrage d'images de cabosses multispectrales .....	71
<b>Figure 40</b> : Structure du jeu de données d'images multispectrale des cabosses de cacao. ....	72
<b>Figure 41</b> : Quelques images de fèves avec la caméra du visible .....	73
<b>Figure 42</b> : Quelques images de fèves avec la caméra du proche infrarouge.....	74
<b>Figure 43</b> : Manipe des mesures spectrales des fèves de cacao en salle blanche.....	75
<b>Figure 44</b> : Graphique des mesures spectrales des échantillons des fèves la catégorie 1 .....	77
<b>Figure 45</b> : Graphique mesure dans l'espace Lab des échantillons des fèves la catégorie 1 ...	78
<b>Figure 46</b> : Graphique mesure dans l'espace Lab des échantillons des fèves la catégorie 2 ...	79
<b>Figure 47</b> : Graphique des mesures dans l'espace Lab des échantillons des fèves la catégorie 2 .....	80
<b>Figure 48</b> : Graphique des mesures dans l'espace Lab des échantillons des fèves la catégorie 3 .....	82
<b>Figure 49</b> : Graphique des mesures dans l'espace Lab des échantillons des fèves la catégorie 3 .....	83
<b>Figure 50</b> : Processus de création des masques des cabosses de cacao.....	87
<b>Figure 51</b> : Architecture de U-NET.....	88
<b>Figure 52</b> : Architecture de FCN.....	89
<b>Figure 53</b> : Architecture de la méthodologie de la détection et extraction des cabosses .....	90
<b>Figure 54</b> : Histogramme des performances de la phase de validation .....	92
<b>Figure 55</b> : Histogramme des performances de la phase de test .....	93
<b>Figure 56</b> : Images des trois catégories de fèves de cacao .....	99
<b>Figure 57</b> : Pré-traitement et extraction des fèves de cacao .....	101
<b>Figure 59</b> : Architecture générale de la classification des fèves de cacao .....	106
<b>Figure 59</b> : Illustration des courbes Loss et Accuracy .....	107
<b>Figure 61</b> : Matrice de confusion des optimiseurs de Softmax .....	108
<b>Figure 60</b> : Histogramme des performances des optimiseurs .....	108
<b>Figure 62</b> : Histogramme des performances du SVM.....	109
<b>Figure 63</b> : Matrice de confusion du SVM.....	110
<b>Figure 64</b> : Matrice de confusion des différents paramètres du modèle hybride CNN - SVM .....	111
<b>Figure 65</b> : Histogramme des performances des paramètres avec CNN - SVM.....	111
<b>Figure 66</b> : Histogramme des performances des paramètres avec PCA - SVM .....	113
<b>Figure 67</b> : Matrice de confusion des différents paramètres du modèle PCA - SVM.....	113
<b>Figure 69</b> : Histogramme des performances des méthodes de notre étude .....	115
<b>Figure 69</b> : Histogramme des performances des méthodes de notre étude et de la littérature .....	116
<b>Figure 70</b> : (A) cabosse mature ; (B) cabosse non mature ; (C) cabosse mature et non mature .....	120
La méthodologie est représentée par la figure 71 ci – dessous : .....	121
<b>Figure 71</b> : Architecture du modèle de prédiction de la maturité des cabosses de cacao ....	121
<b>Figure 73</b> : Histogramme des valeurs métriques.....	124
<b>Figure 74</b> : Image originale et image issu de l'augmentation .....	130
<b>Figure 75</b> : Processus d'extraction de caractéristique avec le GCLM .....	132
<b>Figure 76</b> : Illustration of MobileNet CNN Feature Extraction .....	134
<b>Figure 77</b> : Architecture Générale de la méthodologie d'analyse des cabosses de cacao ....	137
<b>Figure 78</b> : Matrice de confusion et courbe ROC de l'extracteur CNN-MobileNet .....	139
<b>Figure 79</b> : Matrice de confusion et courbe ROC de l'extracteur GCLM.....	140

<b>Figure 80</b> : Matrice de confusion et courbe ROC de l'extracteur CNN-MobileNet en HSV	142
<b>Figure 81</b> : Matrice de confusion et courbe ROC de l'extracteur GCLM en HSV.....	143
<b>Figure 82</b> : Matrice de confusion et courbe ROC de l'extracteur CNN en Luv .....	144
<b>Figure 83</b> : Matrice de confusion et courbe ROC de l'extracteur GCLM en Luv .....	146
<b>Figure 84</b> : Matrice de confusion et courbe ROC de l'extracteur CNN en Lab.....	147
<b>Figure 85</b> : Matrice de confusion et courbe ROC de l'extracteur GCLM en Lab.....	149

## Liste des abréviations

<b>Abréviation</b>	<b>Signification</b>
<b>RGB</b>	Red Green Blue
<b>HSV</b>	Hue Saturation Value
<b>CNN</b>	Convolutional Neural Network
<b>GCLM</b>	Gray Level Co-occurrence Matrix
<b>IA</b>	Intelligence Artificiel
<b>Lab</b>	Lightness Green-Red Blue-Yellow
<b>Luv</b>	Lightness Green-Red Blue-Yellow
<b>SVM</b>	Support Vector Machine
<b>K-NN</b>	K-Nearest Neighbors
<b>RF</b>	Random Forest
<b>LR</b>	Logic Regression
<b>MLP</b>	Multi-layer Perceptron
<b>DT</b>	Decision Tree
<b>SGD</b>	Stochastic Gradient Descent
<b>GNB</b>	Gaussian Naive Bayes
<b>FCN</b>	Fully Convolutional Network
<b>IoU</b>	Intersection over Union
<b>PCA</b>	Principal Component Analysis
<b>MSE</b>	Mean Squared Error
<b>MCC</b>	Matthews Correlation Coefficient
<b>CIE</b>	Commission internationale de l'éclairage
<b>ML</b>	Machine Learning
<b>DL</b>	Deep Learning

# Sommaire

Dédicace.....	I
Remerciements .....	II
Résumé .....	III
Abstract .....	V
Liste des tableaux .....	VI
Liste de figures.....	VIII
Liste des abréviations.....	XI
Sommaire .....	XII
<b>Introduction générale.....</b>	<b>1</b>
1. Contexte et motivation .....	1
2. Objectif.....	2
3. Contribution .....	2
4. Liste des publications .....	4
5. Organisation de la thèse .....	5
<b>Chapitre 1 : Etat de l’art .....</b>	<b>7</b>
Introduction .....	7
1.1. Intelligence artificielle (IA).....	7
1.2. Machine Learning (ML).....	10
1.3. Deep Learning (DL) .....	12
1.4. Café .....	15
1.5. Cacao .....	18
1.6. Production du cacao en Côte d’Ivoire.....	20
1.7. Espaces couleurs.....	22
1.8. Imagerie numérique dans le domaine de l’agriculture .....	27
Conclusion.....	32
<b>Chapitre 2 : Classification et reconnaissance des maladies des feuilles de café à l’aide des algorithmes du Machine Learning et du Deep Learning.....</b>	<b>33</b>
Introduction .....	33
2.1. Généralité .....	33
2.2. Jeu de données.....	35
2.3. Algorithmes d’apprentissage automatique .....	36
2.4. Algorithmes de réseaux de neurones convolutifs (CNN).....	42
2.5. Méthodologie de l’étude.....	47
2.6. Paramétrage .....	48

2.7. Résultats expérimentaux .....	50
Conclusion.....	58
<b>Chapitre 3 : Mise en place d'une base de données d'images de cabosses et de fèves de cacao .....</b>	<b>59</b>
Introduction .....	59
3.1. Base de données d'images couleur sur le cacao.....	59
3.2. Base de données d'images multispectrales .....	69
Conclusion.....	83
<b>Chapitre 4 : Détection et extraction des cabosses de cacao en milieu naturel avec des méthodes de Deep Learning .....</b>	<b>84</b>
Introduction .....	84
4.1. Généralité .....	84
4.2. Collecte et annotation des jeux de données.....	86
4.3. Algorithme de U-NET.....	87
4.4. Algorithme de Fully Convolutional Network (FCN) .....	88
4.5. Méthodologie de l'étude.....	89
4.6. Résultats expérimentaux .....	90
Conclusion.....	95
<b>Chapitre 5 : Classification des fèves de cacao par couplage de méthodes .....</b>	<b>96</b>
Introduction .....	96
5.1. Généralité .....	96
5.2. Jeu de données.....	98
5.3. Extraction de caractéristique .....	101
5.4. Classification .....	102
5.5. Méthodologie de l'étude.....	105
5.6. Résultats expérimentaux .....	106
Conclusion.....	116
<b>Chapitre 6 : Détermination de la maturité des cabosses de cacao .....</b>	<b>117</b>
Introduction .....	117
6.1. Généralité .....	117
6.2. Jeu de données.....	120
6.3. Méthodologie de l'étude.....	121
6.4. Fusion RGB - HSV .....	121
6.5. Résultats expérimentaux .....	122
Conclusion.....	124

<b>Chapitre 7 : Classification de la maturité des cabosses de cacao à l'aide d'outils de similarité sur une base de données d'images : comparaison des extracteurs de caractéristiques et des espaces de couleurs .....</b>	<b>126</b>
Introduction .....	126
7.1. Généralité .....	127
7.2. Jeu de données.....	129
7.3. Extracteurs de caractéristiques .....	130
7.4. Outils de mesure de similarité.....	134
7.5. Architecture de la méthodologie.....	136
7.6. Résultats expérimentaux.....	137
7.7. Influence des espaces couleurs .....	149
7.8. Comparaison avec les méthodes existantes .....	150
Conclusion.....	152
<b>Conclusion et perspective .....</b>	<b>153</b>
<b>Références Bibliographies .....</b>	<b>155</b>
<b>Table des matières .....</b>	<b>173</b>



# Introduction générale

## 1. Contexte et motivation

La Côte d'Ivoire est un pays dont l'agriculture est l'un des principaux secteurs économiques qui contribue significativement à l'économie nationale [1]. Le café et le cacao sont les principales cultures commerciales de la Côte d'Ivoire et représentent 60% des exportations. Le café est cultivé principalement dans les régions de l'ouest et du centre, tandis que le cacao est cultivé principalement dans les régions du sud et de l'ouest [2]. La Côte d'Ivoire est le premier producteur mondial du cacao et le quinzième producteur mondial du café en 2023, il est donc nécessaire d'améliorer en continue la qualité de la production des cultures du café et du cacao pour de nombreuses raisons [3]. D'abord, la qualité de la production garantit des produits de qualité supérieure pour la satisfaction des consommateurs. Ensuite, elle permet également d'obtenir de meilleures ventes pour les producteurs, ce qui va contribuer à améliorer leur situation économique. Enfin, l'amélioration de la qualité de la production a des impacts positifs sur l'environnement, en permettant de réduire les pertes de cultures et les gaspillages. La difficulté de garantir des niveaux de qualité élevés en raison de facteurs tels que les conditions météorologiques, les pratiques de gestion des cultures, les parasites et les maladies sont des facteurs qui peuvent avoir un impact négatif sur la qualité des cultures et entraînent des pertes importantes pour les producteurs. La difficulté de surveiller et de gérer ces facteurs de manière efficace complique les efforts visant à améliorer la qualité de la production [4].

Face à ces difficultés, l'utilisation des méthodes d'apprentissage automatique pour améliorer la qualité de la récolte de cacao et de café peut offrir de nombreux avantages. Les méthodes d'apprentissage automatique peuvent permettre d'analyser les données de production en temps réel pour identifier les facteurs qui influencent la qualité des cultures et aideront les producteurs à prendre des décisions éclairées en matière de gestion des cultures, ils permettront également de prévoir les rendements futurs avec une grande précision, qui seront utile pour planifier les approvisionnements en matière de fertilisants et d'autres ressources. Enfin, l'utilisation des méthodes d'apprentissage automatique peuvent également améliorer l'efficacité et la rentabilité de la production en réduisant les coûts liés à la main-d'œuvre et en maximisant les rendements.

L'apprentissage automatique est un domaine de l'intelligence artificielle qui consiste à utiliser des algorithmes pour analyser des données et en tirer des conclusions. En utilisant des données sur les conditions climatiques, les méthodes de culture et d'autres facteurs, les

méthodes d'apprentissage automatique peuvent aider les producteurs de cacao et de café à optimiser leurs pratiques de production pour obtenir une meilleure qualité de leurs récoltes. De ce fait, l'apprentissage automatique peut contribuer à améliorer la qualité et la valeur des récoltes de cacao et de café, ainsi que leur durabilité à long terme.

Dans le but d'apporter une contribution à l'amélioration de la qualité de production des cultures de café et de cacao, le sujet de thèse sur lequel porte nos travaux de recherche s'intitule : Système d'aide à l'amélioration de la qualité des récoltes de café et du cacao à l'aide de l'intelligence artificielle.

## **2. Objectif**

L'objectif général de cette thèse est de mettre en place un système d'aide basé sur l'intelligence artificielle pour améliorer la qualité des récoltes de café et de cacao.

Pour atteindre cet objectif, plusieurs objectifs spécifiques ont été dégagés en l'occurrence :

- mettre en place une base de données d'images couleur sur le cacao, qui permettra de stocker des images de différentes variétés de cacao et de les utiliser pour entraîner et tester les modèles d'intelligence artificielle.
- mettre en place une base de données d'images multispectrales sur le cacao, qui permettra d'utiliser des images prises à différentes longueurs d'onde pour mieux comprendre les caractéristiques du cacao ;
- mettre en place d'un système de reconnaissance des maladies des plantes de café, qui permettra de détecter automatiquement les maladies qui affectent les plantes de café ;
- détecter et extraire des cabosses de cacao en milieu naturel, en utilisant des techniques d'intelligence artificielle pour localiser les cabosses de cacao dans les images et les extraire pour les analyser ;
- déterminer la maturité des cabosses de cacao, en utilisant des techniques d'IA pour analyser les images des cabosses et déterminer leur état de maturité ;
- proposer une technique de reconnaissance des fèves de cacao fermentées, en utilisant des techniques d'intelligence artificielle pour analyser les images des fèves de cacao et déterminer leur degré de fermentation.

## **3. Contribution**

Les résultats scientifiques présentés dans cette thèse qui ont été décrits dans les différents chapitres, ont fait l'objet de présentation lors de plusieurs conférences et ont été

publiés dans des revues à comité de lecture international. Ces contributions peuvent être énumérées à travers les points suivants :

La **première contribution** a été consacrée à l'utilisation de techniques du Machine Learning et du Deep Learning pour classer et reconnaître les maladies des feuilles de café. Cette étude a été menée à partir d'une base de données publique de maladies de feuilles de café, qui a été prétraitée pour être utilisée dans les algorithmes. Les différentes méthodes d'apprentissage automatique ont été appliquées à cette base de données prétraitée pour classer et reconnaître les maladies des feuilles de café. Le but de ces travaux est de développer une méthode robuste pour détecter les maladies des feuilles de café, qui pourrait être utilisée par les producteurs de café pour protéger leurs cultures.

La **seconde contribution** a consisté à créer des bases de données dédiées au cacao. Ces bases de données sont composées de deux principaux éléments en l'occurrence des bases de données d'images couleur de cacao et des bases de données d'images multispectrales de cacao. Les bases de données d'images couleur de cacao comprennent des images de cacao prises à l'aide d'appareils photo traditionnels. Tandis que les bases de données d'images multispectrales de cacao sont constituées d'images de cacao prises à l'aide de capteurs multispectraux permettant d'obtenir des informations supplémentaires sur les caractéristiques physiques du cacao. Ces bases de données nous permettent de stocker et de récupérer des informations sur le cacao de manière efficace, pour l'analyse et la compréhension des caractéristiques du cacao.

La **troisième contribution** est basée sur l'utilisation de techniques de Deep Learning pour détecter et extraire les cabosses de cacao en milieu naturel. Cela permet une séparation efficace des cabosses de cacao des autres éléments présents dans l'environnement, ainsi qu'une détection précoce de maladies pouvant affecter les cabosses. De plus, ces algorithmes peuvent également être utilisés pour estimer la quantité de cacao à cueillir et prévoir les rendements de la récolte. En utilisant ces techniques, les agriculteurs peuvent maximiser la production de cacao tout en minimisant les pertes causées par les maladies et les erreurs pendant la cueillette.

La **quatrième contribution** est basée sur l'utilisation de techniques hybrides pour classer les fèves de cacao en fonction de leur degré de fermentation. Plus précisément, les auteurs combinent l'utilisation de réseaux de neurones à convolution (CNN) avec des machines à vecteur de support (SVM) et de l'analyse en composantes principales (PCA) avec des SVM. L'objectif de cette approche est de permettre une sélection des meilleures fèves pour obtenir des produits de qualité supérieure. Les résultats de cette étude montrent que cette

méthode hybride est efficace pour classer les fèves de cacao en fonction de leur degré de fermentation.

**La cinquième contribution** permettra de déterminer l'état de maturité d'une cabosse de cacao en utilisant une méthode basée sur la fusion des espaces de couleur, suivie d'une classification. Pour ce faire, nous avons utilisé différents espaces de couleur, tels que l'espace RGB (Red, Green, Bleu) et l'espace HSV (Hue Saturation Value) pour représenter les images de cabosses de cacao. Ces espaces ont ensuite été combinés en utilisant des techniques de fusion de données pour obtenir une représentation plus complète de l'image. Les résultats obtenus montrent que cette méthode est efficace pour déterminer l'état de maturité des cabosses de cacao.

**La sixième contribution** examinera les images de cabosses de cacao en utilisant différents espaces de couleurs tels que RGB, HSV, Luv et Lab, ainsi que diverses méthodes d'extraction de caractéristiques telles que GCLM et CNN. Des outils mathématiques de mesure de similarité seront utilisés pour classer les caractéristiques extraites dans chaque espace de couleur. Les résultats expérimentaux sont comparés pour chaque combinaison d'extracteur de caractéristiques et d'espace colorimétrique afin de déterminer la méthode de traitement d'image la plus efficace pour extraire des informations à partir du jeu de données. Ces résultats fournissent des informations précieuses pour l'analyse des images de cabosses de cacao.

#### **4. Liste des publications**

[1] AYIKPA, Kacoutchy Jean, MAMADOU, Diarra, GOUTON, Pierre, et al. Experimental Evaluation of Coffee Leaf Disease Classification and Recognition Based on Machine Learning and Deep Learning Algorithms. *Journal of Computer Science*, 2022, vol. 18, no 12, p. 1201-1212.

[2] Kacoutchy Jean AYIKPA, Diarra MAMADOU, Abou Bakary Ballo, Konan Yao, Pierre Gouton, et al. CocoaMFDB: A dataset of cocoa pod maturity and families in an uncontrolled environment in Côte d'Ivoire. *Data in Brief*, 2023, pp.109196. <10.1016/j.dib.2023.109196>

[3] AYIKPA, Kacoutchy Jean, DIARRA, MAMADOU, ABOU BAKARY, BALLO, et al. Application based on Hybrid CNN-SVM and PCA-SVM Approaches for Classification of Cocoa Beans. *International Journal of Advanced Computer Science and Applications*, 2022, vol. 13, no 9.

[4] Fusion RGB and HSV Spaces for Cocoa Pod Maturity Identification using the Random Forest Method, Kacoutchy Jean AYIKPA, Diarra MAMADOU, Abou Bakary BALLO, Pierre GOUTON, Kablan Jérôme ADOU; MDPI conference, Engineering, London, UK, 2022.

[5] AYIKPA, Kacoutchy Jean, MAMADOU, Diarra, SODJINOU, Sovi Guillaume, et al. Detecting and Extracting Cocoa Pods in the Natural Environment Using Deep Learning Methods. In: Digital Technologies and Applications: Proceedings of ICDTA'23, Fez, Morocco, Volume 1. Cham: Springer Nature Switzerland, 2023. p. 164-174.

[6] Ayikpa, K.J.; Mamadou, D.; Gouton, P.; Adou, K.J. Classification of Cocoa Pod Maturity Using Similarity Tools on an Image Database: Comparison of Feature Extractors and Color Spaces. Data 2023, 8, 99. <https://doi.org/10.3390/data8060099>.

## 5. Organisation de la thèse

L'organisation de cette thèse est la suivante :

**Le chapitre 1** sera consacré à revue de littérature sur l'intelligence artificielle, du machine Learning et du Deep Learning, en présentant les dernières avancées dans ces domaines. Il abordera également les cultures du café et du cacao avec leurs impacts au plan économique, suivi d'une analyse approfondie de la production de cacao en Côte d'Ivoire, les méthodes de culture et les défis auxquels les producteurs font face. Enfin, il abordera les espaces couleurs et l'imagerie numérique dans le domaine de l'agriculture, en expliquant comment ces outils peuvent être utilisés pour améliorer la productivité et la qualité des cultures.

**Le chapitre 2** abordera l'utilisation de techniques d'apprentissage automatique, telles que les algorithmes de classification et de reconnaissance, pour détecter et diagnostiquer les problèmes liés aux feuilles de café. Il utilisera à la fois des méthodes de Machine Learning traditionnelles ainsi que des techniques de Deep Learning pour identifier les caractéristiques et les signes de maladies spécifiques dans les feuilles de café, afin de faciliter la prévention et la gestion de ces problèmes.

**Le chapitre 3** sera consacré à la création et à la gestion de bases de données d'images de cacao en couleur et multispectrales. La description des différentes méthodes utilisées pour l'acquisition et le stockage de ces images, ainsi que les outils utilisés pour les analyser et les utiliser dans des applications telles que la classification automatique des fèves et la détection de la maturité. Les différents types de capteurs utilisés pour collecter les images seront également discutés, ainsi que les avantages et les inconvénients de chaque méthode. Enfin, les

perspectives futures pour l'utilisation de ces bases de données d'images seront explorées, notamment pour l'amélioration du potentiel de la précision des futures études.

**Le chapitre 4** sera consacré à l'utilisation de techniques de segmentation pour la détection et l'extraction des cabosses de cacao dans un environnement naturel. Il décrira également les étapes nécessaires de préparation des images pour la segmentation. Il expliquera comment les techniques de segmentation peuvent être utilisées pour sélectionner les régions d'intérêt, comme les cabosses de cacao, en utilisant des critères tels que la taille, la forme, la couleur et la texture.

**Le chapitre 5** abordera la classification des fèves de cacao en utilisant des méthodes hybrides combinant les techniques de réseaux de neurones à convolution (CNN) et d'analyse en composantes principales (PCA) avec les machines à vecteurs de support (SVM). Ces méthodes hybrides seront utilisées pour trier les fèves de cacao en fonction de leur degré de fermentation, ce qui permettra de sélectionner les fèves les plus appropriées pour chaque utilisation spécifique. Les différentes étapes impliquées dans la mise en place de ces méthodes seront également discutées, ainsi que les avantages et les limites de chaque technique. Enfin, les résultats obtenus seront comparés pour évaluer l'efficacité de chaque méthode.

**Le chapitre 6** se concentrera sur la mise en place d'une méthode de détection de la maturité des cabosses de cacao basée sur la fusion des espaces de couleurs et l'utilisation d'un classificateur d'apprentissage automatique appelé Forêt Aléatoire ou Random Forest. La méthode consistera à utiliser des capteurs de couleur pour collecter des données sur les caractéristiques de couleur des cabosses de cacao à différents stades de maturité. Ces données seront ensuite fusionnées pour créer un espace de couleur multidimensionnel. Ensuite on utilisera un classificateur Random Forest pour entraîner un modèle capable de prédire la maturité des cabosses de cacao en fonction des données de couleur fusionnées. Cette méthode efficace pour détecter la maturité des cabosses de cacao, pourrait être utilisée par les producteurs de cacao pour améliorer la qualité et la rentabilité de leur production.

**Le chapitre 7** présentera une étude approfondie menée sur la classification de la maturité des cabosses de cacao à partir d'une base de données d'images en utilisant différents extracteurs de caractéristiques tels que le GCLM et le CNN. L'influence des espaces couleurs sur la classification sera également examinée, en utilisant des techniques de mesure de similarité telles que la distance Euclidienne, la distance de corrélation et la distance du chi carré. Cette approche permettra de déterminer la méthode la plus robuste pour classifier les cabosses de cacao en fonction de leur maturité et quel est l'impact des différents espaces couleurs sur cette classification.

# **Chapitre 1 : Etat de l'art**

## **Introduction**

L'Intelligence Artificielle (IA) est en train de devenir un champ de recherche technologique de plus en plus populaire ces dernières années. Le Machine Learning et le Deep Learning sont des sous-domaines clés de l'IA qui ont permis de développer des modèles de prédiction de plus en plus précis [5]. Les applications de ces technologies sont de plus en plus répandues dans les industries et également dans l'agriculture. L'utilisation de l'IA pour améliorer les récoltes de café et de cacao est un domaine en constante évolution, en particulier en Côte d'Ivoire où ce domaine de recherche est devenu important. L'analyse de l'espace couleur et de l'imagerie numérique est également un domaine en développement qui peut aider à améliorer la qualité de ces produits agricoles. L'objectif de ce chapitre est de faire une revue complète de la littérature sur les domaines tels que l'IA, le machine Learning, le deep Learning, le café, le cacao, la production de cacao en Côte d'Ivoire, les espaces couleurs et l'imagerie numérique dans le domaine de l'agriculture.

### **1.1. Intelligence artificielle (IA)**

#### **1.1.1. Définition de l'intelligence artificielle**

L'IA est un processus d'imitation ou simulation de l'intelligence humaine par des ordinateurs. Elle se compose de plusieurs techniques telles que l'apprentissage automatique, la reconnaissance de la parole et de l'image, la planification et la compréhension du langage naturel [6]. L'objectif de l'IA est de mettre en place des systèmes capables de réaliser des tâches qui basées sur le principe d'une intelligence humaine, comme la prise de décisions et la résolution de problèmes.

#### **1.1.2. Histoire de l'IA**

L'IA remonte aux années 1950 avec la création du premier ordinateur à réseau de neurones, lorsque des chercheurs ont commencé à explorer la possibilité de créer des machines dotées d'intelligence. Les premiers travaux en IA ont porté sur l'apprentissage automatique et les systèmes de traitement de la langue naturelle. Au cours des années 1960 et 1970, l'IA a connu un développement important grâce aux avancées en matière de traitement de la parole et de reconnaissance de l'écriture [7]. Cependant, les résultats ont été décevants, car les systèmes étaient incapables de généraliser les connaissances acquises. C'est dans les années 1980 et 1990 que l'IA a suscité à nouveau un intérêt pour la communauté scientifique avec l'avènement de l'apprentissage profond, qui a permis de créer des systèmes plus

performants [8]. Depuis cette période, l'IA a connu des progrès considérables, notamment dans les domaines de la reconnaissance vocale, de la vision par ordinateur et de la compréhension du langage naturel. Présentement, elle est utilisée dans de nombreux domaines tels que la robotique, la santé, les finances, les transports, la recherche, les services publics, l'agriculture, l'éducation etc [9] [10] [11] [12].

### 1.1.3. Différentes catégories d'IA

Parmi les catégories des IA [13], nous avons :

- **Apprentissage automatique** : c'est un processus où des algorithmes sont formés à partir de données d'entraînement pour effectuer des tâches spécifiques, comme la classification ou la prédiction ;
- **Traitement du langage naturel** : c'est la capacité d'un système informatique à comprendre, générer et interagir avec le langage humain [14]. Il se base les techniques de traitement du langage, de l'analyse syntaxique et de la compréhension du sens pour effectuer des tâches telles que la reconnaissance de la parole, la traduction automatique, la classification de sentiments et la génération de réponses pour les chatbots [15] ;
- **Vision par ordinateur** : c'est la capacité d'un système informatique à comprendre et interagir avec le monde visuel [16]. Il utilise des algorithmes de traitement d'images et de vidéos pour effectuer des tâches telles que la reconnaissance faciale, la détection d'objets, la segmentation de l'image et la reconnaissance de la scène ;
- **Robotique** : c'est un domaine interdisciplinaire qui combine la mécanique, l'électronique, l'informatique et l'intelligence artificielle pour concevoir, construire et utiliser des robots [17]. Les robots sont des machines programmables conçues pour effectuer des tâches automatisées ;
- **Génération de contenu** : c'est la capacité d'un système informatique à produire du contenu, comme du texte, de l'audio ou de la vidéo, sans intervention humaine [18]. Elle utilise des algorithmes de traitement du langage naturel et d'apprentissage automatique pour générer du contenu qui imite ou complète le contenu humain ;
- **Raisonnement et planification** : c'est la capacité d'un système informatique à prendre des décisions en utilisant des connaissances et des algorithmes pour trouver des solutions à des problèmes complexes. Ils sont utilisés dans des applications telles que les systèmes d'assistance médicales, les systèmes de planification de voyage et les systèmes de contrôle de la qualité pour les produits manufacturés [19]. Ils sont



également utilisés pour automatiser des processus de prise de décisions complexes dans les domaines tels que la finance, la défense et les ressources naturelles ;

- **Systèmes experts** : c'est un système informatique conçu pour imiter les capacités d'un expert humain dans un domaine spécifique. Ils utilisent des algorithmes de raisonnement et des connaissances préétablies pour prendre des décisions, résoudre des problèmes et fournir des conseils. Ils sont basés sur le modèle d'inférence de la règle, où des connaissances sont représentées sous forme de règles et utilisées pour trouver des solutions à des problèmes en utilisant la logique et le raisonnement [20].

#### **1.1.4. Applications de l'IA**

Les applications de l'IA sont très vastes et couvrent de nombreux domaines différents [21], nous pouvons citer quelques domaines et des cas d'utilisation suivante :

- **la santé** : le diagnostic médical assisté par ordinateur, l'analyse de données pour la recherche médicale et les robots chirurgicaux ;
- **la finance** : l'analyse des risques financiers, le trading automatisé, la détection de des fraudes financières ;
- **le marketing et la publicité** : le ciblage de la publicité en ligne, l'analyse des tendances de consommation, la prévision des ventes ;
- **l'industrie automobile** : les voitures autonomes, les systèmes de conduite assistée, la détection des défauts de maintenance ;
- **la cybersécurité** : la détection des menaces, l'analyse de la sécurité des réseaux, la protection des données ;
- **l'éducation** : le tutorat en ligne, l'évaluation automatisée des devoirs, la recommandation de parcours d'apprentissage ;
- **les ressources naturelles** : la surveillance environnementale, la détection des gisements de ressources, la planification de l'exploitation minière ;
- **l'agriculture** : l'utilisation de modèles de prévision de rendement pour estimer les rendements futurs des cultures, l'utilisation de drones et de capteurs pour surveiller les conditions de croissance des cultures, telles que la température, l'humidité et la qualité de la terre, l'optimisation des systèmes d'irrigation en fonction des besoins des cultures et des conditions météorologiques, la détection les maladies des cultures et la recommandation des traitements.

### 1.1.5. Défis et les limites de l'IA

Les défis de l'IA sont nombreux [22] et nous pouvons en relever quelques-uns tels que

:

- **l'apprentissage supervisé limité** : il y a des dépendances liées sur les données étiquetées pour former des modèles ;
- **le biais dans les données** : les modèles peuvent refléter les biais dans les données d'entraînement ;
- **l'interprétabilité** : la difficulté de comprendre les décisions prises par les modèles ;
- **la généralisation** : une capacité limitée des modèles à généraliser l'apprentissage aux nouvelles données ;
- **l'éthique et responsabilité** : les questions éthiques liées à l'utilisation de l'IA, telles que la protection de la vie privée et la responsabilité en cas de décision erronée.

Aussi, l'IA présente des limites tel que :

- **les connaissances limitées** : les modèles d'IA sont limités par les connaissances qu'ils ont été formés à partir ;
- **la dépendance à l'entraînement** : les modèles d'IA dépendent fortement des données d'entraînement pour fonctionner correctement ;
- **le manque de créativité** : l'IA manque de créativité et d'imagination ;
- **la faible compréhension de la complexité humaine** : l'IA a du mal à comprendre les nuances et la complexité des situations sociales et émotionnelles.

## 1.2. Machine Learning (ML)

### 1.2.1. Définition du machine Learning

Le machine Learning est une branche de l'intelligence artificielle qui utilise des algorithmes pour apprendre à effectuer des tâches en analysant des données passées, c'est aussi un processus qui consiste à utiliser des techniques statistiques ou géométriques et des algorithmes informatiques pour automatiser la création d'une fonction de prédiction à partir d'un ensemble de données connues appelé ensemble d'apprentissage. Les algorithmes du machine Learning sont utilisés dans de nombreuses applications, telles que la reconnaissance de la voix, l'identification et la reconnaissance des images, la classification de données et la prédiction [23].

### 1.2.2. Types d'algorithmes de machine Learning

Les algorithmes du machine Learning peuvent être classés trois groupes qui sont :

- **apprentissage supervisé** : l'ordinateur est formé à partir de données annotées pour effectuer une tâche spécifique, comme la classification ou la régression ;
- **apprentissage non supervisé** : l'ordinateur est formé à partir de données non étiquetées pour découvrir des structures et des modèles dans les données ;
- **apprentissage par renforcement** : l'ordinateur interagit avec un environnement pour effectuer une tâche et est récompensé ou puni en fonction de ses actions pour apprendre comment effectuer la tâche de manière optimale.

### 1.2.3. Fonctionnement du machine Learning

Le machine Learning suit les principales étapes suivantes pour son fonctionnement, il s'agit de :

- **la préparation et la sélection des données** : les données doivent être soigneusement préparées, organisées et nettoyées. Elles peuvent être étiquetées ou non étiquetées. Les données doivent être généralement divisées en trois parties à savoir les données d'entraînement, de validation et de test ;
- **la sélection de l'algorithme** : le choix de l'algorithme dépend du type et du volume de données d'entraînement et du problème à résoudre ;
- **l'entraînement de l'algorithme** : c'est un processus itératif dans lequel les variables sont exécutées à travers l'algorithme et les résultats sont comparés pour ajuster les poids et le biais. Elle utilisera les données d'entraînement et de validation ;
- **la validation du modèle** : le modèle est utilisé sur de nouvelles données pour évaluer sa performance et l'améliorer.

### 1.2.4. Différentes catégories d'algorithmes du machine Learning

Les algorithmes du machine Learning sont regroupés généralement en quatre grandes catégories [24], il s'agit des catégories suivantes :

- **la régression** : c'est une technique statistique utilisée pour mettre en relation une variable dépendante et une ou plusieurs variables indépendantes. Son but est de construire un modèle qui permet de prédire la valeur de la variable dépendante en fonction des variables indépendantes. Les modèles de régression les plus couramment utilisés sont la régression linéaire simple et la régression linéaire multiple ;
- **la classification** : elle consiste à attribuer une étiquette ou une catégorie à une entrée en fonction de ses caractéristiques. Les algorithmes de classification passent par une phase d'entraînement avec des données d'entraînement pour construire un modèle qui peut prédire la classe d'une nouvelle entrée. Les algorithmes de classification les plus

couramment utilisés comprennent la régression logistique, les arbres de décision, les forêts aléatoires, les k plus proches voisins (KNN) et les réseaux de neurones ;

- **le regroupement** : il consiste à regrouper un ensemble d'objets de telle sorte que les objets dans le même groupe également appelé cluster soient plus similaires entre eux que ceux dans d'autres groupes. Il est utilisé dans divers domaines tels que la segmentation d'image, la segmentation de marché, la reconnaissance de formes, et plus encore. Certains algorithmes populaires de clustering incluent K-Means, le clustering hiérarchique, DBSCAN et les modèles de mélange gaussiens ;
- **la réduction de dimensionnalité** : elle permet de réduire le nombre de variables ou de caractéristiques d'une observation pour simplifier les données. Il aide à améliorer les performances des modèles en éliminant la corrélation et la complexité superflues, tout en préservant les informations les plus importantes. Les techniques courantes de réduction de dimensionnalité comprennent l'analyse en composantes principales (ACP), la projection sur des sous-espaces linéaires et la technique t-SNE.

### 1.3. Deep Learning (DL)

#### 1.3.1. Définition du Deep Learning

L'apprentissage en profondeur est un type de machine Learning qui utilise des réseaux de neurones profonds pour résoudre des tâches complexes. Les réseaux de neurones profonds sont des modèles de calcul comprenant de nombreuses couches de neurones connectés les uns aux autres. Ces couches interagissent pour produire des résultats précis en analysant des données complexes [25]. L'apprentissage en profondeur peut être utilisé pour résoudre des problèmes dans divers domaines, tels que la reconnaissance d'objets, la traduction de langues, le traitement du langage naturel et bien d'autres encore.

#### 1.3.2. Différents types de réseaux de neurones profonds

Il existe plusieurs types de réseaux de neurones profonds [26], qui sont :

- **les réseaux de neurones à propagation avant** : c'est un type de réseau qui est utilisé pour la classification et la régression. Ils ont une structure en chaîne où les entrées sont propagées à travers plusieurs couches de neurones pour produire une sortie. Chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et reçoit des entrées de ces derniers pour produire une sortie qui est transmise aux neurones de la couche suivante. La dernière couche produit la sortie du réseau. Les poids des connexions entre les neurones sont appris au cours de l'entraînement du modèle ;

- **les réseaux de neurones récurrents** : c'est un type de réseau de neurones qui sont utilisés pour le traitement des séquences de données. Ils utilisent des boucles internes pour maintenir l'état interne, qui permettra de conserver la mémoire des entrées précédentes et d'utiliser cette information pour informer les prédictions sur les entrées suivantes. Ils sont utilisés pour les tâches telles que la reconnaissance de la parole, la traduction automatique, la génération de textes et la classification de séquences ;
- **les réseaux de neurones à convolution** : c'est un type de réseau de neurones qui utilise des couches de convolution pour extraire des caractéristiques locales des entrées, telles que des textures et des formes, et les combiner pour former une représentation plus abstraite de l'image. Les réseaux de neurones à convolution sont largement utilisés dans les applications de reconnaissance d'images et de traitement du signal, telles que la reconnaissance de visages, l'analyse de mouvements vidéo, la reconnaissance de chiffres manuscrits et la reconnaissance de la parole ;
- **les réseaux de neurones de type attention** : ce type de réseau utilise une variante des réseaux de neurones classiques qui permettent à la couche d'attention de focaliser sur des parties spécifiques des entrées du modèle. Il est utile pour des tâches telles que la traduction de langue, la reconnaissance d'objets dans des images et la génération de texte. Les réseaux de neurones avec attention utilisent un mécanisme d'attention pour pondérer différentes parties des entrées, ce qui permet au modèle de faire une sélection attentive des informations les plus importantes.

### 1.3.3. Différents algorithmes d'apprentissage des réseaux de neurones profonds

Il existe plusieurs algorithmes différents pour entraîner des réseaux de neurones profonds, y compris :

- **la rétropropagation du gradient** : c'est un algorithme d'optimisation couramment utilisé pour entraîner des réseaux de neurones profonds. Il permet d'ajuster les poids de manière à minimiser la perte ou l'erreur d'une tâche. Cela se fait en calculant la dérivée par rapport aux poids du coût ou de la perte, puis en utilisant ces dérivées pour mettre à jour les poids dans la direction qui réduit la perte [27] ;
- **la rétropropagation en profondeur** : c'est une variante de la rétropropagation du gradient qui utilise des couches multiples pour capturer les caractéristiques complexes dans les données d'entraînement. Il sert à minimiser la perte d'erreur d'un modèle en ajustant les poids des connections entre les neurones pour optimiser la prédiction. La rétropropagation en profondeur calcule les gradients des erreurs à partir de la sortie du

modèle et les propage à travers le réseau pour mettre à jour les poids de chaque neurone de manière à minimiser la perte d'erreur [28] ;

- **la descente de gradient stochastique** : c'est aussi une variante de la rétropropagation du gradient qui utilise des échantillons aléatoires des données d'entraînement à chaque étape pour réduire les fluctuations dans les erreurs d'apprentissage. Cette méthode d'optimisation est utilisée pour minimiser une fonction de coût. Cela permet de faire des ajustements plus rapides et plus efficaces par rapport à la descente de gradient classique, qui utilise l'ensemble des échantillons d'entraînement à chaque itération ;
- **l'optimiseur Adam** : c'est un algorithme d'optimisation qui tient compte de la moyenne exponentielle et de la variance des gradients pour ajuster les paramètres du réseau de neurones de manière plus efficace. Il est une combinaison de l'algorithme SGD (Stochastic, Gradient, Descent) avec des moyennes et des variances des gradients calculés sur plusieurs pas de descente de gradient [29]. Il permet à Adam d'être plus robuste et plus rapide que SGD seul pour trouver des solutions optimales pour les modèles complexes ;
- **l'optimiseur Adagrad** : un algorithme d'optimisation qui utilise des taux d'apprentissage adaptatifs pour les différents paramètres du réseau de neurones. Il ajuste la vitesse d'apprentissage pour chaque paramètre de manière indépendante en utilisant une mise à jour cumulative de la dérivée de chaque paramètre [30]. Cela implique que les paramètres qui ont été souvent mis à jour avec des gradients négatifs dans le passé recevront des mises à jour plus petites, tandis que les paramètres qui ont rarement été mis à jour recevront des mises à jour plus importantes. Adagrad est utile pour les fonctions de coût qui ont des gradients de tailles différentes pour différents paramètres ;
- **l'optimiseur Adadelta** : c'est une variante de l'optimiseur Adagrad qui utilise une moyenne pondérée pour maintenir une certaine stabilité dans les taux d'apprentissage. Il est un algorithme de gradient stochastique pour la mise à jour des poids dans les réseaux de neurones ou d'autres modèles d'apprentissage machine. Il appartient à la catégorie des algorithmes d'optimisation par méthode d'accumulation d'inertie, similaires à Adagrad et RMSprop. Adadelta se différencie de ces algorithmes en utilisant une méthode de mise à jour basée sur l'accumulation du gradient au fil du temps, plutôt que sur une moyenne mobile des gradients [31]. Cela permet à Adadelta de s'adapter aux variations des gradients dans les différentes étapes d'apprentissage ;

- **l'optimiseur RMSprop** : c'est un algorithme d'optimisation utilisé dans l'entraînement des réseaux de neurones et d'autres modèles d'apprentissage automatique. Il appartient à la catégorie des algorithmes d'optimisation basés sur la moyenne mobile des gradients, similaires à Adagrad et Adadelta. L'idée de base de RMSprop est d'ajuster les taux d'apprentissage pour chaque paramètre en utilisant une moyenne mobile des carrés du gradient pour chaque paramètre [32]. Il permet à RMSprop de s'adapter aux variations des gradients pour différents paramètres et de traiter efficacement les gradients qui varient beaucoup dans le temps.

## 1.4. Café

### 1.4.1. Introduction à la culture du café et à ses origines

Le café est un produit originaire d'Ethiopie. Il a été consommé pour la première fois en tant que boisson autour du 15<sup>ème</sup> siècle [33]. Au fil des ans, il est devenu l'une des boissons les plus populaires au monde, avec une culture du café émergente dans de nombreux pays, y compris en Europe, en Amérique et en Asie [34]. Les différentes méthodes de production, de torréfaction et de préparation du café ont donné naissance à une variété de cafés différents, chacun ayant ses propres caractéristiques de saveur et de goût. Aujourd'hui, le café est largement consommé comme boisson énergisante, mais il est également apprécié pour son arôme et ses propriétés stimulantes, que ce soit en tant que boisson seule ou comme ingrédient dans de nombreux aliments et boissons.

### 1.4.2. Différentes variétés de café

Il existe de nombreuses variétés de café, chacune avec ses propres caractéristiques uniques en termes de saveur, de couleur et de corps. Les plus courantes sont l'arabica et le robusta [35].

- **l'Arabica** est considéré comme le meilleur en termes de qualité, avec une saveur douce et sucrée et une acidité légère ;
- **le Robusta**, quant à lui, a un goût plus fort et plus amer, avec une teneur en caféine plus élevée.

Les différents types de café sont souvent utilisés dans des mélanges pour créer des saveurs uniques et variées. La figure 1 présente l'image du café Arabica et Robusta [36].



**Figure 1** : Image des cafés Arabica et Robusta

### 1.4.3. Production du café

La production de café est un processus complexe qui comprend plusieurs étapes clés telle que la culture, la récolte, le traitement, la torréfaction et le conditionnement.

- **la culture** : la culture du café commence par la plantation de graines de café dans des zones appropriées pour la croissance du café. Les producteurs doivent prendre soin de leurs plantes en leur fournissant des soins adéquats tels que l'arrosage, la fertilisation et la protection contre les ravageurs ;
- **la récolte** : elle a lieu lorsque les cerises de café atteignent leur maturité, elles sont récoltées, triées et sélectionnées pour enlever les cerises vertes ou abîmées ;
- **le traitement** : après la récolte, les cerises de café sont traitées pour enlever leur enveloppe et sont ensuite séchées pour enlever toute l'humidité restante ;
- **la torréfaction** : c'est le processus de cuisson des grains de café à haute température pour leur donner une saveur et un arôme distinctif. Il existe plusieurs types de torréfaction, chacun produisant des arômes et des saveurs différents ;
- **le conditionnement** : enfin, les grains de café torréfiés sont conditionnés pour leur transport et leur distribution. Les grains peuvent être emballés en sacs de papier ou de toile, en boîtes en métal ou en sachets plastiques.

Le processus de production de café est important pour garantir la qualité du café final. Les producteurs doivent suivre les bonnes pratiques pour garantir une meilleure qualité.

### 1.4.4. Différentes maladies du café

Il existe plusieurs maladies qui affectent les plants de café et peuvent entraîner une réduction de la production et de la qualité du café. Les maladies les plus courantes sont :

- **la rouille du café** : c'est une maladie fongique qui provoque des taches jaunes sur les feuilles et une réduction de la croissance des plantes ;
- **la pourriture des cerises** : c'est une maladie causée par un champignon qui peut entraîner une réduction de la qualité du café et une perte des récoltes ;
- **les maladies bactériennes** : Ce sont des bactéries qui peuvent attaquer les racines, les tiges et les feuilles des plants de café, entraînant une réduction de la croissance et de la production.

Il est important de surveiller régulièrement les plants de café pour détecter tout signe de maladie et de prendre des mesures pour la contrôler, telles que l'utilisation de traitements phytosanitaires et la rotation des cultures.



### 1.4.5. Zones de culture du café

Les zones de culture du café se situent principalement dans les régions tropicales et subtropicales du monde. Les meilleurs pays producteurs du café sont le Brésil, la Colombie, l'Ethiopie, l'Indonésie et le Vietnam [37] [38]. Les conditions idéales pour la culture du café comprennent un climat chaud et humide, ainsi qu'une terre fertile et bien drainée. La plupart des variétés de café poussent dans des zones situées entre les tropiques du Cancer et du Capricorne, à des altitudes comprises entre 600 et 2000 mètres au-dessus du niveau de la mer [39]. D'autres facteurs tels que la disponibilité de l'eau, la main-d'œuvre et les coûts de production peuvent également influencer les zones de culture du café. La Côte d'Ivoire est l'un des principaux producteurs de café en Afrique. La production de café en Côte d'Ivoire a connu une croissance constante au cours des dernières années, grâce à des investissements dans les technologies de production, l'amélioration des conditions de vie des producteurs et la mise en place de politiques favorables à l'agriculture. La répartition de la zone de production [40] est représentée par la figure suivante :





Figure 2 : Zone de production du café en Côte d'Ivoire.

## 1.5. Cacao

### 1.5.1. Introduction

Le cacao est un arbre produisant des fèves qui sont le principal ingrédient pour fabriquer du chocolat. Les fèves de cacao sont récoltées, fermentées, séchées et torréfiées pour être transformées en pâte de cacao, utilisée pour produire du chocolat et d'autres produits dérivés tels que le beurre de cacao et la poudre de cacao. Outre le chocolat, la pâte de cacao peut également être utilisée dans la cuisine pour ajouter une saveur de cacao à divers plats et boissons, tandis que le beurre de cacao est utilisé dans la production de cosmétiques et de produits de soins pour la peau. La poudre de cacao peut également être utilisée comme édulcorant et colorant dans les produits alimentaires. La figure 3 fait une illustration des cabosses de cacao.



**Figure 3 :** Images des cabosses de cacao

### 1.5.2. Histoire du cacao

La culture du cacao a commencé en Amérique centrale il y a environ 3 000 ans, où les peuples Maya et Aztèque cultivaient le cacao pour en faire une boisson précieuse [41]. Les graines de cacao étaient également utilisées comme monnaie dans ces cultures antiques. Au 16ème siècle, les Espagnols ont découvert le cacao lors de leurs explorations en Amérique centrale et ont commencé à l'introduire en Europe, où il a rapidement gagné en popularité en tant que boisson chocolatée. Au cours des siècles suivants, le cacao a été introduit en Afrique et en Asie, où il est devenu un ingrédient de base pour la production de chocolat dans de nombreux pays.

Au fil des années, la culture du cacao s'est développée et a évolué pour devenir un secteur économique important dans de nombreux pays producteurs, notamment en Afrique, en Amérique centrale et en Amérique du Sud. Aujourd'hui, le cacao est l'un des principaux produits d'exportations de ces régions et est utilisé dans la production de nombreux produits alimentaires et non alimentaires à travers le monde.

### **1.5.3. Production du cacao**

Le cacao est principalement cultivé dans les régions tropicales du monde, notamment en Afrique, en Amérique centrale, en Amérique du Sud et en Asie. Les principales régions productrices de cacao comprennent la Côte d'Ivoire, le Ghana, l'Indonésie, le Brésil et le Nigeria. Les méthodes de culture du cacao varient selon les régions, mais la plupart des producteurs cultivent le cacao en milieu forestier, en utilisant une méthode appelée culture en touffes. Cela implique de planter les graines de cacao sous la canopée des arbres existants, ce qui fournit de l'ombre et de l'humidité pour les jeunes plants de cacao.

La récolte du cacao se fait généralement à la main, en cueillant les fruits du cacao lorsqu'ils sont mûrs. Les fèves de cacao sont ensuite enlevées des coques, pour être fermentées et séchées avant d'être vendues aux transformateurs. La culture du cacao peut être difficile et coûteuse, mais elle peut également être rentable pour les producteurs qui peuvent obtenir des prix équitables pour leur récolte. Cependant, la production de cacao peut également être soumise à des défis tels que les maladies des plantes, les ravageurs, les fluctuations des prix du marché et les conditions météorologiques extrêmes.

### **1.5.4. Transformation du cacao**

La transformation du cacao en produits finis suit les principales étapes suivantes :

- **la récolte et la sélection des fèves de cacao** : les fèves de cacao sont récoltées à la main à partir des cabosses mûrs, puis sélectionnées pour éliminer les cabosses abîmées ou mal formées ;
- **la fermentation et le séchage** : les fèves de cacao sont placées dans des boîtes ou des paniers et fermentées pendant plusieurs jours. Cette étape est importante pour développer les arômes et les saveurs du cacao. Les fèves sont ensuite séchées au soleil pendant plusieurs jours pour réduire leur teneur en eau ;
- **la torréfaction** : les fèves de cacao sont torréfiées pour développer leur saveur et leur arôme, et pour éliminer les bactéries et les moisissures restantes ;
- **l'écrasement et le broyage** : les fèves de cacao torréfiées sont écrasées et broyées pour produire une pâte de cacao lisse et homogène ;

- **le raffinement et le concassage** : la pâte de cacao est ensuite soumise à un processus de raffinage pour éliminer les impuretés et obtenir une consistance lisse. La pâte de cacao raffinée est ensuite concassée pour produire du beurre de cacao et de la poudre de cacao ;
- **la fabrication de produits finis** : la pâte de cacao, le beurre de cacao et la poudre de cacao peuvent être utilisés séparément ou combinés pour produire différents produits finis tels que le chocolat, les produits de confiserie, les cosmétiques, etc.

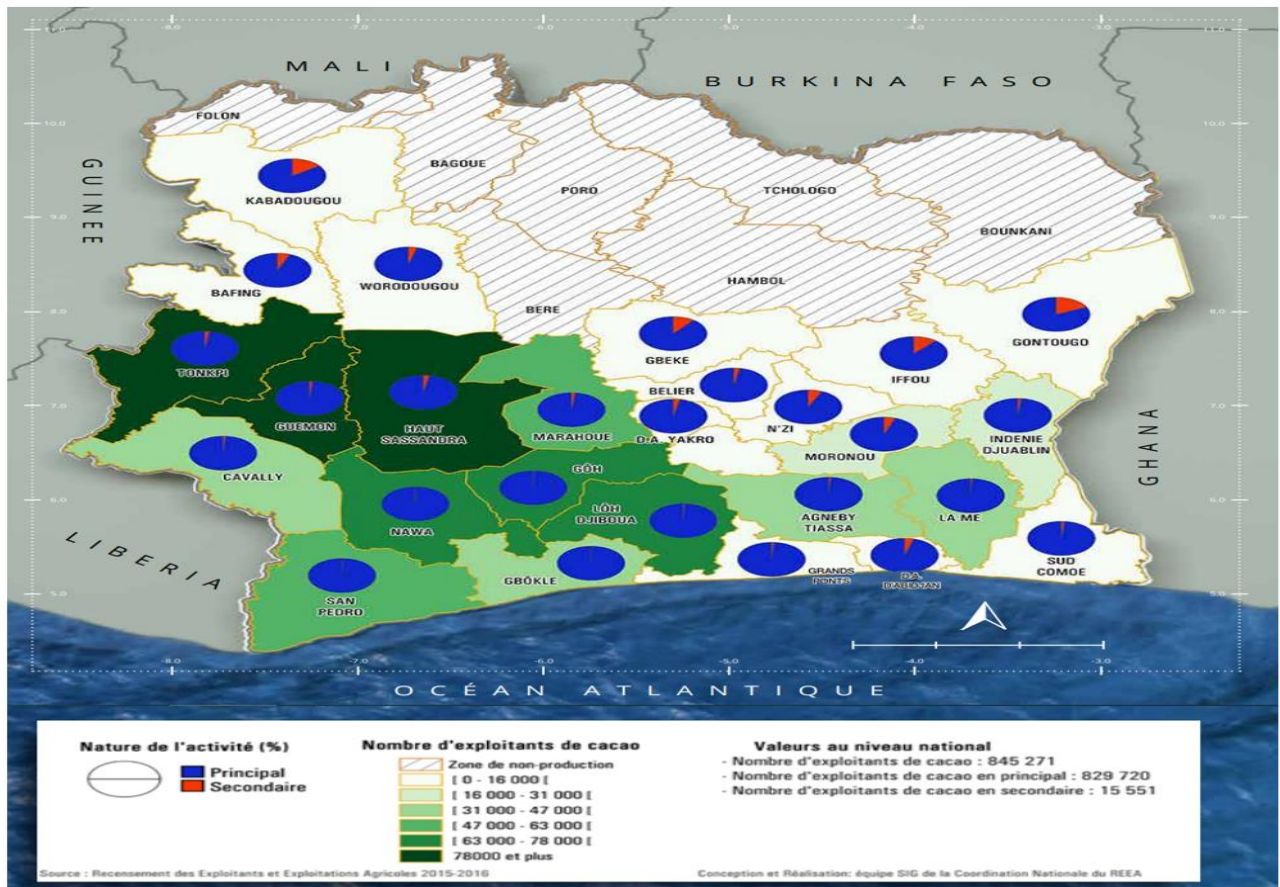
## **1.6. Production du cacao en Côte d’Ivoire**

### **1.6.1. Introduction**

La Côte d'Ivoire est l'un des plus grands producteurs de cacao au monde, avec environ 40% de la production mondiale de cacao provenant de ce pays. La culture du cacao est un élément clé de l'économie ivoirienne et génère des revenus pour des millions d'agriculteurs, de travailleurs et d'entreprises. Ce secteur représente entre 15% et 20% du PIB de la Côte d'Ivoire selon le conseil café-cacao [42] [43]. Depuis des décennies, la Côte d'Ivoire a établi un système efficace pour la production et la transformation du cacao en produits finis tels que les fèves de cacao, la pâte de cacao, le beurre de cacao et le chocolat. Cependant, la production de cacao est soumise à de nombreux défis, notamment la baisse de la qualité des fèves de cacao, la faible productivité des plantations et la concurrence sur les marchés mondiaux. En dépit de ces défis, la production de cacao en Côte d'Ivoire continue d'être un moteur économique important pour le pays et une source de revenus pour les communautés agricoles. De nombreux ménages dépendent directement du secteur du cacao pour leur existence, et certains aspects de l'industrie cacaoyère.

### **1.6.2. Régions de production**

En Côte d'Ivoire, la production de cacao est principalement concentrée dans les régions côtières et dans les zones rurales intérieures. Les régions productrices de cacao incluent les départements d'Abidjan, de San-Pedro, de Soubré d'Abengourou, d'Aboisso, de Divo, de Gagnoa, du Cavally et du Tonkpi [44]. La production de cacao est généralement concentrée dans des zones rurales où les conditions climatiques et les sols sont favorables à la croissance des cacaoyers. Les agriculteurs y produisent du cacao sur des petites exploitations familiales ou en coopérative [45]. La figure ci-dessous présente la répartition des régions de production de cacao.



**Figure 4 :** Représentation de la production de cacao en Côte d'Ivoire.

### 1.6.3. Evolution de la production en chiffres de 2010 à 2020

La production de cacao en Côte d'Ivoire a connu une croissance constante au cours des dernières décennies. En 2010, la Côte d'Ivoire a produit environ 1,4 million de tonnes de cacao, tandis qu'en 2020, la production de cacao était d'environ 2,0 à 2,5 millions de tonnes [46]. Cela représente une augmentation d'environ 30% à 80% sur une période de dix ans.

Cependant, il est important de noter que la production de cacao peut varier en fonction de nombreux facteurs, notamment les conditions climatiques, les prix du cacao sur les marchés mondiaux et les politiques gouvernementales. La Côte d'Ivoire est soumise à des conditions climatiques instables, ce qui peut entraîner des fluctuations dans la production de cacao d'une année à l'autre. Les efforts du gouvernement pour améliorer les conditions de production du cacao, tels que la mise en place de programmes de formation pour les agriculteurs, le fonds d'investissement pour améliorer les conditions de vie et de travail des producteurs et leurs communautés, la fourniture de semences de qualité et l'optimisation des opérations commerciales peuvent également avoir un impact sur l'évolution de la production de cacao.

#### **1.6.4. Impact économique de la production de cacao**

La production de cacao en Côte d'Ivoire est un secteur économique important pour le pays. En tant que premier producteur mondial de cacao, la Côte d'Ivoire dépend fortement de l'industrie pour sa croissance économique et l'emploi de millions de personnes. La production de cacao représente environ 40% des exportations du pays et contribue également à la croissance de l'agriculture, de l'industrie alimentaire et de la transformation. Cependant, la production de cacao peut également entraîner des défis sociaux et environnementaux, notamment des salaires bas pour les travailleurs agricoles, des pratiques d'agriculture nocives pour l'environnement et des problèmes de sécurité alimentaire pour les petits producteurs de cacao [47].

#### **1.6.5. Danger de la production de cacao**

Un mauvais état de santé des acteurs de la production permet d'avoir des effets négatifs sur la capacité et la productivité de la population active, et donc sur la production et le revenu des ménages. La production de cacao en Côte d'Ivoire peut également être menacée par des maladies de la culture du cacao [48]. Parmi lesquelles nous avons :

- **la moniliose** : C'est une maladie fongique qui affecte les feuilles et les fruits du cacao, réduisant ainsi la production de fèves de cacao ;
- **la maladie des racines** : Cette maladie est causée par un champignon qui attaque les racines du cacao, entraînant une dégradation progressive de la plante et une baisse de la production ;
- **la rouille du cacao** : Cette maladie est causée par un champignon et peut affecter les feuilles, les pousses et les fruits du cacao, réduisant la qualité et la quantité de la production ;
- **la maladie de la boursouflure des cabosses** : Cette maladie est causée par un virus et peut provoquer une boursouflure des cabosses, réduisant ainsi la quantité et la qualité des fèves de cacao produites ;
- **la pourriture des cabosses** : Cette maladie est causée par des bactéries et des champignons, qui peuvent endommager les fruits et réduire la quantité de fèves de cacao produites.

### **1.7. Espaces couleurs**

#### **1.7.1. Introduction à l'espace couleur en imagerie**

La Commission internationale de l'éclairage (CIE) est une organisation internationale qui traite les problématiques de la lumière, à l'éclairage, la couleur et leur représentation.

Fondée à Berlin en 1913 et aujourd'hui située à Vienne en Autriche, elle travaille à développer des méthodes pour représenter les couleurs de manière abstraite, en utilisant des mesures telles que la luminosité, la teinte, la saturation, etc [49]. La colorimétrie est une théorie décrite dans les sciences psychophysiques qui définit le principe de la reproduction des couleurs par le mélange des trois couleurs de base choisies indépendamment les unes des autres, selon des lois bien établies d'additivité et de proportionnalité. Cette théorie se base sur des principes expérimentaux de l'appariement des couleurs pour déterminer les proportions uniques de chaque couleur dans le mélange [50]. L'espace couleur est un modèle mathématique qui définit la manière de représenter les couleurs numériquement et il définit la gamme de couleurs disponibles. L'espace couleur est important pour l'affichage et le traitement d'image car il définit l'affichage sur différents écrans, ce qui est crucial pour une qualité d'image uniforme dans des applications telles que la photographie, la vidéographie, la conception graphique, etc [51]. De plus, en utilisant un espace couleur standardisé, les couleurs peuvent être facilement converties d'un système à l'autre sans perte de qualité, car il est important pour le partage et la diffusion de fichiers d'images. Chaque espace couleur est conçu pour une raison différente, et est utile pour différents types d'analyse et de traitement [52].


### **1.7.2. Espaces couleur courants en imagerie**

Il existe plusieurs espaces couleurs [53], mais les plus couramment utilisés sont les suivantes :

#### **1.7.2.1. Espace RGB**

L'espace RGB (Red, Green, Blue) est un modèle de couleur utilisé dans les systèmes informatiques pour représenter les couleurs visuelles. Dans cet espace, chaque couleur est représentée avec les composantes spectrales de rouge (longueur d'onde égale à 700,0 nm), vert (longueur d'onde à 546,1 nm) et bleu (longueur d'onde à 435,8 nm). Il peut être considéré comme la représentation fondamentale de couleur pour ordinateurs, appareils photo numériques et scanners ; mais aussi, pour le stockage d'images. La plupart des logiciels développés pour le traitement d'images et le graphisme utilisent ce modèle. Dans le modèle RGB, la combinaison de couleurs est basée sur l'addition des composants individuels en considérant comme base la couleur noire. Le processus peut être considéré comme la combinaison de trois rayons de couleur rouge, vert et bleu. L'intensité des différentes composantes de la couleur détermine à la fois la teinte et la luminosité de la couleur résultante. Il utilise des valeurs numériques pour décrire la quantité de rouge, de vert et de bleu nécessaires pour produire une couleur donnée. Cette représentation est utilisée pour les écrans d'affichage, l'impression et d'autres applications en imagerie numérique [54]. Pour la


conversion dans les espaces couleur CIE Luv et CIE Lab. Les composantes de couleur RGB sont remplacées par la valeur normalisée CIE XYZ composants comme base pour définir. La figure 5 présente le cube des composantes RGB [55].



**Figure 5 :** Cube représentant les composantes du RGB

### 1.7.2.2. Espace HSV

L'espace de couleur HSV (Hue, Saturation, Valeur) est un autre modèle de couleur couramment utilisé en informatique pour représenter les couleurs. Il utilise une combinaison de teinte (angle sur la roue des couleurs qui varie de 0 à 360 degrés), saturation (pureté de la couleur de la teinte dans la plage de 0 à 100) et valeur (luminosité indique l'intensité dans la plage de 0 à 100) pour décrire une couleur. Ce modèle est souvent considéré comme plus intuitif pour les utilisateurs, car il permet de sélectionner facilement des couleurs en fonction de leur teinte, saturation et luminosité, plutôt que de simplement spécifier des valeurs numériques pour le rouge, le vert et le bleu. La figure 6 présente le cône des composantes HSV [56].




**Figure 6 :** Cône représentant les composantes du HSV



### 1.7.2.3. Espace Lab

L'espace de couleur Lab est un modèle de couleur utilisé en informatique pour représenter les couleurs de manière uniforme, c'est-à-dire que les couleurs proches dans l'espace Lab sont perçues comme similaires par l'œil humain. L'axe L représente la luminosité (du blanc au noir), tandis que les axes a et b représentent les couleurs chromatiques (du vert au rouge et du bleu au jaune, respectivement). Ce modèle est souvent utilisé pour des applications nécessitant une comparaison précise entre les couleurs, telles que la correction des couleurs en imagerie numérique. La figure 7 représente les composantes de l'espace Lab [57].



**Figure 7 :** Représentation des composantes de l'espace Lab

### 1.7.2.4. Espace Luv

L'espace de couleur Luv est un modèle de couleur similaire à l'espace Lab, mais utilisant une représentation différente des couleurs chromatiques. Comme l'espace Lab, Luv est conçu pour être uniforme, ce qui signifie que les couleurs proches dans l'espace Luv sont perçues comme similaires par l'œil humain. L'axe L représente la luminosité (du blanc au noir), tandis que les axes u et v représentent les couleurs chromatiques (teintes uniformes). L'espace Luv est souvent utilisé en imagerie numérique pour la correction des couleurs et d'autres applications nécessitant une comparaison précise entre les couleurs.

### 1.7.3. Conversion entre différents espaces couleur

Il est possible de convertir les couleurs d'un espace de couleur à un autre en utilisant des algorithmes de transformation mathématique. La conversion dépend des formules spécifiques utilisées pour chaque espace de couleur, mais généralement les valeurs de chaque composante sont transformées pour correspondre aux nouvelles bases de couleur de la destination.

Dans le cas d'une conversion d'une couleur de l'espace RGB à l'espace Lab, il faut d'abord convertir les valeurs RGB en valeurs XYZ en utilisant une matrice de transformation, puis convertir les valeurs XYZ en valeurs Lab en utilisant une autre formule. Il est important de noter que la conversion entre les espaces de couleur peut entraîner une perte de qualité ou de précision, en particulier lorsque les couleurs sont transformées entre des espaces non compatibles. Par conséquent, il est souvent nécessaire de choisir soigneusement l'espace de couleur approprié pour chaque application [53].

#### **1.7.4. Utilisation de l'espace couleur dans les algorithmes de traitement d'image**

L'espace de couleur peut avoir un impact considérable sur les performances d'un algorithme de traitement d'image, car cela peut affecter la qualité et la précision des données d'entrée utilisées par l'algorithme. Les différents espaces de couleur peuvent offrir des avantages et des inconvénients en termes de facilité de traitement, de qualité de couleur, de précision et de compatibilité avec d'autres systèmes.

Certains algorithmes de traitement d'image sont conçus pour travailler avec des données en niveaux de gris, ce qui signifie qu'ils ne nécessitent qu'une seule valeur numérique pour représenter chaque pixel. Dans ce cas, l'utilisation de l'espace de couleur RGB peut rendre le traitement plus complexe et moins efficace, car il faut traiter trois valeurs différentes pour chaque pixel.

D'un autre côté, certains algorithmes de traitement d'image sont conçus pour travailler avec des couleurs chromatiques, et dans ce cas, l'utilisation d'un espace de couleur permettant une représentation précise des couleurs, comme l'espace Lab, peut améliorer les résultats. Le choix de l'espace de couleur dépend des exigences spécifiques de chaque algorithme de traitement d'image, et il est important de tenir compte des avantages et des inconvénients de chaque espace pour optimiser les performances de l'algorithme [58].

Les différents espaces de couleur peuvent être utilisés pour des tâches spécifiques de traitement d'image, en fonction de leurs caractéristiques et de leur capacité à représenter les données de couleur de manière efficace et précise. On peut citer en outre :

- **la détection de contours** : certaines applications de détection de contours, utilise des images en niveaux de gris pour simplifier le processus de détection des bords ce qui nécessite qu'une seule valeur numérique pour chaque pixel. Dans ce cas, il peut être utile de convertir les images RGB en niveaux de gris en utilisant une formule de luminosité moyenne ;

- **la segmentation d'image** : pour réaliser la segmentation d'image, il est souvent préférable d'utiliser des espaces de couleur qui permettent une séparation précise des couleurs similaires, comme l'espace Lab ou Luv, il permet de faciliter la sélection des pixels appartenant à des régions spécifiques de l'image basées sur leurs couleurs ;
- **la correction des couleurs** : la correction des couleurs nécessite l'utilisation des espaces de couleur qui sont uniformes, comme l'espace Lab ou Luv. Ils permettent de garantir que les modifications apportées aux couleurs sont perçues de manière cohérente par l'œil humain, même si les valeurs numériques des couleurs ont changé.

De manière générale, le choix de l'espace de couleur dépend des exigences spécifiques de chaque tâche de traitement d'image et de la capacité de l'espace à représenter les données de couleur de manière efficace et précise.

## **1.8. Imagerie numérique dans le domaine de l'agriculture**

### **1.8.1. Généralité**

L'imagerie numérique est une technique de capture, de traitement et d'analyse d'images numériques. Cette technique permet de produire des images de qualité supérieure et permet le stockage, le traitement et l'analyse des données en temps réel. Elle est utilisée dans de nombreux domaines, tels que la médecine, la cartographie, la reconnaissance d'objets, la surveillance de la sécurité, etc. Dans le domaine de l'agriculture, l'imagerie numérique offre de nombreuses opportunités pour améliorer les pratiques agricoles et surveiller les ressources naturelles, en permettant une observation et une analyse plus précises et efficaces de l'état des cultures et de l'environnement.

L'imagerie numérique est de plus en plus utilisée dans le domaine de l'agriculture pour améliorer la productivité et la qualité des cultures, ainsi que pour surveiller les ressources naturelles et les écosystèmes.

Les images aériennes et satellitaires sont souvent utilisées pour cartographier les terres cultivées, évaluer la croissance des cultures et détecter les problèmes tels que les maladies des plantes, les infestations d'insectes et les stress hydriques. Les algorithmes de reconnaissance d'image peuvent également être utilisés pour mesurer la maturité des cultures, ce qui aide les agriculteurs à déterminer le moment idéal pour récolter les récoltes. En plus de ces applications, l'imagerie numérique peut également être utilisée pour surveiller l'état des ressources naturelles, comme les réserves d'eau et les sols, ainsi que pour évaluer les impacts des pratiques agricoles sur l'environnement [59].

L'imagerie numérique offre de nombreuses opportunités pour améliorer les pratiques agricoles et surveiller les ressources naturelles dans le domaine de l'agriculture, en permettant une observation et une analyse plus précises et efficaces de l'état des cultures et de l'environnement. On distingue principalement différents types d'imagerie numérique utilisés dans l'agriculture, on peut citer :

### **1.8.2. Imagerie aérienne**

L'imagerie aérienne est une technique qui permet la prise d'image numérique de la Terre depuis le ciel. Ces images peuvent être prises depuis des avions, des hélicoptères, des drones, des ballons et des satellites. Les images aériennes sont utilisées dans des applications variées, telles que la cartographie, la surveillance environnementale, la gestion des ressources naturelles, la planification urbaine et la recherche scientifique. Les avancées technologiques de l'imagerie, telles que la résolution élevée et la capacité de capturer des images en couleur et en trois dimensions, ont rendu l'imagerie aérienne de plus en plus précieuse pour une variété d'industries et de domaines d'application [60]. Elles peuvent être utilisées pour évaluer la santé des cultures, identifier les zones problématiques et planifier les activités de traitement des cultures. La figure 8 présente un exemple [61].




**Figure 8 :** Image aérienne de plantation

### **1.8.3. Imagerie satellitaire**

L'imagerie satellitaire désigne l'ensemble des images captées par des satellites en orbite autour de la Terre. Ces images peuvent être utilisées pour de nombreuses applications telles que la surveillance de la Terre, la cartographie, la gestion des ressources naturelles, la

prévision météorologique, la recherche scientifique, etc. Il existe plusieurs types d'images satellites, notamment des images multispectrales qui captent la lumière dans différentes longueurs d'onde, des images radar qui utilisent des ondes radio pour détecter des objets et des surfaces, et des images panchromatiques qui captent la lumière dans toutes les couleurs visibles.

Les images satellitaires sont utilisées conjointement avec d'autres données pour fournir des informations détaillées sur la Terre et son environnement. Elles sont combinées avec des données topographiques pour créer des cartes en 3D de la surface de la Terre, également pour surveiller les changements environnementaux tels que la déforestation, la perte de la couverture neigeuse, et les émissions de gaz à effet de serre. Les images satellitaires fournissent une vue complète des champs et des fermes pour surveiller l'état des cultures et identifier les zones de stress [62]. La figure 9 représente des images satellitaires pour l'aménagement des territoires [63].




**Figure 9 :** Image satellitaire pour l'aménagement des territoires

#### **1.8.4. Imagerie multispectrale**

L'imagerie multispectrale permet de collecter et d'analyser des données à plusieurs longueurs d'onde du spectre électromagnétique, du visible, de l'infrarouge et des ondes radio. Les capteurs multispectraux sont utilisés pour capturer des données en utilisant différents filtres pour sélectionner des bandes spécifiques de longueurs d'onde. L'utilisation de l'imagerie multispectrale est utile pour une variété d'applications, telles que la cartographie de la végétation, la détection de l'agriculture, la reconnaissance des ressources minérales, la surveillance de l'environnement et la reconnaissance de la scène. Les images multispectrales fournissent une information complète sur les caractéristiques du terrain qui est très utile pour

la planification territoriale, la gestion des ressources naturelles et la surveillance environnementale. Il existe plusieurs types de capteurs multispectraux, y compris les caméras multispectrales, les radars multispectraux et les spectromètres. Chacun de ces capteurs utilise une combinaison de filtres et de détecteurs pour collecter des données à différentes longueurs d'onde. Les images multispectrales peuvent également être produites en combinant les données collectées par plusieurs capteurs différents. Elles peuvent être utilisées pour évaluer les besoins en nutriments, identifier les maladies et les ravageurs, et planifier les activités de traitement des cultures [64]. La figure 10 présente un exemple d'image multispectrale.




**Figure 10 :** Image multispectrale

#### **1.8.5. Imagerie thermique**

L'imagerie thermique est une technique permettant de visualiser et de mesurer les radiations infrarouges émises par les objets et les surfaces. Elle est utilisée dans de nombreux domaines, notamment la maintenance préventive, l'inspection de bâtiments, la recherche médicale, l'analyse environnementale, la surveillance de la sécurité, etc.

L'imagerie thermique utilise des caméras spécialement conçues pour détecter les radiations infrarouges et les convertir en une image visible. Cette image peut être utilisée pour identifier les anomalies de température, les fuites d'air, les défauts électriques et les défauts mécaniques, entre autres. L'avantage de l'imagerie thermique par rapport à d'autres méthodes de mesure de la température est qu'elle permet de visualiser les variations de température sur une grande surface en même temps, ce qui peut faciliter la localisation rapide de problèmes potentiels. De plus, elle est utilisée pour mesurer la température dans des conditions difficiles, telles que les environnements sombres, humides ou dangereux pour les personnes. Les images thermiques peuvent être utilisées pour mesurer la température des cultures et identifier les zones de stress [65], la figure 11 présente une image thermique [66].



**Figure 11** : Image thermique de culture

#### **1.8.6. Utilisation de l'imagerie numérique**

L'imagerie numérique joue un rôle clé dans le domaine de l'agriculture en fournissant des informations précises et à jour sur l'état des cultures, des terres et des équipements. Les besoins en imagerie numérique dans le domaine de l'agriculture peuvent inclure :

- **la Surveillance des cultures** : l'analyse de l'imagerie satellite peut aider les agriculteurs à surveiller l'état des cultures et à détecter les maladies et les parasites précocement ;
- **le Mapping des terres agricoles** : l'utilisation de la télédétection peut aider les agriculteurs à cartographier leurs terres et à surveiller les changements au fil du temps ;
- **l'Amélioration de l'irrigation** : les données d'imagerie peuvent être utilisées pour optimiser les systèmes d'irrigation en identifiant les zones les plus sèches et en mesurant la consommation d'eau ;
- **l'Optimisation des pratiques culturales** : l'analyse de l'imagerie peut aider les agriculteurs à identifier les zones de leurs champs qui nécessitent une attention particulière et à optimiser les pratiques culturales en conséquence ;
- **la Planification des récoltes** : les données d'imagerie peuvent aider les agriculteurs à planifier les récoltes en fonction de l'état des cultures et des conditions météorologiques.

Les besoins en imagerie numérique dans le domaine de l'agriculture sont nombreux et variés, allant de la surveillance de la santé des cultures à la planification des récoltes en passant par l'optimisation des pratiques culturales et l'amélioration de l'irrigation.

## **Conclusion**

Au terme de ce chapitre, l'intelligence artificielle, le Machine Learning et le Deep Learning sont des domaines en constante évolution qui ont un impact significatif sur de nombreux secteurs, y compris l'agriculture. L'application de ces technologies pour améliorer les récoltes de café et de cacao est un domaine en plein essor et serait très bénéfique pour l'agriculture en Côte d'Ivoire. L'analyse de l'espace couleur et de l'imagerie numérique peut également aider à améliorer la qualité de ces produits agricoles. La revue de la littérature montre que les recherches menées dans ce domaine sont prometteuses et pourraient mener à des améliorations significatives dans la production agricole. Il est donc important de continuer à explorer les différents moyens d'utiliser l'IA pour améliorer les méthodes agricoles et augmenter la qualité des produits.



## **Chapitre 2 : Classification et reconnaissance des maladies des feuilles de café à l'aide des algorithmes du Machine Learning et du Deep Learning**

*(“Experimental Evaluation of Coffee Leaf Disease Classification and Recognition Based on Machine Learning and Deep Learning Algorithms”, KJ AYIKPA, D MAMADOU, P GOUTON, KJ ADOU, Journal of Computer Science 18 (12), 1201-1212, 2022)*

### **Introduction**

Les maladies de plantes de café représentent un risque prépondérant à la production mondiale du café et le défi majeur est de détecter ces maladies le plus tôt possible en vue de sauver les récoltes. Les méthodes traditionnelles sont le plus souvent basées sur des observations visuelles avec souvent des erreurs de diagnostic de maladies de plantes. Le machine Learning est devenu un outil qui se présente comme une alternative pour identifier automatiquement les maladies des plantes. Dans l'agriculture moderne, les approches du machine Learning sont très utilisées pour leur robustesse. Notre étude consiste à mettre en place une méthode robuste de classification et de reconnaissance de maladie de feuilles de café en utilisant aussi bien des méthodes de machine Learning classique que des méthodes de Deep Learning, aussi nous avons mis en place un CNN personnalisé. Ces méthodes ont été évaluées sur le jeu de données des feuilles de café Arabica connus sous le nom de JMuBEN. Les résultats des méthodes classiques du machine Learning ont fourni des résultats qui varient entre 81.03% et 100% et la meilleure performance a été obtenue avec SVM et le Random Forest ; tandis que les méthodes du Deep Learning ont fourni des résultats entre 97.37% et 100% avec notre custom CNN qui a obtenu la meilleure précision avec une plus faible perte soit 0.013%. Les métriques de performance utilisées en l'occurrence la précision, le MSE, le F-score, le Recall et le MCC ont été utilisés pour confirmer cette bonne performance.

### **2.1. Généralités**

L'agriculture est le secteur dans lequel nous retrouvons l'exploitation de la terre pour obtenir des cultures et aussi l'exploitation animal appelée élevage. Elle est confrontée à tout moment à des maladies qui risquent de mettre en péril la production. Les maladies ont un effet néfaste sur les plantes et les animaux et impacte l'accès au marché à la production agricole. Parmi ces maladies, celles de la plante constituent un véritable obstacle en termes de rendement et de qualité pour les producteurs [67]. Les maladies des plantes peuvent être divisées en plusieurs types en l'occurrence fongiques, oomycètes, hyphomycetes, bactériens et viraux [68]. Le café est l'un des produits les plus consommés avec une production

mondiale de plus de 7 millions de tonnes par an [69]. Le Kenya, second producteur africain d'arabica est confronté à des maladies qui s'attaquent aux feuilles de café ce qui impacte sa production [70]. Ces maladies concernées sont le cercospora, La rouille du caféier et phoma [71].

Identifier les maladies et savoir quand et comment y remédier efficacement est le challenge permanent pour les producteurs. Les symptômes de la maladie peuvent apparaître sur les feuilles à n'importe quel stade de la croissance de la plante.

La détection et la reconnaissance précoce des maladies permettent de réduire au maximum les pertes des cultures. Le processus de détection manuelle des maladies des plantes n'est pas assez fiable et très difficile dans les grandes exploitations [72]. La détection en utilisant la vision par ordinateur pour la détection des maladies de plantes permettront aux experts de faire des mesures à titre préventif sur les détections précoces. La reconnaissance et la classification des maladies des feuilles de café sont d'une importance économique et technique majeure dans l'industrie agricole. Ces dernières années, la vision par ordinateur a été utilisée pour la détection d'objets et la classification d'images et a réalisé d'énormes progrès.


Nous pouvons noter plusieurs techniques qui ont été proposées qui permettent le diagnostic des maladies de plante. Ramcharan et al. ont appliqué l'apprentissage par transfert pour former un réseau neuronal convolutif profond afin d'identifier trois maladies et deux types de dommages causés par les ravageurs avec une précision globale de 93 % [73]; Saleem et al. ont mis en place le modèle SSD entraîné avec un optimiseur Adam et a présenté la précision moyenne la plus élevée de tous les modèles d'apprentissage profond soit 73,07 % [74]; Afifi et al. proposent l'utilisation des réseaux neuronaux convolutifs (CNN) pour leur capacité d'apprentissage par transfert, trois architectures CNN (ResNet18, ResNet34 et ResNet50) ont été utilisées pour construire deux modèles de base, un réseau Triplet et un réseau profond d'apprentissage métrique adversatif (DAM). Ces méthodes atteignent une précision de 81% à 99% [75]; Xiao et al. proposent un réseau de neurone convolutif en l'occurrence ResNet50 avec une technique de deux ensembles de données différents contenant les images originales et les images caractéristiques. La précision de la classification est de 100% pour les cas de brûlure de la feuille affectant la couronne, la feuille et le fruit ; 98% pour les cas de moisissure grise et 98% pour les cas d'oïdium [76]; Yang et al. ont utilisé un module de fusion de caractéristiques fusionne les caractéristiques d'image apprises par le module de rééquilibrage convolutif et garantit que l'extraction de caractéristiques du jeu de données déséquilibré est plus complète. Leurs résultats ont démontré des performances

supérieures aux méthodes de pointe, avec une précision de 97.58 % sur le jeu d'images de ravageurs et de maladies du riz [77]; Shao et al. ont proposé une méthode qui combine le modèle LC-FCN (réseau de neurones convolutifs à comptage basé sur la localisation) basé sur l'apprentissage par transfert avec l'algorithme de la ligne de partage des eaux pour la reconnaissance d'images de riz denses avec une précision 89.88% [78].

Cependant notre étude consiste dans un premier temps à utiliser des algorithmes du machine Learning classique en l'occurrence le Support vector Machine(SVM), le K-Nearest Neighbors(K-NN), le Random Forest, le Logic Regression, le Multi-layer Perceptron Classifier(MLPClassifier), Decision Tree Classifier(DTClassifier) , Stochastic Gradient Descent Classifier(SGDClassifier), Gaussian Naive Bayes(GNB) et dans un second temps à utiliser des algorithmes du deep Learning plus précisément des réseaux de neurones convolutifs à savoir MobileNet, VGG-19, Iception-V3, DenseNet-201, ResNet-50 et enfin notre Custom CNN. Enfin une comparaison sera effectuée pour faire ressortir les modèles les plus robustes de notre étude.

## **2.2. Jeu de données**

La base de données utilisées pour cette étude est le jeu de données sur les feuilles de café Arabica connus sous le nom de JMuBEN, elle est constituée d'images de feuilles de café d'une plantation dans le comté de Kirinyaga au Kenya. Le premier dossier contient 7682 images de Cercospora, le second contient 8337 images de rouille et le dernier contient 6572 images de Phoma. Nous avons également ajouté un dossier de 8927 image saine du dossier JMuBEN2. En somme le jeu de données de notre étude contient 31518 images de feuilles de café réparties en quatre classes en l'occurrence Phoma, Cercospora, Rouille et sain) [71]. La figure 12 montre les échantillons des feuilles de café.



**Figure 12** : Échantillons d'images des différentes maladies de la feuille de café : (a) Cercospora ; (b) Healthy ; (c) Leaf rust ; (d) Phoma.

Notre jeu de données sera divisé comme le montre le tableau ci-dessous :

**Tableau 1** : Répartition du jeu de données

Jeu de données	Entrainement	Validation	Test
100%	60%	20%	20%
31518	18909	6303	6303

### 2.3. Algorithmes d'apprentissage automatique

Les algorithmes d'apprentissage automatique sont des outils qui permettent aux machines d'apprendre à partir de données, sans être explicitement programmées. Ils sont largement utilisés dans de nombreux domaines, notamment dans la reconnaissance de la parole, la classification d'images, la détection de fraude et la recommandation de produits. Les algorithmes d'apprentissage automatique se divisent en deux grandes catégories :

l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage par renforcement [79].

### **2.3.1. Apprentissage supervisé**

En apprentissage supervisé, le système est aidé dans son apprentissage, on lui présente des données en entrées et les sorties que l'on souhaite avoir. Le système va ensuite généraliser ce qu'il a appris pour les autres données non apprises. L'algorithme développera une fonction qui permettra de faire une prédiction précise de la sortie à partir des données en entrée. L'apprentissage supervisé est divisé en deux catégories en l'occurrence :

- **la régression** : Dans ce cas la variable en sortie est une catégorie ;
- **la classification** : Dans ce cas la variable en sortie est une valeur numérique.

Ces principaux algorithmes sont : forêts aléatoires, arbres décisionnels, méthode du k plus proche voisin (k-NN), régression linéaire, classification naïve bayésienne, machine à vecteurs de support (SVM), régression logistique et boosting des gradients etc.

### **2.3.2. Apprentissage non supervisé**

En apprentissage non supervision, le système ne reçoit aucune aide pour déterminer la structure des données en entrée. L'algorithme cherchera à découvrir des caractéristiques dans les données pour d'atteindre un certain but. Cette approche est également appelée apprentissage des caractéristiques. Ces principaux algorithmes sont : K-Means, clustering/regroupement hiérarchique et réduction de la dimensionnalité.

### **2.3.3. Apprentissage par renforcement**

En apprentissage par renforcement, le système fait l'apprentissage en interaction avec le milieu environnant. À tout moment, le système obtient l'état actuel et toutes les actions possibles. Il effectue une des actions et reçoit un signal de retour qui lui notifie son nouvel état et la récompense associée. A force d'itération, le système doit pouvoir déterminer automatiquement le comportement idéal (celui qui maximise les récompenses) pour un contexte spécifique. Ce type d'apprentissage est également dit « semi-supervisé » dans la mesure où la récompense donne une indication sur le bon résultat à atteindre

### **2.3.4. Support Vector Machine (SVM)**

Les SVM sont utilisés pour la classification, la régression et la détection des valeurs aberrantes. Le SVM construit un hyper-plan ou un ensemble d'hyper-plans dans un espace de dimension élevée ou infinie, qui peut être utilisé pour la classification, la régression ou d'autres tâches. Intuitivement, une bonne séparation est obtenue par l'hyper-plan qui a la plus

grande distance aux points de données d'apprentissage les plus proches de n'importe quelle classe, car en général plus la marge est grande, plus l'erreur de généralisation du classificateur est faible [80].

Le SVM résout l'équation d'optimisation suivante :

$$\begin{aligned} \min_{\omega, b, \zeta} \quad & \frac{1}{2} \omega^T \omega + C \sum_{i=1}^m \zeta_i \\ \text{s.t.} \quad & y_i(\omega^T \Phi(x_i) + b) \geq 1 - \zeta_i, \\ & \zeta_i \geq 0, i = 1, \dots, n \end{aligned} \tag{2-1}$$

$\omega$  : c'est un vecteur de poids qui représente l'orientation et l'inclinaison de l'hyperplan séparateur.  $\omega$  est un vecteur de taille  $n$ .

$b$  : c'est un scalaire qui représente le biais de l'hyperplan séparateur, c'est-à-dire la distance entre l'hyperplan et l'origine de l'espace.

$\zeta$  : est un ensemble de variables dites de "hinge loss" qui mesurent la distance entre chaque point de données et l'hyperplan séparateur. Si un point est bien classé,  $\zeta_i$  est nul, sinon  $\zeta_i$  est positif et représente la marge de séparation violée.

$C$  : c'est un paramètre de régularisation qui contrôle la trade-off entre la maximisation de la marge et la minimisation de la violation des marges. C'est un nombre positif qui détermine la pénalité appliquée à chaque point mal classé.

$\Phi(x_i)$  : c'est une fonction de transformation de l'espace qui permet de projeter les données d'entrée dans un espace de grande dimension, souvent appelé espace de caractéristiques. Cette fonction est choisie en fonction du domaine d'application et peut être linéaire ou non-linéaire.

$y_i$  : c'est la classe de l' $i$ ème point de données, qui peut prendre les valeurs -1 ou +1 en fonction de la classe à laquelle le point appartient.

### 2.3.5. K-nearest neighbors (K-NN)

Le K-NN est un algorithme de classification non paramétrique qui se base sur les données d'entraînement. Il utilise le calcul de la distance pour mesurer la similarité des données de test avec les données utilisées pour la formation. Par la suite, les données de test sont classifiées par un vote majoritaire des  $k$  plus proches voisins de l'ensemble d'apprentissage [81]. Le calcul de la distance utilisé est la distance euclidienne, sa formule est la suivante :

$$D(x, y) = \sqrt{\sum_{j=1}^n (x_j - y_j)^2} \quad (2-2)$$

### 2.3.6. Random Forest (RF)

Random Forest est un algorithme d'apprentissage supervisé utilisé pour la classification, la régression et la détection d'anomalies. Il est basé sur la méthode de l'agrégation de modèles, qui combine plusieurs arbres de décision pour améliorer la précision et la stabilité des prédictions. Le principe de Random Forest consiste à créer un grand nombre d'arbres de décision en utilisant des échantillons aléatoires de données et de variables d'entrée. Chaque arbre est entraîné sur un sous-ensemble de données et de variables choisis aléatoirement. Ensuite, les prédictions de tous les arbres sont agrégées pour produire une prédiction finale. Le processus de construction des arbres de décision dans Random Forest implique la sélection de la variable la plus discriminante à chaque étape de la construction de l'arbre. Cette sélection est basée sur des critères tels que l'entropie, le gain d'information ou le coefficient de Gini. Random Forest a de nombreux avantages par rapport à d'autres algorithmes d'apprentissage automatique. Il est moins sensible au surapprentissage et peut gérer des ensembles de données de grande taille et à haute dimensionnalité. Il est également capable de gérer des données manquantes et des valeurs aberrantes. Random Forest est largement utilisé dans de nombreux domaines, notamment la finance, l'épidémiologie, la biologie et la reconnaissance de formes. Il est également couramment utilisé dans les compétitions de science des données en raison de sa précision et de sa polyvalence. Chaque arbre dispose d'une vision autonome du problème du fait d'un double tirage aléatoire à savoir le Tree bagging et le Feature sampling. Toutes les décisions des arbres sont fédérées et la décision prise par le RF pour des données de test est alors le vote de tous les arbres. Le taux d'erreur de Random Forest est fonction de la corrélation entre deux arbres, et de précision de chaque arbre [82].

### 2.3.7. Régression Logistique (LR)

La régression logistique est un modèle de régression binomiale. Il permet de modéliser au mieux un modèle mathématique simple à des observations réelles nombreuses. La régression logistique constitue un cas particulier de modèle linéaire généralisé à laquelle on appliquera la fonction sigmoïdale. Le modèle de régression logistique est entraîné en ajustant les coefficients de manière à maximiser la vraisemblance des données d'entraînement. La vraisemblance est une mesure de la probabilité que les données observées soient générées par

le modèle. L'ajustement des coefficients se fait en utilisant des techniques d'optimisation telles que la descente de gradient. Les coefficients sont ajustés pour minimiser la fonction de coût, qui mesure l'écart entre les prédictions du modèle et les valeurs réelles. La régression logistique peut également être étendue à des problèmes de classification multi-classes en utilisant des techniques telles que la régression logistique multinomiale ou la classification d'un-contre-tous (one-vs-all). Il est largement utilisé dans de nombreux domaines, notamment la médecine, la finance, la biologie et la science des données en raison de sa simplicité et de sa facilité d'interprétation. Elle est également souvent utilisée comme modèle de référence pour comparer les performances d'autres algorithmes de classification plus complexes. Pour produire l'équation de la régression logistique, on utilise le rapport du maximum de vraisemblance pour déterminer la signification statistique des variables [83].

### **2.3.8. Multi-layer Perceptron Classifier (MLP)**

C'est un type de réseau de neurones artificiels qui peut être utilisé pour résoudre des problèmes de classification non linéaires. Le MLP est constitué d'au moins trois couches de neurones : une couche d'entrée, une ou plusieurs couches cachées, et une couche de sortie. Les neurones dans chaque couche sont connectés à tous les neurones de la couche suivante. Les neurones dans les couches cachées utilisent une fonction d'activation pour transformer les entrées et produire une sortie. Les sorties des neurones de la couche de sortie sont souvent interprétées comme les probabilités de chaque classe d'appartenance. Le processus d'apprentissage du MLP implique l'utilisation d'un algorithme de rétropropagation pour ajuster les poids des connexions entre les neurones afin de minimiser l'erreur de classification. Cet algorithme utilise la méthode de la descente de gradient pour trouver le minimum global de la fonction de perte. Le MLP peut être utilisé pour résoudre une grande variété de problèmes de classification, y compris la reconnaissance de caractères manuscrits, la classification d'images et la détection de fraude. Cependant, il peut être sensible au sur-apprentissage, en particulier lorsqu'il y a un grand nombre de variables d'entrée. L'apprentissage supervisé utilisant l'algorithme de rétropropagation est plus souvent utilisé pour former le MLP. C'est une évolution du perceptron monocouche corrigeant les faiblesses de celui-ci. [84].

### **2.3.9. Decision Tree Classifier (DTC)**

Le DTC est une technique utilisant un arbre de décision à partir de données d'entraînement. Le modèle apprend à partir de données d'entraînement pour construire l'arbre de décision, qui peut être utilisé pour prédire la classe de nouvelles données. L'arbre de



décision est construit en sélectionnant la variable qui divise le mieux les données en sous-ensembles homogènes. Cette opération est répétée de manière récursive sur chaque sous-ensemble jusqu'à ce que tous les sous-ensembles soient homogènes ou que le critère d'arrêt soit atteint. Le critère d'arrêt peut être une profondeur maximale de l'arbre, un nombre minimal d'observations dans chaque sous-ensemble ou un seuil de pureté minimal. L'arbre de décision est une méthode simple et interprétable de classification, car il peut être visualisé graphiquement. Cependant, les arbres de décision ont tendance à surapprendre les données d'entraînement, ce qui peut entraîner une mauvaise généralisation aux données de test. Il est souvent nécessaire de régulariser l'arbre de décision, en limitant sa profondeur, en imposant un nombre minimal d'observations dans chaque sous-ensemble ou en utilisant des techniques de coupure.

Le modèle peut également être amélioré en utilisant des variantes telles que les arbres de décision aléatoires ou les arbres de décision gradient boosting. Les arbres de décision aléatoires créent des arbres en utilisant des sous-ensembles aléatoires des variables, tandis que les arbres de décision gradient boosting utilisent des arbres de décision plus faibles et les combinent pour former un modèle plus puissant. Les classificateurs à arbre de décision sont également connus comme classificateurs multi-niveaux.

### **2.3.10. Gaussian Naive Bayes (GNB)**

Le GNB est un classificateur basé sur un modèle génératif avec un processus d'apprentissage et de test rapide. Les classificateurs bayésiens, fonctionnent sur la base de la règle bayésienne et des théorèmes de probabilité pour prédire la probabilité qu'une observation donnée appartienne à une certaine classe. Le modèle suppose que toutes les variables d'entrée sont indépendantes et ont une distribution normale. Ainsi, chaque variable d'entrée est modélisée par une distribution de probabilité gaussienne avec une moyenne et une variance spécifique. Les paramètres de la distribution sont estimés à partir des données d'entraînement. Le modèle calcule ensuite la probabilité conditionnelle de chaque classe, étant donné les variables d'entrée, à l'aide de la formule du théorème de Bayes. La classe prédite est celle qui a la plus grande probabilité conditionnelle. Le modèle de classification de Bayes naïf gaussien est simple et rapide, avec une complexité de temps linéaire par rapport à la taille des données. Il est particulièrement utile pour les ensembles de données de petite et moyenne taille, avec des variables d'entrée continues.

Cependant, le modèle suppose que toutes les variables d'entrée sont indépendantes, ce qui peut ne pas être le cas dans certaines situations. De plus, si les données ne suivent pas une

distribution gaussienne, le modèle peut être inapproprié. Dans de tels cas, d'autres modèles de classification peuvent être préférables. La classification naïve gaussienne de Bayes est un cas de méthode naïve de Bayes avec l'hypothèse de l'existence d'une distribution gaussienne sur les valeurs des attributs de classe [85]. Sa formule générale est :

$$P(x_i|y) = \frac{1}{\sqrt{2\pi\sigma_y^2}} \exp\left(-\frac{(x_i - \mu_y)^2}{2\sigma_y^2}\right) \quad (2-3)$$

## 2.4. Algorithmes de réseaux de neurones convolutifs (CNN)

Le Deep Learning a été appliqué avec succès dans plusieurs domaines de recherche, en l'occurrence l'agriculture, la santé, l'éducation, l'environnement et la santé [86]. Dans cette étude nous allons utiliser les réseaux de neurones convolutifs qui est un type d'architectures du Deep Learning. Le CNN est un algorithme du Deep Learning qui est très utilisé en vision par ordinateur, notamment pour le traitement du langage naturel, la reconnaissance de la parole, la reconnaissance des visages, etc. Il est composé de trois principales couches à savoir la couche de convolution, la couche de pooling et les couches entièrement connectées [87].

- **la couche de Convolution** : C'est un élément clé des réseaux de neurones convolutifs. Elle a pour rôle de repérer la présence de points de caractéristique dans les images qu'elle reçoit. Elle consiste à appliquer un filtre sur l'image d'entrée pour extraire des caractéristiques visuelles telles que les bords, les formes ou les textures. Le filtre glisse sur l'image en effectuant des multiplications et des additions pour produire une carte de caractéristiques. Cette carte peut être ensuite réduite en taille en appliquant une opération de sous-échantillonnage pour améliorer l'efficacité et la robustesse du réseau. La couche de Convolution permet ainsi d'extraire les informations les plus pertinentes des images en vue d'une classification ou d'une détection d'objets ;
- **La couche de Pooling** : La couche de pooling, également connue sous le nom de couche de sous-échantillonnage, est une couche couramment utilisée dans les réseaux de neurones convolutifs (CNN) pour réduire la taille des données en sortie des couches convolutives. Cette couche agit en échantillonnant les entrées et en réduisant la résolution spatiale des caractéristiques extraites. Les deux types de pooling les plus couramment utilisés sont le max pooling et le average pooling. Le max pooling prend la valeur maximale dans chaque fenêtre de pooling, tandis que l'average pooling prend la moyenne des valeurs. Cette couche permet de réduire la

dimensionnalité des données, de minimiser le surapprentissage et d'améliorer la généralisation. Les choix les plus communs sont des cellules adjacentes de taille  $2 \times 2$  pixels qui ne se chevauchent pas, ou des cellules de taille  $3 \times 3$  pixels, distantes les unes des autres d'un pas de 2 pixels. Généralement, cette couche est positionnée entre deux couches de convolution. On obtient en sortie les mêmes points de caractéristiques mais de plus petite taille.

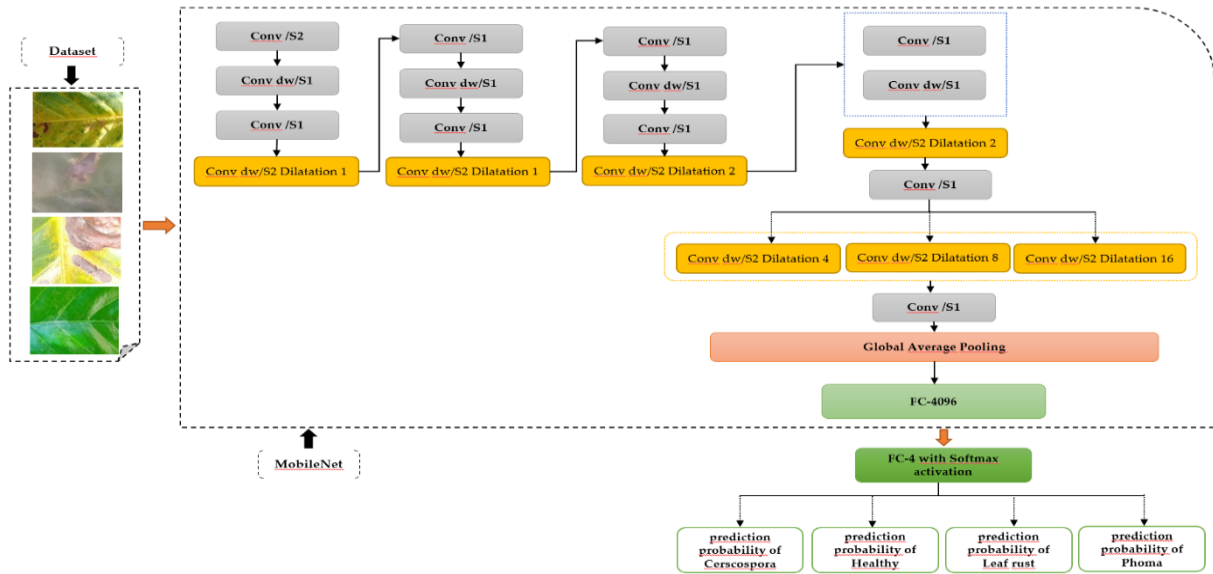
- **les couches Entièrement Connectées** : Les couches entièrement connectées sont des couches utilisées dans les réseaux de neurones artificiels. Ces couches sont couramment utilisées dans les réseaux de neurones profonds pour la classification, la régression et la génération de texte. Les couches entièrement connectées sont utilisées pour transformer les entrées en une sortie en appliquant une combinaison linéaire des entrées, suivie d'une fonction d'activation non linéaire. Cependant, l'utilisation de nombreuses couches entièrement connectées peut entraîner une lenteur dans l'apprentissage. C'est pourquoi d'autres types de couches, comme les couches de convolution et les couches récurrentes, sont également couramment utilisées dans les réseaux de neurones profonds.

Dans cette étude, nous avons utilisé les réseaux de neurone convolutifs les algorithmes sous la forme non pré entraînée suivants : MobileNet, VGG-19, Inception-V3, DenseNet-201, ResNet50 et CNN personnalisé.

#### **2.4.1. MobileNet**

MobileNet utilise des convolutions séparables en profondeur. Il est capable de réduire le nombre de paramètres sans perdre en précision. Cela permet d'obtenir des réseaux neuronaux profonds légers. Il est composé deux couches principales en l'occurrence les couches ponctuelles (pw) et les couches profondes (dw). MobileNet a été mise en libre accès par Google. Les couches profondes sont convolutives avec un noyau de taille  $3 \times 3$  et les couches ponctuelles sont également convolutives avec un noyau de taille  $1 \times 1$ . Ces couches utilisent la fonction d'activation unité linéaire rectifiée et l'algorithme de normalisation par lots. MobileNet a 19 couches profondes [88].

La figure 13 ci-dessous présente l'application de l'architecture de MobileNet à notre étude.



**Figure 13 :** L'architecture de MobileNet appliquée à notre étude

## 2.4.2. VGG-19

VGG-19 est une variante du réseau de géométrie visuelle VGGNet qui est un réseau de neurones profonds avec une multicouche. Il a été créé à l'Université d'Oxford. Le VGG-19 est constitué de 19 couches qui utilise des couches convolutives avec un noyau de taille 3×3 avec des couches de max-pooling. Il possède deux couches entièrement connectées, comportant chacune 4096 nœuds, sont ensuite suivies d'une couche Softmax qui, ensemble, forment le classificateur [89].

La figure 14 présente l'application de l'architecture de VGG-19 à notre étude.



**Figure 14 :** L'architecture de VGG-19 appliquée à notre étude

### 2.4.3. Inception-V3

Inception est un réseau de neurone convolutive largement utilisé dans les tâches de classification. La structure du réseau Inception est au cœur du réseau GoogLeNet. Plusieurs versions de Inception existent en l'occurrence Inception v1 (2014), Inception v2 (2015), Inception v3 (2015), Inception v4 (2016), et Inception-ResNet (2016). Le module Inception contient généralement trois tailles différentes de convolution et une mise en commun maximale. Pour la sortie du réseau de la couche précédente, le canal est agrégé après l'opération de convolution, puis les éléments non liés au réseau sont regroupés.

Par rapport aux versions précédentes (Inception v1 et v2), la structure de réseau d'Inception v3 utilise une méthode de division par noyau de convolution pour diviser les grandes intégrales de volume en petites convolutions. Par exemple, une convolution 3\*3 est divisée en 3\*1 et 1\*3. Grâce à la méthode de division, le nombre de paramètres sera réduit, cela permettra d'accélérer la vitesse d'apprentissage du réseau et la caractéristique spatiale peut être extraite plus efficacement [90]. La figure 15 ci-dessous présente l'application de l'architecture de Inception-V3 à notre étude.

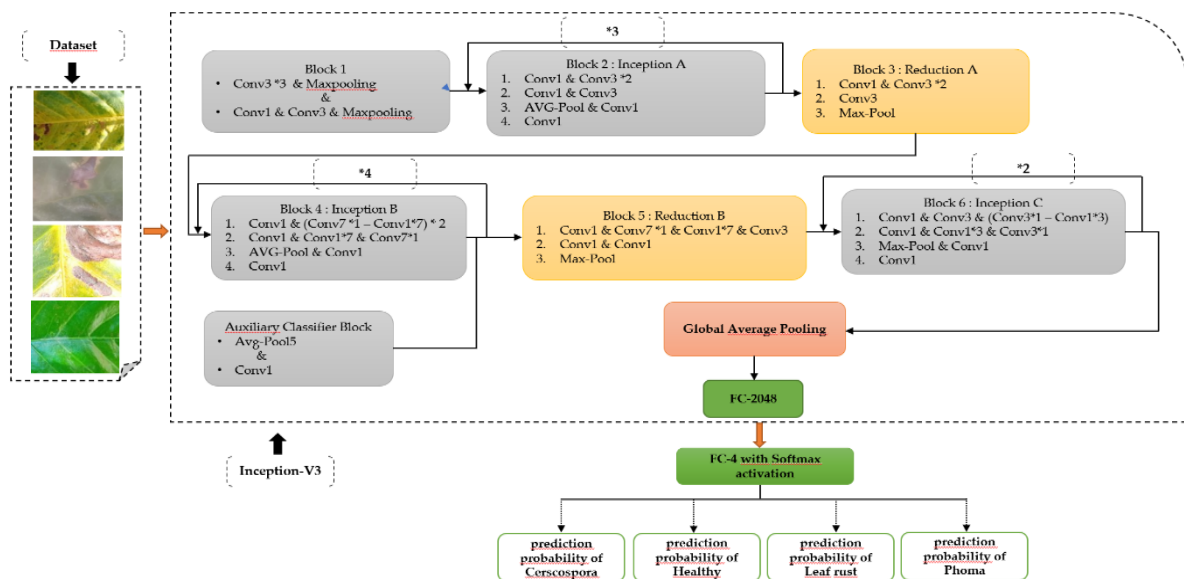



Figure 15 : L'architecture d'Inception-V3 applique notre étude

### 2.4.4. DenseNet-201

DenseNet est l'abréviation de Dense Convolutional Network, utilise moins de paramètres qu'un CNN conventionnel, car il n'apprend pas de cartes de caractéristiques redondantes. Les couches de DenseNet possèdent 12 filtres. DenseNet a quatre variantes différentes : DenseNet-121, DenseNet-169, DenseNet-201 et DenseNet-264. Dans notre étude, nous avons utilisé DenseNet-201, chaque couche a un accès direct à l'image d'entrée


originale et aux gradients de la fonction de perte. Le coût de calcul est considérablement réduit, ce qui fait de DenseNet un des meilleur choix pour la classification d'images[91]. La figure 16 présente l'application de l'architecture de DenseNet-201 à notre étude.



**Figure 16 :** Architecture de DenseNet-201 appliquée à notre étude

### 2.4.5. ResNet-50

ResNet utilise des connexions résiduelles entre les couches, ce qui réduire les pertes, conserve le gain de connaissances et améliore les performances au cours de la phase d'apprentissage. Une connexion résiduelle dans une couche signifie que la sortie d'une couche est une convolution de son entrée plus son entrée [92]. ResNet-50 a cinq variantes différentes à savoir ResNet-18, ResNet-34, ResNet-50, ResNet-101 et ResNet-152. Dans notre étude, nous avons utilisé ResNet-50. La figure 17 présente l'application de l'architecture de ResNet-50 à notre étude.



**Figure 17 :** Architecture de ResNet-50 appliquée à notre étude

### 2.4.6. CNN personnalisé proposé

Nous proposons un CNN personnalisé qui est moins complexe mais très efficace, Il est composé de deux couches convolutifs avec un noyau de taille 5X5 et quatre couches convolutifs avec un noyau de taille 3X3. Pour chaque pair de couches convolutifs il y a un max-pooling qui permettra de réduire les images et le tout sera connecté à 128 couches entièrement connectées. La figure 18 présente le CNN personnalisé.




Figure 18 : Architecture du CNN personnalisé proposé

## 2.5. Méthodologie de l'étude

L'architecture de notre méthode se présente en trois grandes étapes à savoir :

- **étape 1** : Il s'agit de la partie prétraitement et la division de notre jeu de données ;
- **étape 2** : Il s'agit de l'entraînement des algorithmes cités plus haut sur notre jeu de données ;
- **étape 3** : Il s'agit de faire la classification et la reconnaissance de maladies.

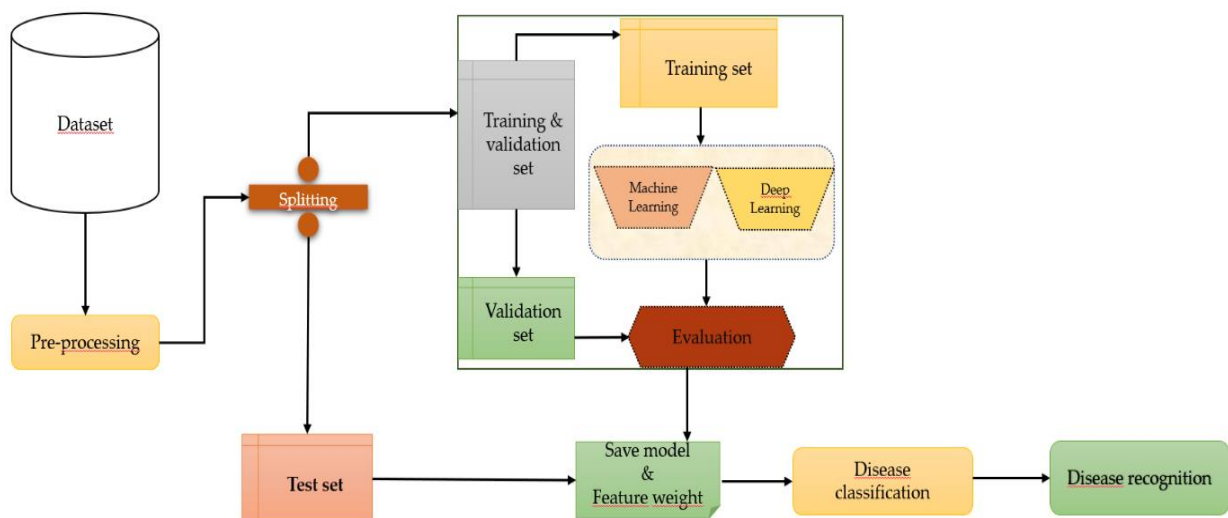



Figure 19 : Architecture générale de notre méthodologie d'étude

## 2.6. Paramétrage

Les performances des huit modèles d'apprentissage automatique et des six modèles d'apprentissage profond pour la détection et la reconnaissance de maladie de feuilles de café ont été évaluées avec les métriques suivantes : la Précision, l'Erreur quadratique moyenne, le Rappel, le score F1 et le Coefficient de corrélation de Matthews. Nous utiliserons le graphique de précision et le graphique des pertes pour les modèles d'apprentissage profond et en ce qui concerne les modèles d'apprentissage automatique nous utilisons le K-Fold Cross validation et la courbe ROC. Les expériences ont été menées avec le langage de programmation Python sur un ordinateur de bureau DELL équipé d'un processeur Intel(R) Core i7-10700 CPU à 2,90 GHz, de 32 Go de RAM et d'un GPU NVIDIA Quadro P400.

### 2.6.1. Algorithmes d'apprentissage automatique

La validation croisée K-Fold est une technique utilisée pour évaluer les performances de modèle d'apprentissage automatique ou d'apprentissage profond de manière robuste. Elle divise l'ensemble de données en k parties de taille approximativement égale. Chaque partie est choisie au fur à mesure pour le test et les parties restantes pour la formation. Ce processus est répété k fois, puis la performance est mesurée comme la moyenne de tous les ensembles de test [93]. Dans notre étude k=10. La figure 20 illustre le K-Fold.



**Figure 20 :** Illustration de la validation croisée (K-Fold)

La courbe des caractéristiques de fonctionnement du récepteur (ROC) est utilisée pour évaluer les performances des algorithmes de classification. Il fournit une représentation graphique des performances d'un classificateur, plutôt qu'une valeur unique comme la plupart des autres métriques [94].



### 2.6.2. Algorithmes de réseaux de neurones convolutifs (CNN)

Les modèles ont été entraînés en utilisant la descente de gradient stochastique (SGD) comme optimiseur avec un Momentum de 0.9, et le taux d'apprentissage est de 0.0001. Le taux d'apprentissage définit la progression de l'apprentissage du modèle proposé et met à jour les paramètres de poids pour réduire la fonction de perte du réseau. Le nombre maximal d'époques a été fixé à 20 et des lots de 20 ont été utilisés dans cette expérience. Le tableau 2 résume les hyperparamètres utilisés pour notre étude [95].

**Tableau 2** : Hyperparamètres des algorithmes du CNN

Paramétrages	Valeur
Optimizer	SGD
Learning rate	0.0001
Momentum	0.9
Epochs	20
Batch size	32

### 2.6.3. Métrique d'évaluation

Pour évaluer la performance des modèles de notre étude, nous allons utiliser différentes métriques d'évaluation en l'occurrence la Précision, l'Erreur quadratique moyenne, le Rappel, le score F1 et le Coefficient de corrélation de Matthews. Elles sont calculées à partir des formules comme suit :

- L'exactitude est une mesure de performance qui montre comment le système a correctement classé les données dans la bonne classe.

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{TN} + \text{FN}} \quad (2-4)$$

- La précision est le rapport d'images correctement classées positives sur le nombre total d'images réellement positives.

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2-5)$$

- Le rappel est la capacité d'un classificateur à déterminer les résultats positifs réels.

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2-6)$$

- Le score F1 est la moyenne pondérée de la précision et du rappel

$$F1 \text{ score} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2-7)$$

- Le coefficient de corrélation de Matthews (MCC) est utilisé en apprentissage automatique comme mesure de la qualité des classifications

$$MCC = \frac{TP * TN - FP * FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (2-8)$$

- L'erreur quadratique moyenne d'un estimateur mesure la moyenne des erreurs au carré, c'est-à-dire la différence quadratique moyenne entre les valeurs estimées et la valeur réelle.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (2-9)$$

Les différentes variables utilisées plus haut sont :

- **Vrais positifs (TP)** : Images avec un label vrai et qui a été classée correctement ;
- **Faux positifs (FP)** : Images avec un label faux et qui a été classée comme positive ;
- **Vrais négatifs (TN)** : Images avec un label faux et qui a été classée comme négative ;
- **Faux négatifs (FN)** : Images avec un label vrai et qui a été classée comme négative ;
- **$Y_i$**  : Les données réelles du jeu de données ;
- **$\hat{Y}_i$**  : Les données prédites du jeu de données.

## 2.7. Résultats expérimentaux

Dans cette partie nous allons présenter les résultats de classification et de reconnaissance selon deux scénarios en l'occurrence : Le scénario utilisant les huit algorithmes du machine Learning cités plus haut et le second scénario présentera les cinq algorithmes de Deep Learning avec notre CNN personnalisé.

### 2.7.1. Scénario 1 : Algorithmes d'apprentissage automatique

Nous présentons dans cette parties les différents résultats de l'apprentissage et validation des modèles en utilisant une valeur de K-Folds à dix et ensuite nous faisons la moyenne de chaque résultat.

**Tableau 3** : Résultats de l'apprentissage et validation des modèles pour chaque K-Folds

Modèles/K-Folds	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	Moyenne
SVM	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
KNN	99.96	99.92	99.92	99.92	99.88	99.96	99.72	99.96	100.0	99.92	99.91
RF	100.0	100.0	99.96	100.0	99.96	100.0	100.0	100.0	100.0	100.0	99.99
LR	91.23	93.41	93.25	93.41	93.09	93.29	93.09	94.28	92.93	93.65	93.16
MPL	97.18	99.80	99.48	69.25	98.53	86.63	73.85	98.84	95.27	96.54	91.54
DT	86.71	88.26	87.86	87.42	87.02	87.38	86.90	86.27	86.31	87.70	87.18
GNB	81.87	81.04	79.29	80.48	81.27	81.07	81.23	80.68	80.00	81.03	80.80

Les résultats présentés dans ce tableau représentent les performances de différents modèles d'apprentissage automatique, mesurées à l'aide de la technique de validation croisée K-Folds, où K est égal à 10 dans ce cas.

Le modèle SVM a obtenu une précision de 100% sur tous les différents jeux de données, cela prouve qu'il a réussi à bien généraliser son apprentissage sur les données d'entraînement. Le modèle KNN a également obtenu des résultats très élevés, avec une moyenne de 99,91%, bien que certains jeux de données aient donné des résultats légèrement inférieurs. Le modèle RF a également obtenu des résultats très élevés, avec une précision de 100% sur la plupart des jeux de données, mais avec une précision légèrement inférieure sur deux jeux de données. Le modèle LR a obtenu des résultats plus modestes, avec une moyenne de précision de 93,16%, mais avec une petite variance entre les différents jeux de données. Le modèle MPL a obtenu une précision élevée sur certains jeux de données, mais a eu des résultats très faibles sur d'autres jeu de données, cela a entraîné une moyenne de précision plus faible de 91,54%. Le modèle DT a également eu des résultats plus modestes, avec une précision moyenne de 87,18%. Enfin, le modèle GNB a obtenu les résultats les plus bas de tous les modèles évalués, avec une moyenne de précision de 80,80%. Ces résultats soulignent l'importance de la validation croisée pour évaluer la performance des modèles d'apprentissage automatique.

Après l'étape de l'apprentissage et de la validation, nous présentons maintenant les résultats des tests de chaque algorithme.




**Tableau 4** : Résultats de la phase de test

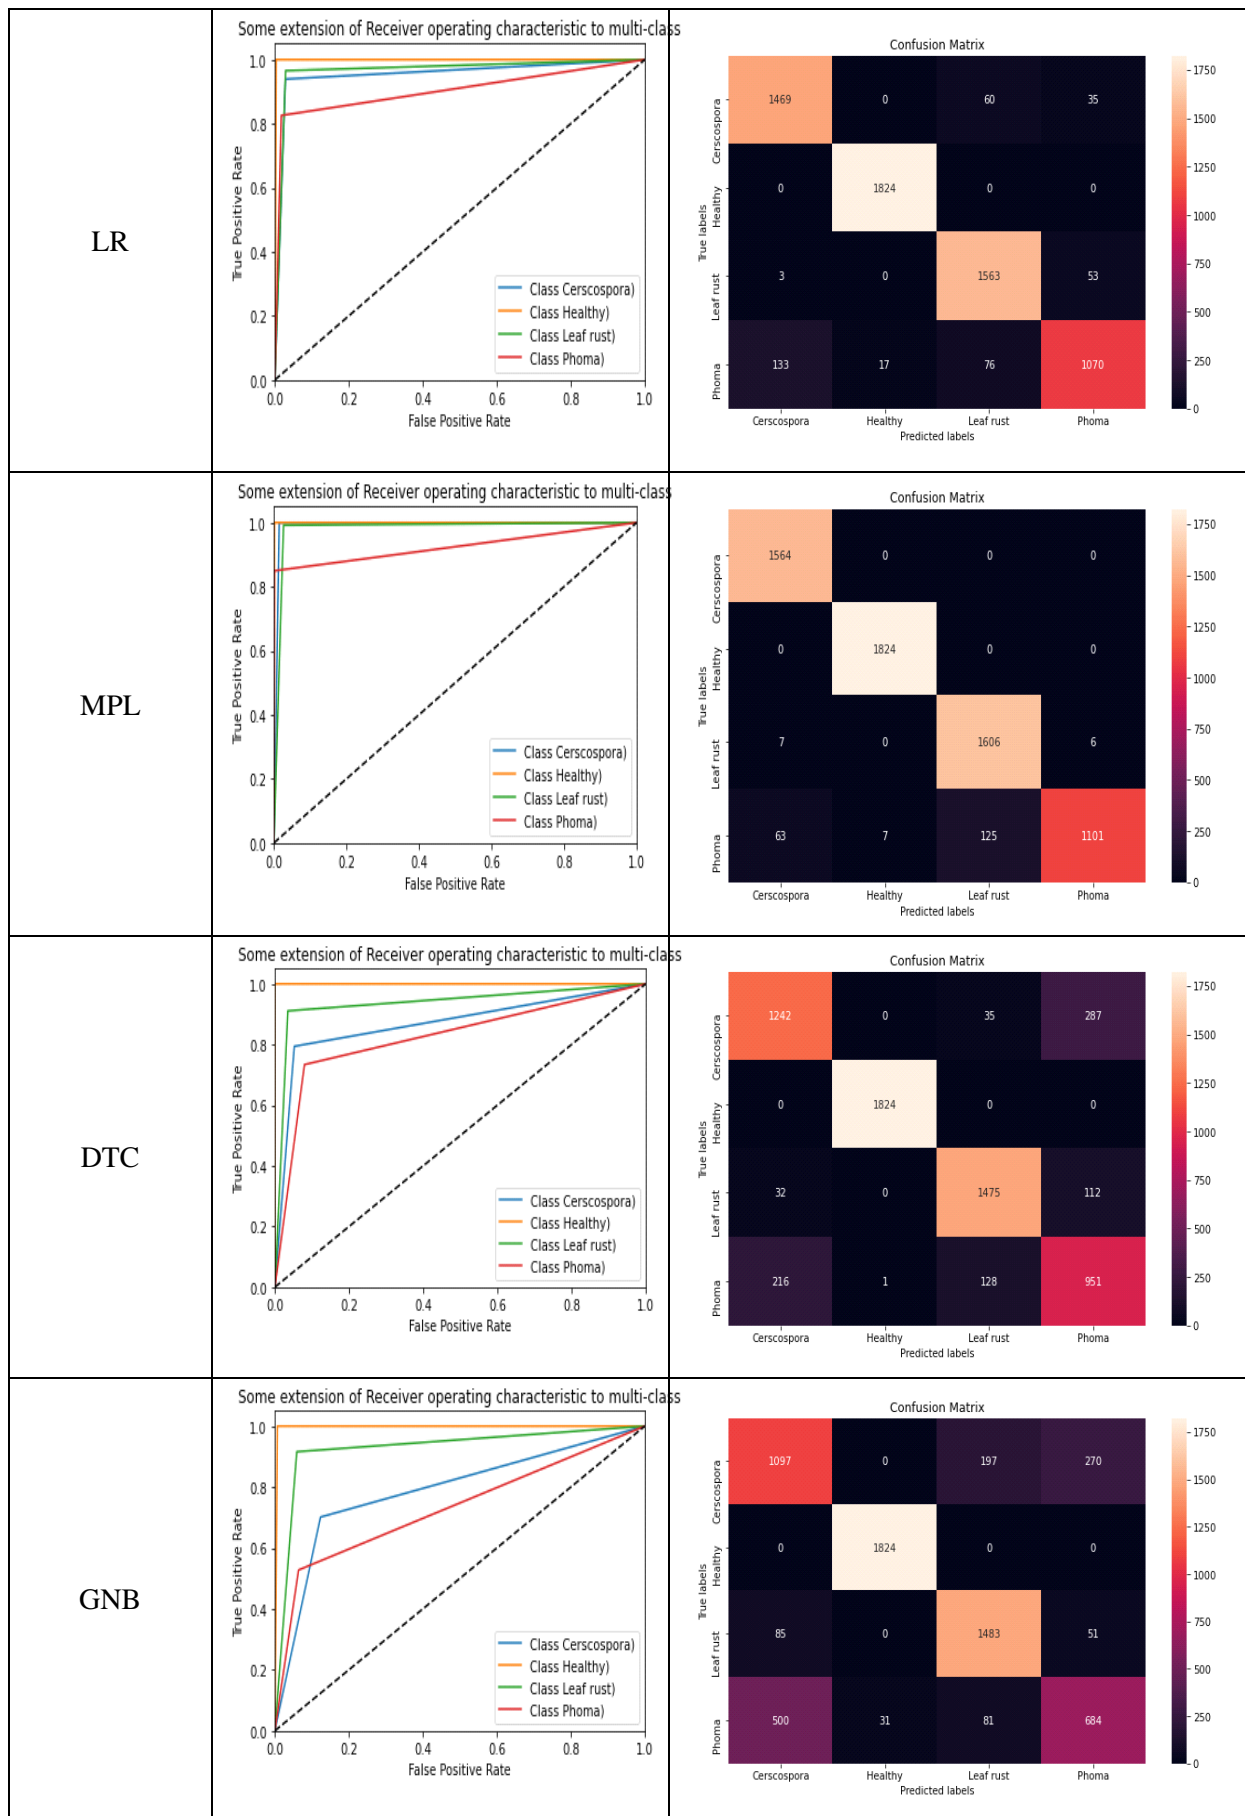
Modèles	SVM	KNN	RF	LR	MPL	DTC	GNB
Accuracy	100.0	99.92	100.0	93.65	96.54	87.70	81.03

La phase de test a donné les performances ont été évaluées en termes de précision. On peut voir que certains modèles ont une précision de 100% comme SVM et RF, qui signifie qu'ils ont réussi à généraliser leur apprentissage sur le jeu de données de test. D'autres modèles ont une précision légèrement inférieure comme KNN avec une précision de 99,92%.

Cependant il y a des modèles comme LR, MPL, DTC et GNB avec des précisions plus faibles, qui sont respectivement 93,65%, 96,54%, 87,70% et 81,03%. Cela peut être dû à la complexité des données ou à la sensibilité des modèles à certains types de caractéristiques. Nous présentons les courbes ROC et les matrices de confusion de chaque modèle dans le tableau 5.

**Tableau 5 : Courbe ROC et la matrice de confusion de chaque modèle**

Modèles	Courbe ROC	Matrice de Confusion																									
SVM	<p>Some extension of Receiver operating characteristic to multi-class</p> 	<p>Confusion Matrix</p> <table border="1" data-bbox="858 593 1398 996"> <tr> <td></td> <td>Cercospora</td> <td>Healthy</td> <td>Leaf rust</td> <td>Phoma</td> </tr> <tr> <td>Cercospora</td> <td>1564</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <td>Healthy</td> <td>0</td> <td>1824</td> <td>0</td> <td>0</td> </tr> <tr> <td>Leaf rust</td> <td>0</td> <td>0</td> <td>1619</td> <td>0</td> </tr> <tr> <td>Phoma</td> <td>0</td> <td>0</td> <td>0</td> <td>1296</td> </tr> </table>		Cercospora	Healthy	Leaf rust	Phoma	Cercospora	1564	0	0	0	Healthy	0	1824	0	0	Leaf rust	0	0	1619	0	Phoma	0	0	0	1296
	Cercospora	Healthy	Leaf rust	Phoma																							
Cercospora	1564	0	0	0																							
Healthy	0	1824	0	0																							
Leaf rust	0	0	1619	0																							
Phoma	0	0	0	1296																							
KNN	<p>Some extension of Receiver operating characteristic to multi-class</p> 	<p>Confusion Matrix</p> <table border="1" data-bbox="858 1057 1398 1460"> <tr> <td></td> <td>Cercospora</td> <td>Healthy</td> <td>Leaf rust</td> <td>Phoma</td> </tr> <tr> <td>Cercospora</td> <td>1564</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <td>Healthy</td> <td>0</td> <td>1824</td> <td>0</td> <td>0</td> </tr> <tr> <td>Leaf rust</td> <td>0</td> <td>0</td> <td>1619</td> <td>0</td> </tr> <tr> <td>Phoma</td> <td>2</td> <td>0</td> <td>6</td> <td>1288</td> </tr> </table>		Cercospora	Healthy	Leaf rust	Phoma	Cercospora	1564	0	0	0	Healthy	0	1824	0	0	Leaf rust	0	0	1619	0	Phoma	2	0	6	1288
	Cercospora	Healthy	Leaf rust	Phoma																							
Cercospora	1564	0	0	0																							
Healthy	0	1824	0	0																							
Leaf rust	0	0	1619	0																							
Phoma	2	0	6	1288																							
RF	<p>Some extension of Receiver operating characteristic to multi-class</p> 	<p>Confusion Matrix</p> <table border="1" data-bbox="858 1538 1398 1942"> <tr> <td></td> <td>Cercospora</td> <td>Healthy</td> <td>Leaf rust</td> <td>Phoma</td> </tr> <tr> <td>Cercospora</td> <td>1564</td> <td>0</td> <td>0</td> <td>0</td> </tr> <tr> <td>Healthy</td> <td>0</td> <td>1824</td> <td>0</td> <td>0</td> </tr> <tr> <td>Leaf rust</td> <td>0</td> <td>0</td> <td>1619</td> <td>0</td> </tr> <tr> <td>Phoma</td> <td>0</td> <td>0</td> <td>0</td> <td>1296</td> </tr> </table>		Cercospora	Healthy	Leaf rust	Phoma	Cercospora	1564	0	0	0	Healthy	0	1824	0	0	Leaf rust	0	0	1619	0	Phoma	0	0	0	1296
	Cercospora	Healthy	Leaf rust	Phoma																							
Cercospora	1564	0	0	0																							
Healthy	0	1824	0	0																							
Leaf rust	0	0	1619	0																							
Phoma	0	0	0	1296																							



### 2.7.2. Scénario 2 : Algorithmes de réseaux de neurones convolutifs

Nous présentons maintenant les résultats de validation et de tests des algorithmes de réseaux de neurones convolutifs utilisés.

**Tableau 6** : Performance de chaque CNN pour validation et test

Modèles	Validation		Test	
	Loss	Accuracy	Loss	Accuracy
MobileNet	0,03	100	0,03	100
ResNet-50	0,16	99,97	0,18	99,94
VGG-19	09,83	97,33	09,68	97,37
DenseNet-201	0,14	99,97	0,14	99,97
InceptionV3	0,17	99,98	0,32	99,95
Custom CNN	0,014	100	0,013	100

Le tableau 6 présente les performances des différents modèles de réseaux de neurones sur notre jeu de données. Les modèles sont évalués en termes de perte et de précision. En analysant les résultats, on constate que tous les modèles ont des performances élevées sur les ensembles de validation et de test, avec des pertes et des précisions très faibles ou très élevées, respectivement.

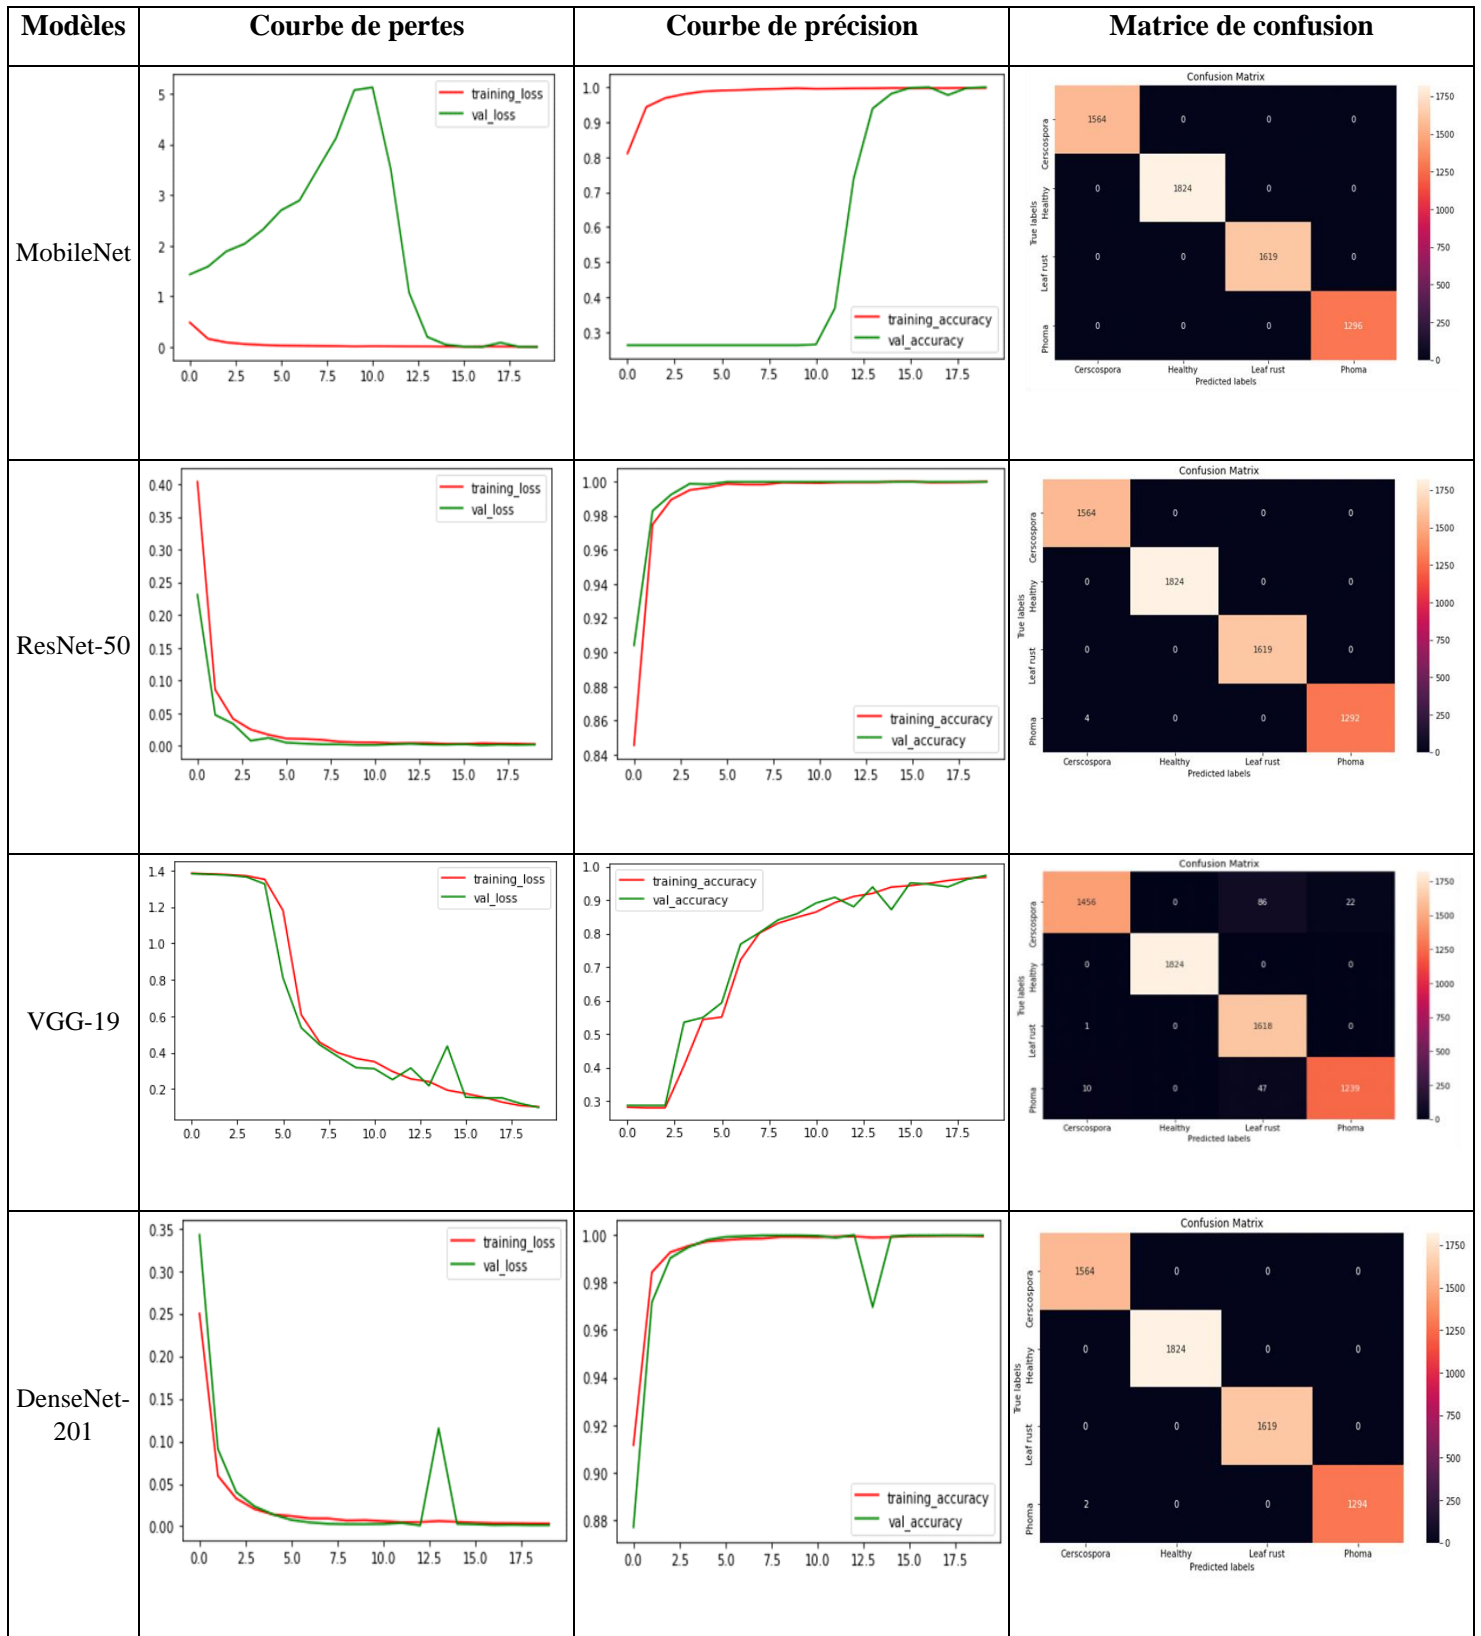
Le modèle MobileNet présente de meilleures performances, avec des pertes et des précisions de validation et de test très faibles et élevées, respectivement. Le modèle ResNet-50 a également des performances élevées, avec des pertes et des précisions légèrement en dessous que celle de MobileNet, mais tout de même très proches.

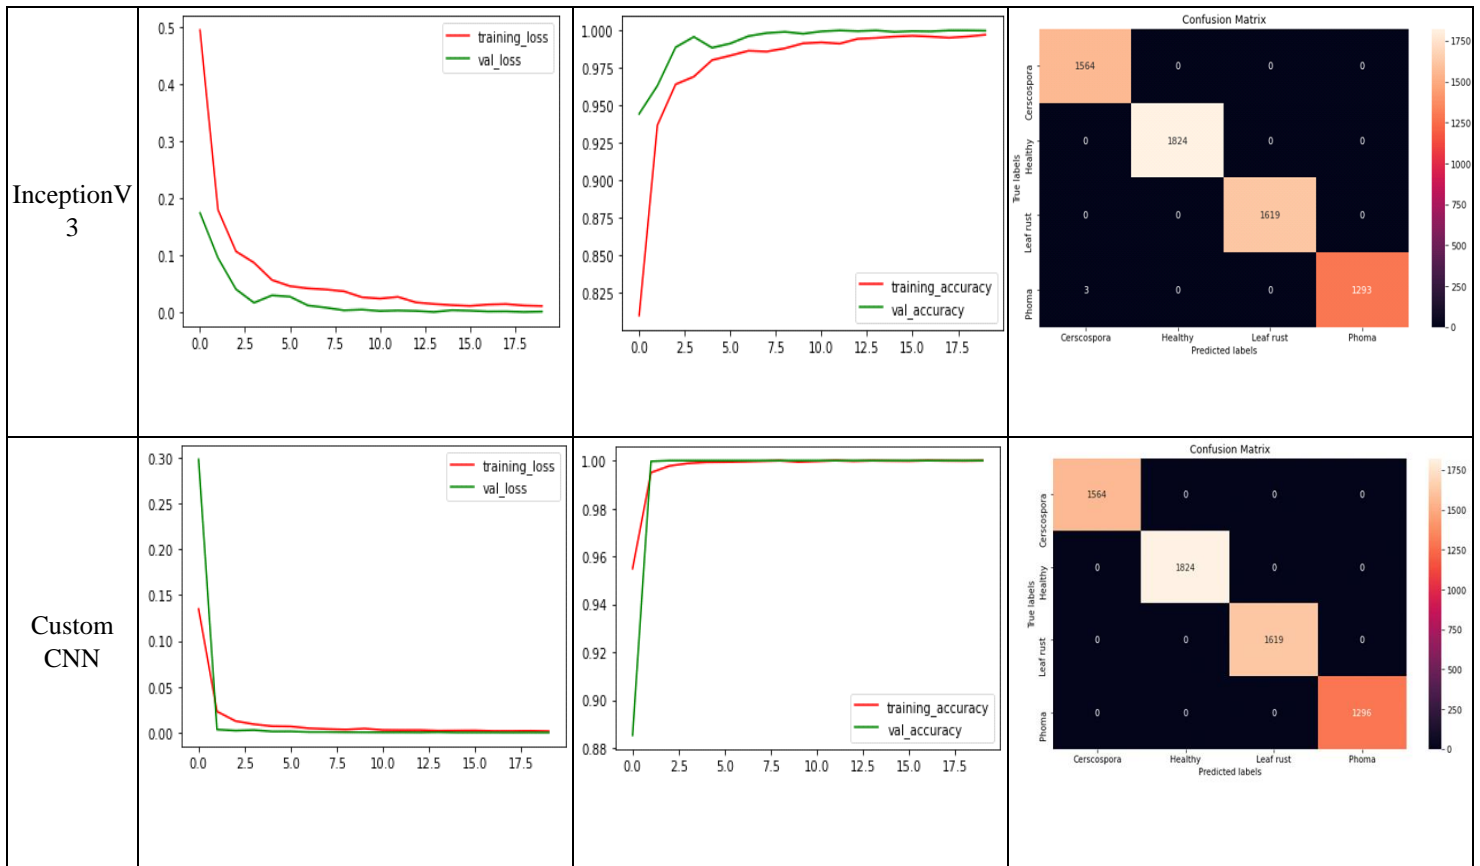
Le modèle VGG-19 présente des performances légèrement inférieures aux deux modèles précédents, avec des pertes plus élevées. Le modèle DenseNet-201 a des performances très similaires à celles de ResNet-50, avec des pertes moins élevées.

Le modèle InceptionV3 a des performances légèrement inférieures à celles des modèles DenseNet-201 et ResNet-50 avec des pertes plus élevées. Enfin, le modèle Custom CNN présente des meilleures performances, avec des pertes les plus faibles et les meilleures précisions équivalentes à celles de MobileNet.

Nous présentons les courbes de pertes, de précisions et les matrices de confusions des différents modèles.

**Tableau 7 : Illustration des courbes de pertes, de précisions et des matrices de confusion**





### 2.7.3. Evaluation des algorithmes à l'aide des métriques

Les tableaux 8 et 9 présentent les métriques respectives des algorithmes d'apprentissage automatique et celles des algorithmes de réseaux de neurones convolutifs qui viennent consolider les performances obtenues dans les deux scénarios ci-dessus.

**Tableau 8 :** Mesures de performances des algorithmes d'apprentissage automatique

Models	Precision (%)	MSE (%)	F-score (%)	Recall (%)	MCC (%)
SVM	100	0	100	100	100
KNN	99.87	0.38	99.87	99.87	99.83
RF	100	0	100	100	100
LR	94.01	31.11	93.93	94.01	92.01
MPL	96.86	11.96	96.62	96.69	95.65
DT	87.22	79.94	87.15	87.13	82.78
GNB	80.26	131.9	80.23	80.72	74.24

Le tableau 8 donne les performances de sept modèles d'apprentissage automatique pour la classification binaire de données. Les modèles inclus sont SVM, KNN, RF, LR, MPL, DT et GNB. Les performances sont évaluées à l'aide de cinq métriques : Les métriques



incluent la précision (Precision), l'erreur quadratique moyenne (MSE), le score F1 (F-score), le rappel (Recall) et le coefficient de corrélation de Matthews (MCC). Le modèle SVM a obtenu de meilleur score sur toutes les métriques à 100 % pour chacune de ces mesures et le MSE à zéro. Cela indique que le modèle SVM a réussi à classifier avec succès toutes les données de test. Le modèle KNN suit de près avec des scores très élevés pour toutes les mesures, mais légèrement inférieurs à ceux de SVM. RF a également des scores parfaits pour chaque mesure.

Le modèle LR a une précision inférieure à celle de SVM, KNN et RF, mais un MSE relativement élevé de 31,11 %. Cela indique que les prédictions de LR peuvent être moins précises et moins fiables que celles des autres modèles.

Le modèle MPL a obtenu pour toutes les mesures des scores à ceux de SVM, KNN et RF. Le modèle DT a des scores relativement faibles par rapport aux autres modèles, en particulier pour l'erreur MSE, qui est assez élevée. Le modèle GNB a les scores les plus bas pour toutes les mesures, indiquant qu'il a eu des difficultés à classifier les données.

En général, les résultats du tableau indiquent que les modèles SVM et RF sont les plus performants pour la tâche de classification binaire, avec KNN qui les suit de près.

**Tableau 9 :** Mesures de performances des algorithmes de réseau de neurones convolutifs

Models	Precision (%)	MSE (%)	F-score (%)	Recall (%)	MCC (%)
MobileNet	100	$6 \cdot 10^{-4}$	100	100	100
ResNet-50	99.93	0.01	99.93	99.93	99.91
VGG-19	97.50	1.14	97.36	97.36	96.51
DenseNet-201	99.96	0.01	99.96	99.96	99.95
InceptionV3	99.95	0.02	99.95	99.95	99.93
Custom CNN	100	$2 \cdot 10^{-6}$	100	100	100

Le tableau 9 produit des métriques de performance pour différents modèles de réseaux de neurones utilisés pour la classification. Les métriques incluent la précision (Precision), l'erreur quadratique moyenne (MSE), le score F1 (F-score), le rappel (Recall) et le coefficient de corrélation de Matthews (MCC). En analysant les résultats, nous voyons que les performances des modèles sont généralement très élevées, avec des précisions et des scores F1 supérieurs à 97%. De plus, la majorité des modèles présentent des erreurs quadratiques moyennes assez faibles, et représente une bonne performance pour cet indicateur.

Le modèle MobileNet présente des résultats exceptionnels avec une précision et un score F1 de 100%, un MSE très faible de  $6 \cdot 10^{-4}$  et un rappel et un MCC également de 100%.

Cela indique que ce modèle est très précis et robuste. Le modèle ResNet-50 obtient également de bons résultats, avec une précision de 99,93%, un MSE de 0,01 et des scores F1, rappel et MCC supérieurs à 99,9%.

Le modèle VGG-19, bien qu'il présente des résultats inférieurs aux MobileNet et ResNet-50, obtient tout de même une précision et un score F1 de 97,5%, un MSE de 1,14 et des scores de rappel et de MCC supérieurs à 96%. Le modèle DenseNet-201 et InceptionV3 ont des performances similaires avec des précisions et des scores F1 de 99,96% et des MSE de 0,01 et 0,02 respectivement. Le rappel et le MCC sont également élevés, démontrant la robustesse de ces modèles. Enfin, le modèle Custom CNN obtient également des résultats exceptionnels avec une précision, un score F1, un rappel et un MCC de 100% et un MSE la plus faible avec une valeur de  $2 \cdot 10^{-6}$ .

De manière générale, tous ces modèles ont des performances de classification très élevées, mais certains d'entre eux ont des performances exceptionnelles avec des précisions et des scores F1 de 100% et des erreurs quadratiques moyennes très faibles. Ces résultats témoignent de l'efficacité des réseaux de neurones pour la classification et de leur capacité à généraliser sur de nouvelles données.

## **Conclusion**

Dans cette étude, nous avons utilisé plusieurs approches pour la classification et la reconnaissance des maladies des feuilles de café. Les méthodes du machine Learning classique et les méthodes du Deep Learning ont été utilisées pour mettre en place notre méthode.

L'évaluation de ces approches a démontré l'efficacité des méthodes du SVM et du Random Forest avec une précision de 100% pour les modèles du machine Learning classique tandis que MobileNet et notre custom CNN ont montré leur efficacité avec une précision de 100% pour les modèles du Deep Learning. Concernant notre custom CNN, il a enregistré moins de perte que le MobileNet en utilisant la fonction de perte et cela démontre que notre modèle est le plus robuste. Le SVM et le Random Forest ont obtenu de bonne performance comme les modèles de Deep Learning. Nous pouvons à l'avenir mettre en place une méthode efficace en environnement non contrôlé en couplant notre méthode à la segmentation pour mieux se concentrer sur la partie malade de la plante malade.

## **Chapitre 3 : Mise en place d'une base de données d'images de cabosses et de fèves de cacao**

*(“CocoaMFDB: A dataset of cocoa pod maturity and families in an uncontrolled environment in Côte d’Ivoire.”, Kacoutchy Jean AYIKPA, Diarra MAMADOU, Abou Bakary BALLO, Konan YAO, Pierre GOUTON, Kablan Jérôme ADOU, Data in Brief - Elsevier)*

### **Introduction**

Le cacao est une culture importante qui connaît une forte demande à travers le monde. Pour améliorer la qualité de la récolte de cette culture, la mise en place d'une base de données d'images de cabosses et de fèves de cacao est essentielle. Elle permettra de collecter des données précises sur les cabosses et les fèves, leur état de maturité et de fermentation. Deux techniques d'imagerie seront utilisées pour la mise en place de la base de données il s'agira de l'imagerie couleur et l'imagerie multispectrale. Ces techniques permettront d'obtenir des images de qualité, que nous pourrons ensuite analysées pour extraire des informations utiles. Nous avons également procédé à la mesure spectrale des fèves de cacao qui permettra d'obtenir des données plus détaillées sur les propriétés spectrales des fèves et nous permettra ainsi de mieux comprendre les variations spectrales. La mise en place d'une base de données d'images de cabosses et de fèves de cacao ainsi que la mesure spectrale des fèves sont nécessaires pour améliorer la qualité des fèves, de réduire les coûts de production, d'identifier les variétés de cacao et bien d'autres.

### **3.1. Base de données d'images couleur sur le cacao**


#### **3.1.1. Cabosses de cacao**

Les cabosses de cacao ont été photographiées avec des appareils photo Nikon D500 et Infinix dans une plantation de cacao située dans le village de Yakassé 1 à quelques km de Grand Bassam en Côte d'Ivoire. Ces images ont été prises dans un environnement non contrôlé sous plusieurs angles et à différents moments de la journée. Les images des cabosses ont été classées par catégorie et par famille. Les catégories utilisées sont les cabosses de cacao mures et les cabosses de cacao non mûres. Pour chaque catégorie, nous avons obtenu trois grandes familles qui sont : Amelonado, Anjoleta et Guyana.

##### **3.1.1.1. Amelonado**

Amelonado vient du mot espagnol pour en forme de melon. Les fruits ressemblent à des melons allongés, généralement avec un léger goulot d'étranglement. Ils ont des coquilles épaisses, généralement lisses, rarement avec quelques verrues. Le fruit a des rainures peu

profondes et une pointe arrondie. L'Amelonado est un type de *Theobroma cacao* [96]. La figure 21 présente les images du cacao Amelonado qui sont disposées en deux lignes. La première ligne contient des images de cabosses de Amelonado mûres et la deuxième ligne contient des images de cabosse d'Amelonado non mûres.




**Figure 21** : Images de cabosses de Amelonado (A) : cabosse de Amelonado mûres ; (B) : cabosses de Amelonado non mûres.

### 3.1.1.2. Angoleta

Le cacao Angoleta est un dérivé du cacao trinitario. Il est le résultat du croisement entre le criollo et le forastero. Sa forme est presque identique à celle d'un criollo, sa surface est très rugueuse, sans goulot d'étranglement, c'est un gros fruit, avec des graines rondes, et des sillons dans l'endosperme de couleur violet clair et a une qualité supérieure [97].

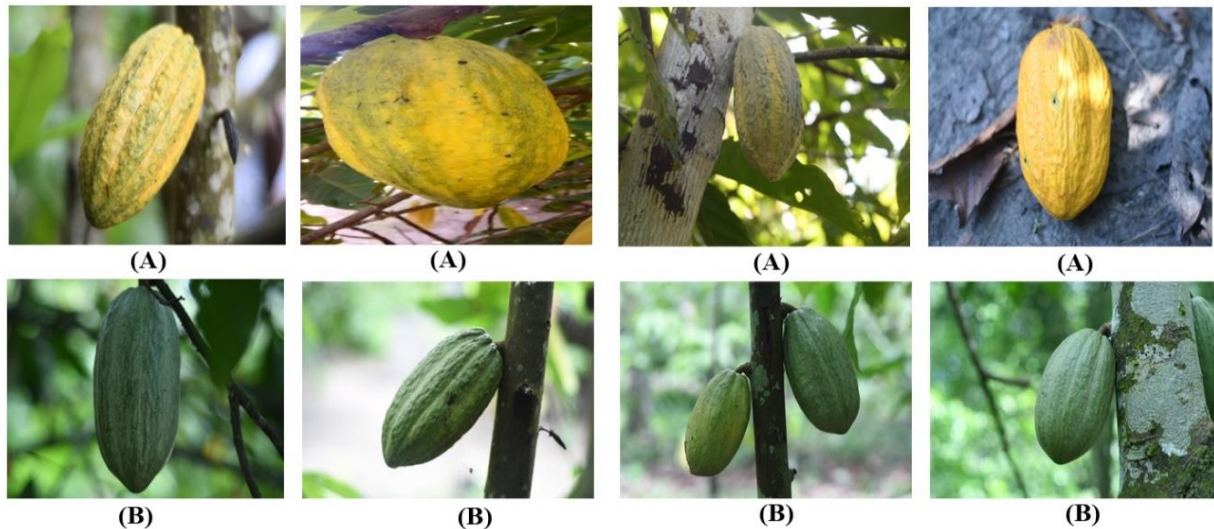
La figure 22 montre les images de cabosses de cacao Angoleta qui sont disposées en deux lignes. La première ligne contient les images des gousses d'Angoleta mûres et la deuxième ligne les gousses d'Angoleta non mûres.



**Figure 22** : Images de cabosses de Angoleta (A) : cabosses de Angoleta mûres ; (B) : cabosses de Angoleta non mûres

### 3.1.1.3. Guiana

La Guyane est une variété de cacao méconnue et endémique de la Guyane française. Le cacaoyer de Guyane se distingue des autres cacaoyers par ses caractéristiques telles que des sillons marqués et la verrucosité de ses surfaces [98]. La figure 23 montre les images des cabosses de cacao de Guyane qui sont disposées en deux lignes. La première ligne contient des images de cabosses de Guyane mures et la deuxième ligne contient des images de cabosses de Guyane non mûres.



**Figure 23** : Images de cabosses de Guyane (A) : Cabosses de Guyane mures ; (B) : Cabosses de Guyane immatures.

### 3.1.1.4. Structure du répertoire de données

Le répertoire de notre jeu de données est structuré comme suit :

Nous avons un répertoire parent nommé CocoaMFDB, puis dans le répertoire CocoaMFDB, nous avons deux sous-répertoires qui sont « mature » et « immature ». Enfin, dans chacun des dossiers matures et non matures, nous avons les répertoires Amelonado, Angoleta et Guyana. La figure 24 montre la structure du répertoire de notre ensemble de données.



**Figure 24** : Structure du jeu de données d'images couleurs des cabosses de cacao.


### 3.1.1.5. Résumé des données

Le tableau 10 présente un résumé des images des cabosses de cacao en fonction de leur type et de leur état de maturité.

**Tableau 10** : Résumé des données sur les cabosses de cacao

Type	Mature	Unmature	Total
Amelonado	260	245	505
Angoleta	170	133	303
Guiana	182	264	446
Total	612	642	1254

La figure 25 montre l'histogramme correspondant au tableau 10.



**Figure 25** : Histogramme du résumé des données sur le cacao

### 3.1.1.6. Collecte des cabosses de cacao


La collecte des images a eu lieu à Yakassé 1 Grand Bassam aux dates suivantes : 26 mai 2022 et 18 août 2022. Ces images ont été prises sous plusieurs angles dans un environnement non contrôlé. Les images contiennent des tiges et des feuilles occluses et des cabosses de cacao.

### 3.1.1.7. Prétraitement des données

L'égalisation adaptative d'histogramme à contraste limité (CLAHE) est utile pour améliorer les images numériques et est une variante de l'égalisation adaptative d'histogramme (AHE) qui prend en charge l'amplification du contraste. CLAHE opère sur de petites régions de l'image, appelées tuiles, plutôt que sur l'image entière. Les tuiles voisines sont ensuite

combinées à l'aide d'une interpolation bilinéaire pour supprimer les frontières artificielles [99].

La figure 26 représente la méthodologie générale du processus d'amélioration de la qualité de notre jeu de données.



**Figure 26 :** Schéma du processus d'amélioration de l'image.

Le processus d'amélioration de nos images est le suivant :

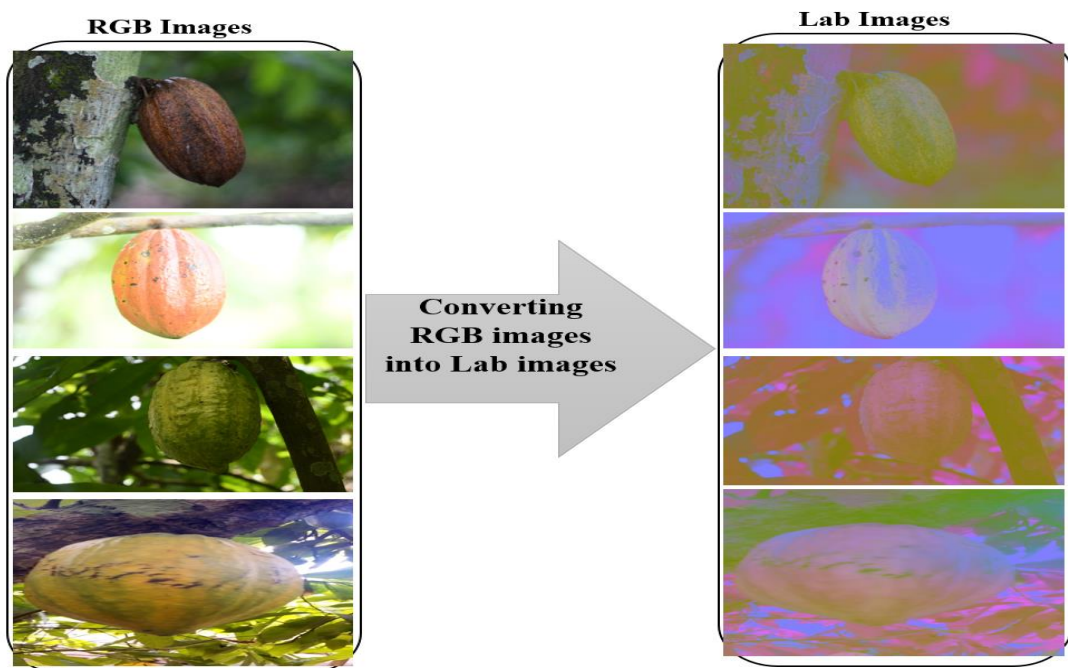
- **Etape 1 :** Nous procédons à la lecture des images au format RGB.
- **Etape 2:** Nous convertissons les images RGB en images Lab. Dans cette étape, l'image a initialement utilisé la conversion d'images couleur RGB en images couleur Lab. L'espace colorimétrique Lab utilise le concept de coloration basée sur la luminance en utilisant la luminosité (L) des composantes blanc-noir et chromatique (a. rouge-vert et b. jaune-bleu). L'espace colorimétrique Lab est un développement de l'espace colorimétrique CIEXYZ, avec des valeurs L qui ont une valeur comprise entre 0 et 100 qui représentent respectivement le noir et le blanc, quant à la représentation chromatique des couleurs rouge-vert et jaune-bleu, chacune est comprise entre - 128 et 128 [100]. La conversion de l'espace colorimétrique RGB vers Lab se fait à l'aide de l'équation ci-dessous :

$$L = 116 \times (0.299R + 0.587G + 0.144B)^{\frac{1}{3}} - 16 \quad (3-10)$$

$$a = 500 \times [1.006 \times (0.607R + 0.174G + 0.201B)^{\frac{1}{3}} - (0.299R + 0.587G + 0.114B)^{\frac{1}{3}}] \quad (3-11)$$


$$b = 200 \times [(0.299R + 0.587G + 0.114B)^{\frac{1}{3}} - 0.846 \times (0.066G + 1.117B)^{\frac{1}{3}}] \quad (3-12)$$

La figure 27 montre la conversion des images de l'espace colorimétrique RGB vers Lab.



**Figure 27 :** Conversion d'images RGB en images Lab.

- **Etape 3 :** Séparation des différents canaux, ici les canaux L, a et b. La figure 28 montre l'image de l'espace colorimétrique séparé en trois canaux.

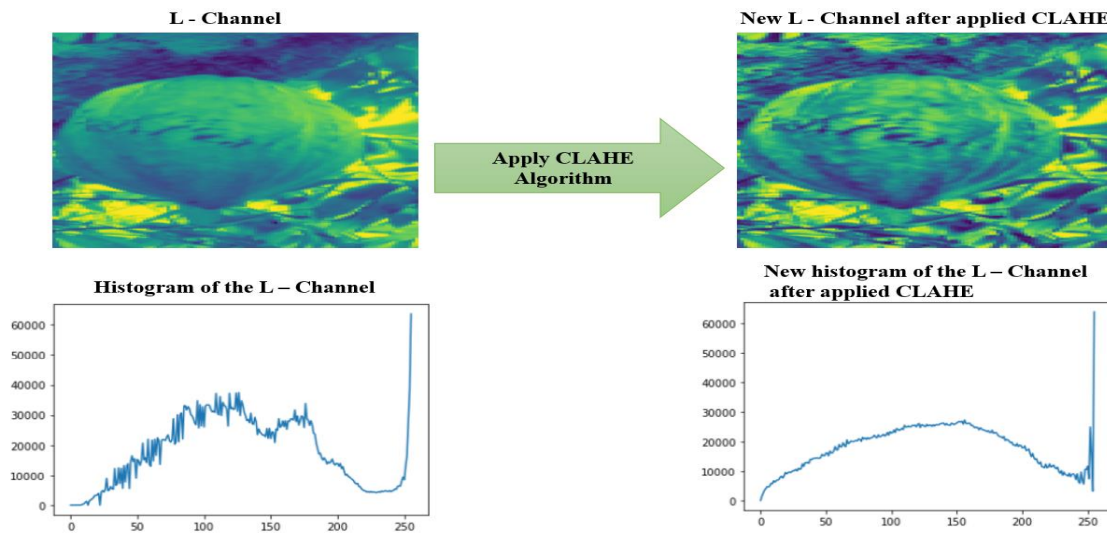


**Figure 28 :** Séparation des différents canaux des images Lab.



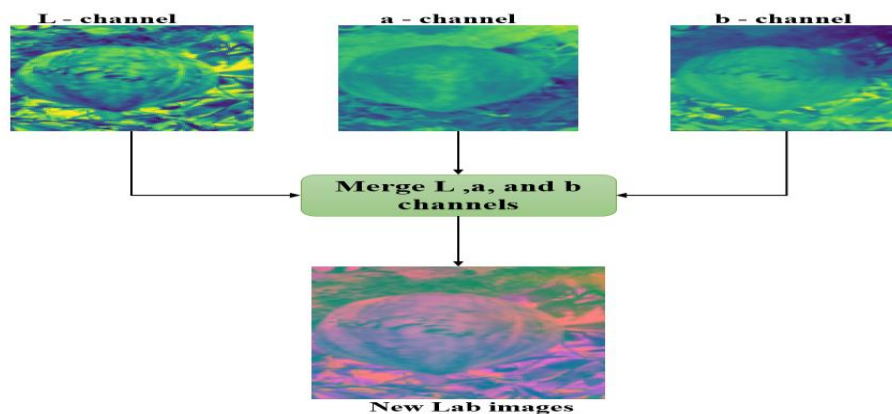
- **Etape 4 :** Nous appliquons maintenant l'algorithme CLAHE qui suit ces cinq étapes :
  - Divisez l'image en petites régions.
  - Ensuite, il décide des fonctions de cartographie de l'histogramme local.
  - Puis il choisit le point de découpage de l'histogramme.
  - Et il appliquera la fonction à chaque région.
  - Enfin, il réduit le bruit par la méthode de soustraction de fond.

La figure 29 montre le résultat obtenu après l'application de l'algorithme CLAHE sur le canal L de l'image.



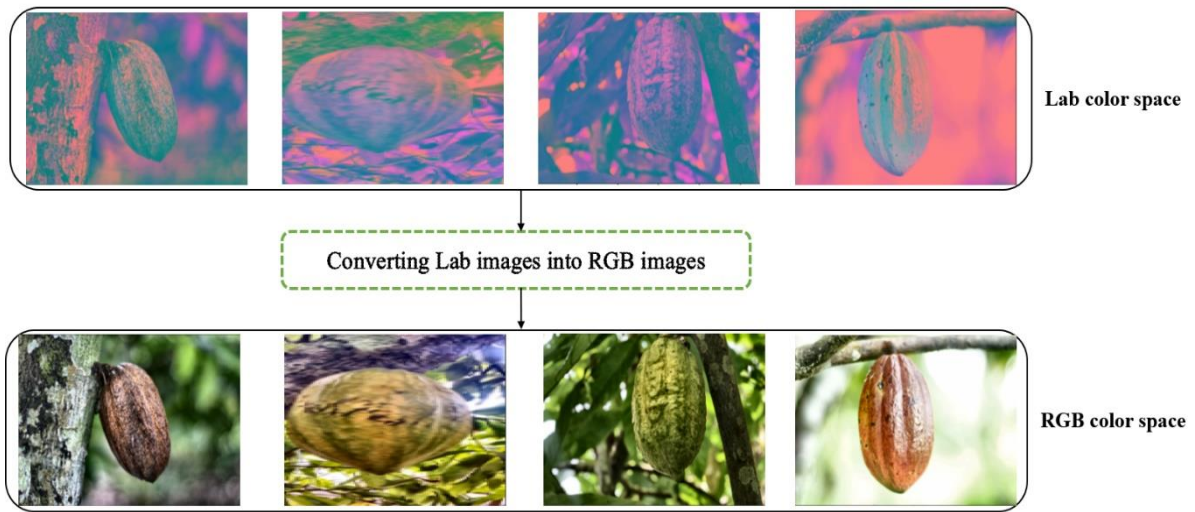
**Figure 29 :** Image et histogramme du canal L avant et après application de l'algorithme CLAHE

- **Etape 5 :** On procède à la fusion des canaux L, a, et b pour obtenir des images dans l'espace couleur Lab. Nous fusionnons maintenant les canaux L, a et b comme le montre la figure 30.



**Figure 30 :** Fusion des canaux L, a et b pour obtenir une nouvelle image dans l'espace colorimétrique Lab.

- **Etape 6** : Enfin, nous convertissons notre nouvelle image formée dans l'espace colorimétrique Lab vers l'espace colorimétrique RGB comme le montre la figure 31.



**Figure 31** : Conversion des images de l'espace colorimétrique Lab vers l'espace colorimétrique RGB

### 3.1.1.8. Étiquetage

Le balisage des données fait référence au processus d'ajout de balises ou d'étiquettes à des données brutes telles que des images, des vidéos, du texte et de l'audio. Ces balises forment une représentation de la classe d'objets à laquelle appartiennent les données et aident un modèle d'apprentissage automatique à apprendre à identifier cette classe particulière d'objets lorsqu'elle est rencontrée dans des données sans balises. L'outil d'étiquetage est utilisé pour annoter les informations de position des cabosses de cacao dans l'image. Il est annoté selon le format de jeu de données PASCAL VOC 2007 qui représente un jeu de données contenant plusieurs types d'images étiquetées et de fichiers annotés, et il génère automatiquement les fichiers d'annotation XML correspondants [101]. La figure 32 présente une image et le fichier généré.



**Figure 32** : Annotation de cabosse de cacao. (A) image annotée. (B) Document XML

### 3.1.2. Fèves de cacao

Les fèves de cacao ont été récupérées dans une plantation de cacao située également dans le village de Yakassé 1 et photographiées avec l'appareils photo Nikon D500. Ces images de fèves ont été prises dans un environnement contrôlé, disposées sur des fonds blancs et dans plusieurs angles. Les images des fèves ont été classées en trois catégories. Il s'agit :

#### 3.1.2.1. Fèves de la catégorie 1


Les fèves de la catégorie 1 désignent des fèves de cacao de haute qualité qui ont été soigneusement triées, fermentées et séchées. Ces fèves sont souvent utilisées pour la production de chocolat haut de gamme et sont connues pour leur saveur complexe et leur arôme distinctif. La figure 33 présente quelques images.



**Figure 33 :** Fèves de la catégorie 1

#### 3.1.2.2. Fèves de la catégorie 2


Les fèves de la catégorie 2 sont des fèves de cacao de qualité intermédiaire qui peuvent être utilisées pour la production de chocolat et d'autres produits à base de cacao, mais qui sont généralement moins chères que les fèves de la catégorie 1 et peuvent présenter certains défauts. La figure 34 présente quelques images.



**Figure 34** : Fèves de la catégorie 2

### 3.1.2.3. Fèves de la catégorie 3

Les fèves de la catégorie 3 sont des fèves de cacao qui n'ont pas été fermentées. Les fèves de cette catégorie sont récoltées et séchées directement après leur cueillette sans subir le processus de fermentation qui est normalement utilisé pour développer les saveurs et les arômes des fèves. La figure 35 présente quelques images.




**Figure 35** : Fèves de la catégorie 3

### 3.1.2.4. Structure du répertoire des données

Le répertoire de notre jeu de données est structuré comme suit :

Nous avons un répertoire parent nommé Cocoa\_beans, puis dans le répertoire Cocoa\_beans, nous avons trois sous-répertoires qui sont category 1, category 2 et category 3. La figure 36 montre la structure du répertoire de notre ensemble de données.



**Figure 36 :** Structure du jeu de données d’images couleurs des fèves de cacao

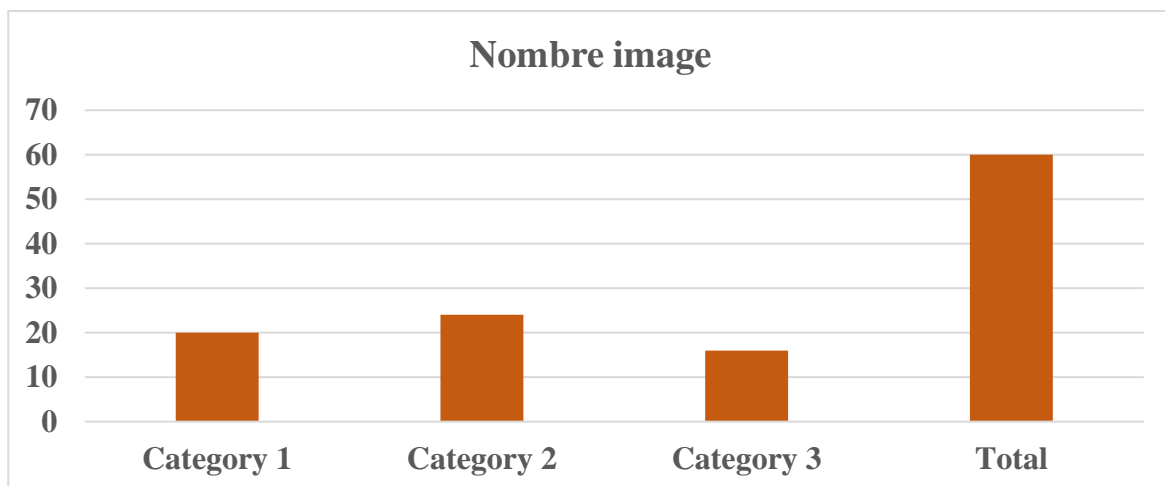
### 3.1.2.5. Résumé des données

Le tableau présente le résumé des données de fèves de cacao.

**Tableau 11 :** Résumé des données sur les fèves de cacao

Catégorie	Category 1	Category 2	Category 3	Total
Nombre image	20	24	16	60

L’histogramme est représenté ci-dessous



**Figure 37 :** L’histogramme du résumé des fèves

## 3.2. Base de données d’images multispectrales

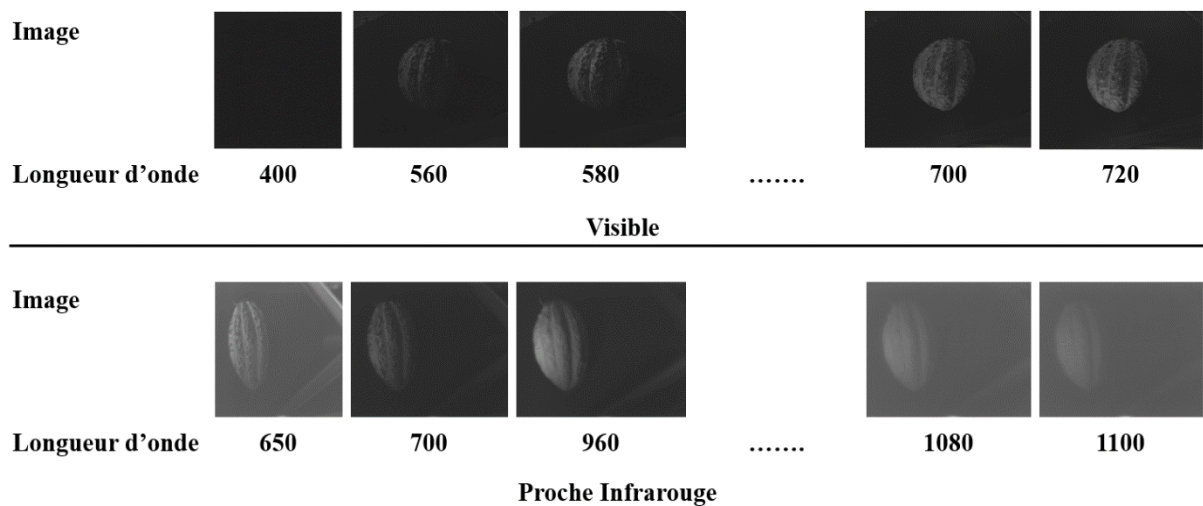
### 3.2.1. Cabosse de cacao

Pour l’acquisition des images des cabosses de cacao en multispectrale, nous avons utilisé la caméra MV1-D1312-3D02 qui utilise la technologie de capteur CMOS qui permet

une résolution de 1312 x 1082 pixels et un taux de rafraîchissement allant jusqu'à 506 images par seconde.


Nous avons effectué une expérience pour capturer des images multispectrales avec deux caméras à savoir le visible et le proche infrarouge dans la salle noire du laboratoire ImVia à l'université de Bourgogne. Nous avons choisi de travailler avec 9 cabosses de cacao pour cette expérience. Pour capturer les spectres dans la plage visible, nous avons utilisé des longueurs d'onde allant de 400 à 720 nm avec une taille de 800x1082, tandis que pour le proche infrarouge, nous avons utilisé des longueurs d'onde allant de 650 à 1100 nm avec une taille de 1200x1082.

La figure 38 présente quelques images dans différentes longueurs d'onde utilisé :



**Figure 38 :** Quelques images dans diverses longueurs d'onde

Nous avons réalisé une opération de recadrage pour éliminer les artefacts présents dans les images ci-dessous. Cette étape de recadrage consistait à ajuster la zone d'intérêt de l'image en la délimitant de manière précise. Après cette opération, nous avons obtenu une nouvelle version des images. Pour mieux visualiser les résultats, nous avons fourni les images avant et après le recadrage, afin que les différences soient facilement identifiables. La figure 39 présente le résultat obtenu.



**Figure 39 :** Avant et après recadrage d'images de cabosses multispectrales

Le tableau ci-dessous donne la description des images :

**Tableau 12 :** Description des images multispectrales

	<b>Caméra visible</b>	<b>Caméra proche infrarouge</b>
<b>Taille</b>	800 x 1082	1200 x 1082
<b>Nombre cabosse</b>	9	9
<b>Nombre image par cabosse</b>	17	22
<b>Total image</b>	153	198


Les différentes longueurs d'onde utilisées dans cette étude sont représentées dans le tableau 13 :

**Tableau 13 :** Longueur d'onde des caméras du visible et du proche infrarouge

<b>Caméra</b>	<b>VIS</b>	<b>NIR</b>
<b>Longueur d'onde</b>	400 ; 420 ; 440 ; 460 ; 480 ; 500 ; 520 ; 540 ; 560 ; 580 ; 600 ; 620 ; 640 ; 660 ; 680 ; 700 ; 720	650 ; 700 ; 720 ; 740 ; 760 ; 780 ; 800 ; 820 ; 840 ; 860 ; 880 ; 900 ; 920 ; 940 ; 960 ; 980 ; 1000 ; 1020 ; 1040 ; 1060 ; 1080 ; 1100
<b>Total</b>	17	22

Les données que nous avons sont organisées de manière hiérarchique, avec plusieurs niveaux de répertoires imbriqués les uns dans les autres. Tout d'abord, nous avons un répertoire principal appelé DB\_MultiSpectrale. À l'intérieur de ce répertoire, nous trouvons un répertoire appelé Cocoa et un autre sous répertoire de Cocoa appelé Cropping.

Dans le répertoire Cropping, nous trouvons les répertoires pour les deux caméras disponibles, à savoir Camera NIR et Camera VIS. Pour chaque caméra, nous trouvons des sous-répertoires pour chacune des neuf cabosses disponibles. Ces sous-répertoires sont nommés cabosse 1 à cabosse 9. La figure 40 présente cette hiérarchie des répertoires de notre base de données.



**Figure 40** : Structure du jeu de données d'images multispectrale des cabosses de cacao.

### 3.2.2. Fèves de cacao

Les fèves que nous avons sélectionnées pour l'acquisition d'images multispectrales partagent les mêmes caractéristiques que celles que nous avons examinées dans la section 3.1.2. Cependant, cette fois-ci, nous allons encore plus loin en effectuant la mesure spectrale de 30 échantillons pour chaque catégorie de fèves.

Cette méthode nous permet d'obtenir des données plus détaillées sur les propriétés spectrales des fèves dans chaque catégorie, nous permettant ainsi de mieux comprendre les variations spectrales au sein de chaque groupe. En effet, cette approche nous fournit des informations plus précises sur les propriétés physiques de chaque échantillon de fèves, nous permettant ainsi de mieux caractériser la variabilité des propriétés spectrales.


#### 3.2.2.1. Image Multispectrale

Nous avons effectué une expérience pour capturer des images multispectrales avec deux caméras à savoir le visible et le proche infrarouge dans la salle noire du laboratoire ImVia à l'université de Bourgogne. Nous avons choisi de travailler avec 8 lots de fèves de chaque catégorie pour cette expérience. Pour capturer les spectres dans la plage visible, nous avons utilisé des longueurs d'onde allant de 400 à 720 nm avec une taille de 800x700, tandis que pour le proche infrarouge, nous avons utilisé des longueurs d'onde allant de 650 à 1100 nm avec une taille de 800x700.



- **Caméra du visible**


La plage de longueurs d'onde de 400 à 720 nm utilisée par cette caméra offre une résolution spectrale de 33 bandes à intervalle de 10 nm chacune. Cette gamme de longueurs d'onde permet une grande précision dans la mesure des couleurs et des contrastes des objets, ainsi que la détection de variations subtiles dans les caractéristiques spectrales des cibles observées. En utilisant ces longueurs d'onde, la caméra est capable de capturer des images avec une fidélité et une précision élevée. La figure 41 présente quelques images.



**Figure 41 :** Quelques images de fèves avec la caméra du visible

- **Caméra du proche infrarouge**

La plage de longueurs d'onde utilisée pour capturer ces 46 images s'étend de 610 à 1100 nm, avec un intervalle de 10 nm entre chaque bande spectrale. Cette gamme de longueurs d'onde est particulièrement utile pour la capture d'images infrarouges, qui peuvent révéler des détails invisibles à l'œil nu, tels que la température ou les différences de densité dans les matériaux. Les 46 images obtenues avec ces longueurs d'onde fournissent des données riches et détaillées sur les propriétés de l'objet ou de la scène capturée, permettant des analyses approfondies et des interprétations précises des résultats. La figure 42 présente quelques images.




**Figure 42** : Quelques images de fèves avec la caméra du proche infrarouge

### 3.2.2.2. Mesure spectrale

La mesure spectrale de fève de cacao avec le spectrophotomètre CS2000 est un processus important pour l'industrie du chocolat, car il permet de caractériser la qualité des fèves en termes de couleur et de teneur en composés spécifiques, tels que les flavonoïdes. Le CS2000 mesure la réflectance des fèves dans une gamme de longueurs d'onde allant de l'ultraviolet à l'infrarouge proche, ce qui permet d'obtenir des données spectrales détaillées sur les propriétés optiques de la fève. Ces données peuvent être utilisées pour évaluer la maturité, l'origine et la qualité de la fève, ainsi que pour déterminer les niveaux de contaminants et les impuretés.

La mesure spectrale de fève de cacao avec le CS2000 est particulièrement utile pour l'optimisation des processus de torréfaction et de broyage des fèves de cacao, qui sont des étapes critiques dans la production de chocolat. En utilisant les données spectrales, les fabricants peuvent ajuster précisément les paramètres de torréfaction et de broyage pour obtenir une saveur et une texture optimales, ainsi qu'une couleur uniforme et attrayante. Cette méthode de mesure est également importante pour le développement de produits de chocolat de qualité supérieure, car elle permet de sélectionner les fèves les plus appropriées en fonction de leurs propriétés spectrales.

Les mesures spectrales ont été réalisées dans la salle blanche du laboratoire ImViA de l'université de Bourgogne. Cette salle blanche est un environnement contrôlé avec un niveau de contamination très faible qui permet d'obtenir des mesures précises et fiables en minimisant les interférences causées par les particules en suspension dans l'air. Cette approche est particulièrement importante pour les mesures spectrales, qui peuvent être sensibles à des perturbations externes.



**Figure 43 :** Manipe des mesures spectrales des fèves de cacao en salle blanche

Les mesures ont été effectuées sur les trois catégories de fèves, avec un total de 30 échantillons prélevés pour chaque catégorie. En utilisant des échantillons de chaque catégorie, nous avons pu obtenir des données représentatives de l'ensemble de la population de fèves étudiées, ce qui renforce la validité et la fiabilité des résultats obtenus.

Le spectrophotomètre CS2000 fournit deux types de valeurs : les valeurs de longueurs d'onde dans le domaine visible et les valeurs de l'espace Lab. Les valeurs de longueurs d'onde dans le domaine visible indiquent la quantité de lumière réfléchiée par l'échantillon à différentes longueurs d'onde dans la plage visible du spectre électromagnétique. Ces valeurs sont importantes pour caractériser la couleur de l'échantillon et peuvent être utilisées pour évaluer la qualité de la fève de cacao.

D'un autre côté, les valeurs de l'espace Lab sont une représentation mathématique de la perception humaine de la couleur. L'espace Lab permet de quantifier de manière précise les propriétés de couleur de l'échantillon. Ces valeurs sont utiles pour la comparaison et l'analyse de la couleur entre différents échantillons, ce qui est important pour garantir la qualité constante du produit final.

Nous allons représenter les deux types de données fournies par le spectrophotomètre CS2000 pour chaque catégorie. Cela signifie que pour chaque catégorie de fèves de cacao, nous allons présenter les valeurs de longueurs d'onde dans le domaine visible ainsi que les valeurs de l'espace Lab. Cette approche permettra d'obtenir une vue d'ensemble de la qualité de chaque catégorie de fèves en termes de couleur, en fournissant des informations détaillées sur la quantité de lumière réfléchiée à différentes longueurs d'onde ainsi que sur la perception humaine de la couleur.

- **Category 1 :**


Le tableau ci-dessous affiche les mesures spectrales de quelques longueurs d'onde pour les échantillons de la première catégorie, accompagné d'un graphique représentant ces mesures.

**Tableau 14 :** Mesure spectrale des échantillons des fèves la catégorie 1.

Data Name	380nm	390nm	400nm	410nm	710nm	720nm	730nm	740nm	750nm	760nm	770nm	780nm
F1	7,83	4,53	5,71	5,94	39,20	41,40	43,30	45,20	47,20	48,90	50,80	52,60
F2	7,21	5,31	4,71	5,17	32,00	34,10	36,30	38,50	40,70	42,80	45,10	47,20
F3	9,64	8,11	6,85	7,56	43,60	46,50	49,20	51,90	54,80	57,60	60,20	62,70
F4	9,02	5,19	5,17	5,67	41,50	44,10	46,90	49,30	51,90	54,50	56,80	59,40
F5	14,70	6,51	7,92	8,49	59,20	61,50	63,70	65,60	67,70	69,20	70,70	72,70
F6	9,14	7,84	8,82	8,73	40,10	42,00	43,80	45,40	47,10	48,50	50,20	51,70
F7	6,14	6,22	4,70	5,63	42,60	44,90	47,00	49,00	51,20	52,80	54,90	56,60
F8	9,57	6,85	6,83	6,73	46,20	49,50	52,70	55,70	58,70	61,80	64,80	67,60
F9	8,26	7,06	6,09	6,30	37,60	40,10	42,50	45,00	47,50	49,70	52,20	54,40
F10	10,60	6,93	6,95	6,71	50,10	52,90	55,30	57,90	60,30	62,60	64,70	66,90
F11	11,20	7,85	5,64	6,40	49,60	51,90	53,90	56,00	57,70	59,30	61,00	62,90
F12	9,30	6,97	5,18	5,22	43,80	46,40	48,90	51,30	53,70	55,90	58,00	60,50
F13	8,10	4,06	4,42	5,12	40,30	42,80	45,20	47,60	50,10	52,40	54,60	57,00
F14	6,57	5,82	5,09	5,35	28,90	31,20	33,50	35,70	38,10	40,30	42,70	45,10
F15	12,40	11,70	11,70	11,60	58,80	61,80	64,80	67,60	70,50	72,80	75,70	78,30
F16	12,50	7,92	6,82	6,19	48,20	50,80	53,40	55,80	58,30	60,50	63,00	65,40
F17	11,30	6,13	7,52	7,05	48,00	50,70	53,40	56,00	58,70	60,90	63,50	65,90
F18	7,87	4,85	4,31	4,58	32,20	34,30	36,30	38,30	40,40	42,40	44,30	46,30
F19	9,61	6,66	5,71	6,06	34,20	36,30	38,50	40,60	42,90	45,10	47,50	49,90
F20	9,11	5,53	4,73	5,51	40,90	43,10	44,80	46,70	48,30	49,80	51,50	52,90
F21	7,33	4,42	5,42	5,77	28,20	30,10	31,90	33,70	35,70	37,40	39,20	41,20
F22	10,60	4,36	5,07	5,90	43,10	45,50	47,70	50,00	51,90	54,00	55,80	57,60
F23	9,95	4,53	5,77	5,93	43,90	45,90	47,40	49,10	50,60	52,10	53,70	55,10
F24	3,97	3,98	5,06	4,81	37,20	39,80	42,10	44,30	46,70	48,60	50,60	52,90
F25	4,75	4,14	3,55	3,66	29,80	31,30	32,60	34,00	35,30	36,30	37,50	38,60
F26	9,40	7,37	6,42	6,83	33,70	36,10	38,40	40,80	43,40	45,70	48,20	50,60
F27	11,40	6,28	5,99	7,04	46,30	48,60	50,70	52,70	54,90	56,80	58,60	60,40
F28	10,40	7,80	5,62	5,83	44,60	47,00	49,40	51,50	53,70	55,70	57,60	60,00

F29	5,28	2,58	3,84	4,04	34,00	36,30	38,50	40,80	42,90	44,70	46,60	48,60
F30	10,90	6,34	6,00	6,15	47,00	49,20	51,30	53,20	55,20	56,70	58,50	60,40

Le tableau 14 affiche les mesures dans l'espace Lab les échantillons de la première catégorie, accompagné d'un graphique représentant ces mesures.




**Figure 44 :** Graphique des mesures spectrales des échantillons des fèves la catégorie 1

**Tableau 15 :** Mesure dans l'espace Lab des échantillons des fèves la catégorie 1

Data Name	L*	a*	b*
F1	42,19	13,73	18,44
F2	35,94	13,82	14,68
F3	42,3	15,49	16,25
F4	40,88	15,19	18,88
F5	52,57	16,77	27,81
F6	45,94	11,33	14,77
F7	41,75	16,48	21,84
F8	40,15	17,84	15,92
F9	40,38	13,29	16,72
F10	44,8	17,39	21,47
F11	45,83	17,37	24,25
F12	40,5	17,35	20,42
F13	38,69	17,25	19,17
F14	33,19	12,92	9,91
F15	51,4	16,1	16,97
F16	45,71	15,54	21,51
F17	44,58	16,18	19,47
F18	36,03	14,69	15,5
F19	38,75	13,97	14,41
F20	41,77	16,23	21,71
F21	36,92	10,05	12,28
F22	42,33	16,23	20,96

F23	44,68	16,61	23,16
F24	37,01	15,87	16,32
F25	33,29	16,34	17,2
F26	38,38	12,36	11,28
F27	44,67	16,19	20,79
F28	43,57	14,98	21,15
F29	33,93	17,84	18,07
F30	43,63	17,61	22,68



**Figure 45 :** Graphique mesure dans l'espace Lab des échantillons des fèves la catégorie 1


- **Category 2 :**

Le tableau 16 affiche les mesures spectrales de quelques longueurs d'onde pour les échantillons de la deuxième catégorie, accompagné d'un graphique représentant ces mesures.

**Tableau 16 :** Mesure spectrale des échantillons des fèves la catégorie 2

Data Name	380nm	390nm	400nm	710nm	720nm	730nm	740nm	750nm	760nm	770nm	780nm
NF1	7,27	6,01	6,15	15,40	15,80	16,10	16,40	16,80	16,90	17,20	17,60
NF2	11,50	9,54	11,50	34,50	35,20	35,80	36,60	37,50	38,00	38,70	39,50
NF3	8,09	7,06	6,20	21,40	22,00	22,60	23,30	24,00	24,40	25,00	25,70
NF4	7,67	5,31	5,78	19,40	20,00	20,40	21,00	21,60	22,10	22,50	23,00
NF5	4,37	4,40	4,37	13,40	14,70	16,10	17,60	19,20	20,80	22,60	24,50
NF6	8,41	6,60	6,81	22,90	23,60	24,30	25,00	25,70	26,30	27,00	27,70
NF7	3,68	3,56	3,81	13,70	14,00	14,40	14,70	15,10	15,30	15,60	16,00
NF8	3,78	2,59	3,00	14,50	15,50	16,50	17,50	18,60	19,50	20,60	21,70
NF9	2,22	2,12	1,88	5,98	6,62	7,30	8,07	8,89	9,72	10,70	11,60
NF10	1,96	1,88	1,85	4,24	4,33	4,43	4,52	4,62	4,66	4,76	4,86
NF11	4,34	3,82	3,77	16,50	18,00	19,70	21,50	23,30	25,00	26,90	28,80
NF12	7,94	6,27	5,52	25,90	27,20	28,30	29,70	30,90	31,90	33,10	34,20
NF13	8,05	5,36	5,05	26,00	26,90	27,90	28,90	29,80	30,50	31,40	32,20
NF14	5,13	3,87	4,15	17,10	18,40	19,60	21,00	22,40	23,60	25,00	26,50

NF15	4,40	4,10	4,16	12,90	13,30	13,60	14,00	14,40	14,60	14,90	15,30
NF16	8,54	5,85	6,08	17,90	18,30	18,70	19,10	19,60	19,90	20,30	20,70
NF17	9,68	6,50	7,57	22,50	23,00	23,50	24,00	24,60	24,90	25,40	25,80
NF18	4,40	3,60	3,89	16,00	16,90	17,70	18,70	19,80	20,60	21,70	22,60
NF19	3,71	3,69	3,71	8,74	8,89	9,02	9,21	9,39	9,48	9,63	9,78
NF20	10,50	8,27	8,59	26,90	27,70	28,20	29,00	29,70	30,30	30,80	31,40
NF21	8,23	7,86	8,71	27,60	28,40	29,30	30,40	31,30	32,10	33,20	34,20
NF22	10,90	8,51	9,18	25,40	25,90	26,30	26,90	27,40	27,70	28,20	28,60
NF23	4,04	3,87	3,62	10,90	12,00	13,10	14,50	15,90	17,20	18,80	20,50
NF24	5,39	4,95	5,00	13,10	14,00	15,00	16,10	17,20	18,30	19,50	20,70
NF25	4,06	4,34	4,40	15,00	16,40	17,90	19,60	21,30	23,00	24,90	26,80
NF26	5,01	4,02	4,22	15,40	16,40	17,40	18,50	19,60	20,50	21,70	22,70
NF27	10,50	7,58	5,60	41,20	43,30	45,10	47,30	49,20	50,90	52,80	54,40
NF28	7,61	7,55	6,23	26,00	28,10	30,20	32,40	34,60	36,70	38,80	41,20
NF29	3,40	2,56	2,86	14,00	15,10	16,30	17,60	18,90	20,10	21,40	22,80
NF30	4,21	2,93	3,00	16,40	18,00	19,50	21,30	23,00	24,70	26,40	28,20




**Figure 46 :** Graphique mesure dans l'espace Lab des échantillons des fèves la catégorie 2

Le tableau 17 affiche les mesures dans l'espace Lab les échantillons de la deuxième catégorie, accompagné d'un graphique représentant ces mesures.

**Tableau 17 :** Mesure dans l'espace Lab des échantillons des fèves la catégorie 2

Data Name	L*	a*	b*
NF1	36,97	1,82	8,67
NF2	52,83	3,7	14,45
NF3	40,65	3,85	11,69

NF4	38,58	4,24	11,22
NF5	26,99	4,43	3,91
NF6	41,66	4,23	11,97
NF7	32,44	3,64	10,2
NF8	27,26	7,33	9,77
NF9	17,4	2,77	2,76
NF10	18,95	1,25	4,88
NF11	26,32	7,35	5,89
NF12	38,52	8,68	12,67
NF13	40,13	9,2	16,02
NF14	30,81	6,26	9,02
NF15	31,52	3,1	8,69
NF16	38,83	3,46	10,09
NF17	42,91	3,19	11,84
NF18	32,32	5,5	10,09
NF19	28,77	1,39	6,82
NF20	46,31	3,39	11,9
NF21	45,49	4,92	11,88
NF22	46,38	2,29	10,62
NF23	25,45	3,19	3,74
NF24	29,5	3,61	3,7
NF25	27,77	4,7	4,26
NF26	28	7,25	5,88
NF27	45,32	12,11	18,78
NF28	36,05	8,26	8,61
NF29	24	8,26	8,05
NF30	24,76	8,68	6,41



**Figure 47 :** Graphique des mesures dans l'espace Lab des échantillons des fèves la catégorie 2


- **Category 3 :**

Le tableau 18 affiche les mesures spectrales de quelques longueurs d'onde pour les échantillons de la troisième catégorie, accompagné d'un graphique représentant ces mesures.



**Tableau 18 : Mesure spectrale des échantillons des fèves la catégorie 3**

Data Name	380nm	390nm	400nm	700nm	710nm	720nm	730nm	740nm	750nm	760nm	770nm	780nm
N1	10,9	4,66	5,17	42,9	45,2	47,2	49,2	50,9	52,7	54,3	56	57,4
N2	17,3	7,72	7,07	38,8	40,4	41,8	43,1	44,6	45,9	47,2	48,6	49,6
N3	7,48	7,47	5,93	43,9	46,3	48,4	50,4	52,4	54,5	56,5	58,4	60
N4	17,2	7,01	5,91	51,4	53,7	55,5	57,3	58,9	60,7	62,1	63,9	64,9
N5	15	5,28	5,47	40,7	42,7	44,5	46,2	47,8	49,6	51,1	52,8	54,1
N6	13,8	5,37	5,02	41,6	43,9	46	48,1	49,9	52	53,9	55,8	57,3
N7	10,3	5,73	5,42	44,1	46,5	48,4	50,4	52,3	54,3	56,1	57,8	59,5
N8	13,7	7,65	6,33	47,1	49,5	51,5	53,5	55,3	57,2	59	60,8	62,3
N9	12,9	6,28	6,31	46,8	49	50,8	52,8	54,2	56	57,6	59,1	60,4
N10	7,53	5,88	4,15	46,9	49,8	52,2	54,7	56,8	59,2	61,4	63,6	65,1
N11	7,97	5,89	6,34	36,1	37,8	39,3	40,7	42	43,5	44,8	46,4	47,5
N12	3,58	5,23	3,79	41	43,3	45,2	47,1	48,8	50,7	52,3	54	55,5
N13	13	4,58	4,47	37	39	40,7	42,5	44	45,8	47,3	49,1	50,4
N14	10,7	5,14	4,81	33,7	35,3	36,7	38	39,2	40,5	41,7	43,1	43,9
N15	14,7	7,37	7,29	41	42,6	44	45,4	46,8	48,2	49,5	51	52
N16	14,1	5,59	7,74	45,5	47,3	48,8	50,5	51,8	53,6	55,2	56,7	58,1
N17	14,1	5,38	7,09	43,5	45,6	47,5	49,3	50,9	52,7	54,6	56,4	57,9
N18	10,6	7,77	6,05	44,4	46,5	48,2	49,9	51,4	53,1	54,6	56,1	57,4
N19	14,2	7,2	5,22	49,2	51,9	54,2	56,2	58,1	60	61,8	63,7	65
N20	14	6,38	6,28	44,8	47,1	49,1	51	52,7	54,6	56,4	58,2	59,4
N21	18,5	6,6	8,73	52,1	54,4	56,2	58,2	60	62	63,7	65,5	66,9
N22	22,9	8,39	8,84	51,2	53,2	54,7	56,2	57,6	59	60,4	62,1	62,9
N23	14,5	7,93	5,89	37,1	38,6	40	41,3	42,6	44	45,3	46,7	47,9
N24	10,9	5,65	6,3	44,3	46,5	48,3	50,3	52,1	53,9	55,7	57,4	58,8
N25	14,3	7,76	7,48	45,4	47,1	48,7	50	51,3	52,7	53,9	55,5	56,3
N26	13	5,8	6,63	49,8	52,2	54,4	56,6	58,5	60,5	62,4	64,4	66
N27	4,44	3,15	3,17	22,5	23,8	24,8	25,9	26,9	27,9	28,8	29,9	30,8
N28	10,8	5,98	4,31	33,4	35,2	36,7	38,1	39,4	40,7	42,1	43,3	44,3
N29	8,99	5,22	4,28	40,5	42,8	44,8	46,7	48,5	50,4	52	54	55,4
N30	16,3	7,5	6,12	40,2	42,1	43,6	45,1	46,5	48	49,3	50,9	52




**Figure 48 :** Graphique des mesures dans l'espace Lab des échantillons des fèves la catégorie 3

Le tableau 19 affiche les mesures dans l'espace Lab les échantillons de la troisième catégorie, accompagné d'un graphique représentant ces mesures.

**Tableau 19 :** Mesure dans l'espace Lab des échantillons des fèves la catégorie 3

Data Name	L*	a*	b*
N1	42,05	19,31	24,25
N2	47,48	13,9	21,74
N3	45,29	17,44	22,98
N4	50,64	17,09	29,72
N5	44,22	16,03	25,17
N6	42,96	16,59	24,41
N7	45,67	17,11	24,18
N8	46,12	17,97	22,79
N9	46,94	17,1	25,29
N10	43,98	19,02	25,61
N11	45,45	12,47	20,11
N12	41,13	18,67	26,17
N13	39,93	17,85	22,55
N14	41,69	14,86	23,05
N15	48,05	15,2	24,64
N16	49,45	16,27	24,82
N17	49,1	13,64	23,81
N18	46,27	17,35	23,81
N19	43,39	21,51	25,03
N20	45,78	17,23	22,96
N21	52,13	15,61	24,98
N22	52,57	16,39	24,84
N23	46,19	14,27	22,93
N24	45,54	18,14	24,56
N25	49,63	16,12	24,93

<b>N26</b>	47,1	19,12	26,26
<b>N27</b>	34,33	11,38	17,64
<b>N28</b>	40,07	15,14	22,36
<b>N29</b>	40,28	19,14	25,18
<b>N30</b>	45,77	15,24	21,79



**Figure 49 :** Graphique des mesures dans l'espace Lab des échantillons des fèves la catégorie 3

## Conclusion

L'utilisation des techniques d'imagerie pour la mise en place d'une base de données d'images de cabosses et de fèves de cacao, ainsi que la mesure spectrale des fèves, représentent des avancées importantes pour l'industrie du cacao. Ces avancées permettent de collecter des données précises sur les caractéristiques des cabosses et des fèves, qui aideront les producteurs de mieux comprendre et contrôler le processus de fermentation, d'identifier les variétés de cacao et leur maturité, d'améliorer la qualité des fèves et d'augmenter leur valeur marchande. Ces données peuvent contribuer à accroître la rentabilité de l'industrie du cacao, à renforcer la durabilité des exploitations agricoles et à répondre à la demande croissante des consommateurs pour des produits de cacao de qualité supérieurs.

## **Chapitre 4 : Détection et extraction des cabosses de cacao en milieu naturel avec des méthodes de Deep Learning**

*(“Detecting and extracting cocoa pods in the natural environment using deep learning methods”, Kacoutchy Jean AYIKPA, Diarra MAMADOU, Sovi Guillaume SODJINO, Abou Bakary BALLO, Pierre GOUTON and Kablan Jérôme ADOU; Digital Technologies and Applications, 668, Springer Nature Switzerland, pp.164-174, 2023, Lecture Notes in Networks and Systems)*

### **Introduction**

Les applications de traitement d'images reposent de plus en plus sur l'extraction et la détection d'objets. La récolte des cabosses de cacao produit les fèves de cacao utilisées pour faire du chocolat. L'un des produits les plus appréciés, le chocolat, est fabriqué à partir de ces fèves. Il serait possible de développer des moyens automatiques pour évaluer la maturité des cabosses de cacao, la présence de maladies des cabosses ou la quantité de cacao recueillie à un endroit spécifique en séparant les cabosses de cacao des autres matériaux naturels. Notre recherche vise à évaluer dans quelle mesure les stratégies basées sur l'apprentissage en profondeur pour localiser et retirer les cabosses de cacao de leur environnement naturel fonctionnent. Ce modèle permettra aux agriculteurs de compter les cabosses de cacao sur un cacaoyer spécifique et en général sur une zone définie. Les algorithmes U-Net et Fully Convolutional Network (FCN) ont été utilisés. Dans l'analyse des résultats, la phase de validation des algorithmes a donné des scores pour U-Net et FCN de 93,61 et 93,06, respectivement, et la phase de test a donné des scores pour U-Net et FCN de 92,92 et 94,20, respectivement. Cela indique que FCN a pu généraliser son apprentissage avec plus de précision que U-NET. En utilisant des mesures telles que le coefficient de similarité de Jaccard et le coefficient de Dice, ces stratégies ont été évaluées.

### **4.1. Généralités**

Le cacao est une culture importante pour de nombreuses régions du monde, fournissant des ingrédients clés pour la production de chocolat et d'autres produits alimentaires. Les fèves de cacao proviennent des cabosses, et chaque cabosse contient de nombreuses fèves. Toutefois, de nombreux sous-produits sont produits lors de la torréfaction et du broyage, avant que le chocolat ne soit finalement produit. Dans un environnement non contrôlé, il peut être difficile de trouver et de retirer une cabosse de cacao. C'est pourquoi nous suggérons de comparer quelques techniques basées sur l'apprentissage profond pour évaluer leur performance sur nos ensembles d'images de cabosse. Bien que ce domaine ait connu une avancée significative au cours des dernières années, l'évaluation objective des différentes initiatives suggérées fait encore défaut. La segmentation d'une image revient à

enlever un objet de celle-ci. Cela signifie qu'une image segmentée peut être considérée comme la portion pertinente d'un objet qui correspond spécifiquement à la requête de l'utilisateur à partir de photos que l'utilisateur a minutieusement examinées pour découvrir l'objet d'intérêt [102]. Le processus de segmentation d'image divise les pixels en groupes en fonction de critères prédéterminés. La division d'une image est composée de pixels disposés en régions. Elle permet, par exemple, de supprimer l'arrière-plan des objets [103]. Bien qu'il y ait eu de nombreuses études sur les méthodes de segmentation d'images, il y en a eu presque aucune sur la segmentation des cabosses de cacao [104] [105] [106].

La segmentation d'image est un processus crucial de bas niveau qui divise une image en parties visuellement distinctes et cohérentes en utilisant divers critères, tels que la texture et/ou la couleur. De cette simple déclaration, la question fondamentale de l'évaluation théorique de ces méthodologies émerge. La majorité des techniques de segmentation prennent en compte les entrées humaines en tant que restrictions de premier plan et d'arrière-plan, telles que les fruits, les pointeurs et d'autres éléments. Au début, la probabilité d'arrière-plan/avant-plan est prédite à l'aide d'approches conventionnelles qui combinent des restrictions avec des caractéristiques d'image de base. Kramer et al.[107] ont créé une carte de probabilité de localisation des plantes en utilisant un modèle de réseau neuronal pour la régression de la posture. Les tiges sont extraites avec précision de la carte thermique au centimètre près. Une toute nouvelle architecture de modèle conjoint construite sur FC-DenseNet a été utilisée par Lottes et al. [108] lors de la segmentation, le codeur crée généralement une représentation compressée mais riche en informations de l'entrée, et le décodeur suréchantillonne les représentations à la taille d'entrée d'origine tout en effectuant des prédictions par pixel. Cependant, deux décodeurs sont connectés au volume de données du codeur. Pour déterminer si un pixel est un sol, une plante, des mauvaises herbes dicotylédones ou des graminées, le décodeur de plante génère des caractéristiques de plante. De plus, le décodeur de tige détecte les tiges dans la région des plantes et des mauvaises herbes. Cependant, dans des situations compliquées, ces stratégies sont inutiles car elles ne prennent en compte que les aspects de bas niveau tout en négligeant les informations de haut niveau. Les méthodes basées sur l'apprentissage en profondeur exploitent complètement les caractéristiques de haut niveau pour utiliser les contraintes de segmentation des images couleur et différencier les plantes des mauvaises herbes, même s'il reste encore du travail à faire pour améliorer les méthodes conventionnelles [109] [110] [111] [112]. La première méthode basée sur l'apprentissage en profondeur et de nombreuses techniques d'échantillonnage de points aléatoires qui sont maintenant considérées comme des normes de l'industrie ont été proposées par Xu et al [113].

L'architecture du réseau fait l'objet de quelques recherches. DeepLabv3 est une architecture de segmentation sémantique qui améliore DeepLabv2 en apportant un certain nombre de modifications de très haut niveau. Les modules qui utilisent la convolution en cascade ou en parallèle pour capturer le contexte à plusieurs échelles visent à résoudre le problème de la segmentation des objets à de nombreuses échelles. Les entrées multi-échelles sont souvent traitées à l'aide du même modèle. Alors que les moindres détails de l'objet sont préservés dans les entrées à grande échelle, les réponses des caractéristiques des entrées à petite échelle diminuent la portée et la précision de la segmentation. Des exemples de ce type peuvent être trouvés dans Farabet et al. [114], qui applique une transformation pyramidale laplacienne à l'image d'entrée, alimente l'entrée de chaque échelle vers un DCNN, puis fusionne les cartes de caractéristiques de toutes les échelles. Pyramid Scene Parsing Net (PSP) [115] a récemment effectué une mise en commun spatiale à plusieurs échelles de grille et a affiché des performances exceptionnelles sur de nombreux critères de segmentation sémantique. D'autres techniques basées sur LSTM existent [116] pour agréger le contexte global [117] [118] [119] et la reconnaissance d'objets [120] ainsi que la mise en commun pyramidale spatiale. Nous découvrons expérimentalement qu'il est crucial de s'entraîner avec la normalisation par lots pour les modules suggérés [121].

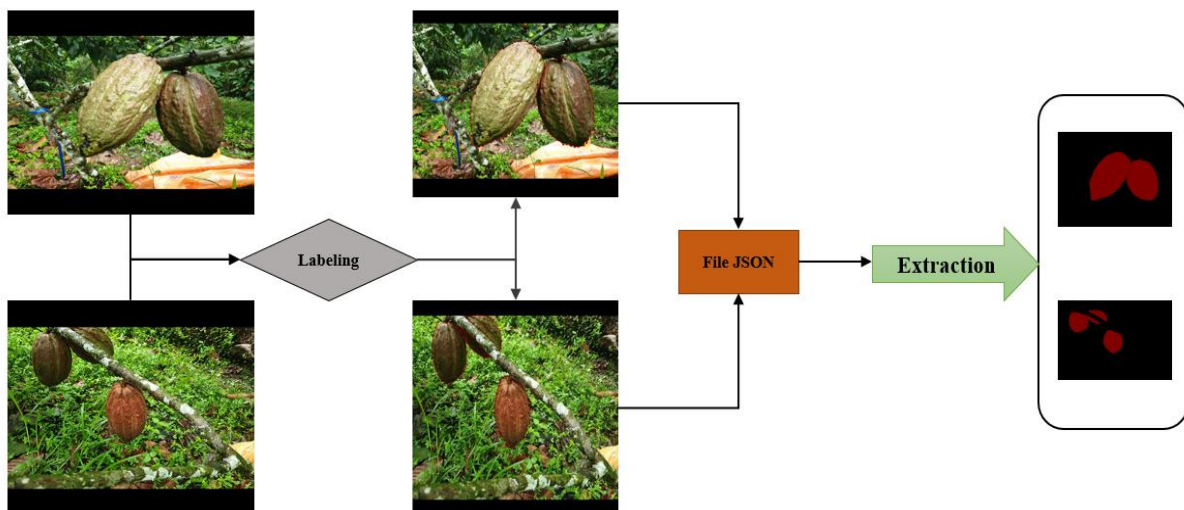
L'intérêt de cette recherche nous a amenés à adopter deux algorithmes basés sur l'apprentissage profond, à savoir U-Net et FCN. Pour mener notre recherche, nous devons d'abord créer une base de données de cabosse de cacao qui implique de trouver les coordonnées de chaque gousse sur chaque image avant de créer un masque. Nous utiliserons ensuite les algorithmes U-Net et FCN pour détecter et extraire les gousses de nos images. Chaque résultat sera comparé à une vérité de terrain obtenue en plongeant chaque objet dans un fond tout aussi compliqué. Afin d'évaluer de manière critique les approches basées sur l'apprentissage profond utilisées, nous fournirons l'ensemble des indicateurs de stabilité dans la dernière section. Une deuxième section permettra d'effectuer une évaluation quantitative de plusieurs procédures choisies pour leur diversité tout en décrivant le développement des images de test.

## **4.2. Collecte et annotation des jeux de données**

L'efficacité de l'annotation des données a un impact sur le bon fonctionnement des méthodes d'apprentissage supervisé. Dans le cas des images de cabosses de cacao, nous allons d'abord créer un ensemble de masques pour entraîner notre modèle profond pour la segmentation.

Chaque image est associée à un fichier JSON qui détaille l'arrangement spatial des pixels. Un polygone de délimitation avec les coordonnées spécifiées dans le fichier JSON est utilisé pour représenter chaque caractéristique. Toutes les cabosses de cacao dans les images sont annotées à l'aide du polygone de délimitation. Pour entraîner un modèle pour l'extraction de cabosses de cacao, il est essentiel de fournir des données annotées de manière précise. Les données doivent inclure des informations sur l'emplacement et la forme des cabosses, qui seront utilisées pour créer des masques d'annotation. Ces masques seront ensuite utilisés pour entraîner le modèle de segmentation qui permettra de séparer les cabosses du fond de l'image.

Il est important de noter que la qualité de l'annotation des données est cruciale pour la précision du modèle de reconnaissance. Si les annotations ne sont pas précises, le modèle peut mal fonctionner et produire des résultats incohérents. La figure 50 donne la description de cette annotation.



**Figure 50** : Processus de création des masques des cabosses de cacao

### 4.3. Algorithme de U-NET

U-Net est une architecture de réseau de neurones convolutifs qui est souvent utilisée pour la segmentation d'images biomédicales, notamment pour la segmentation d'images médicales en 3D, telles que les images d'IRM (Imagerie par Résonance Magnétique). L'architecture de U-Net comporte deux parties : une partie encodeur et une partie décodeur.

L'encodeur est constitué de plusieurs couches de convolution et de pooling, qui réduisent la résolution spatiale de l'image en extrayant les caractéristiques de bas niveau. Le décodeur, quant à lui, utilise des couches de déconvolution et de concaténation pour remonter dans la résolution de l'image en utilisant les caractéristiques de l'encodeur pour guider la segmentation.

La forme en U de l'architecture permet une connexion directe entre les couches de l'encodeur et du décodeur, ce qui permet à l'information de haute résolution d'être transmise au décodeur tout en conservant les caractéristiques de bas niveau.

U-Net a été largement utilisé pour la segmentation d'images médicales, y compris la segmentation de tumeurs, la segmentation de cellules et la segmentation de vaisseaux sanguins. Il a également été utilisé pour d'autres applications telles que la détection de glaucome et la segmentation de la peau [122].





Figure 51 : Architecture de U-NET

#### 4.4. Algorithme de Fully Convolutional Network (FCN)

Fully Convolutional Network (FCN) est un algorithme de traitement d'image qui a été développé pour la segmentation sémantique de scènes. Contrairement aux réseaux de neurones conventionnels, qui sont conçus pour classifier des images en utilisant des couches de neurones entièrement connectées, le FCN utilise des couches de convolution pour préserver l'information spatiale. Le FCN utilise des réseaux de neurones convolutifs profonds pour extraire des fonctionnalités d'une image, en utilisant des couches de convolution qui maintiennent la structure spatiale de l'image. Ensuite, des couches de déconvolution sont utilisées pour effectuer une segmentation pixel par pixel de l'image, en associant à chaque pixel une étiquette de classe correspondante. Le FCN est utilisé dans de nombreuses applications de traitement d'image, notamment la reconnaissance de forme, la détection d'objet, la localisation d'objet et la segmentation d'image. Il a également été appliqué à des domaines tels que la médecine, la robotique et l'analyse de vidéos. Le FCN a été l'un des premiers algorithmes à montrer qu'il était possible d'effectuer une segmentation sémantique



en utilisant des réseaux de neurones convolutifs. Depuis lors, de nombreuses variantes de l'algorithme ont été développées, chacune avec ses propres avantages et inconvénients en fonction des applications spécifiques [123] [124].



**Figure 52 :** Architecture de FCN

#### 4.5. Méthodologie de l'étude

Notre modèle suivra les étapes suivantes pour l'apprentissage de la segmentation d'image :

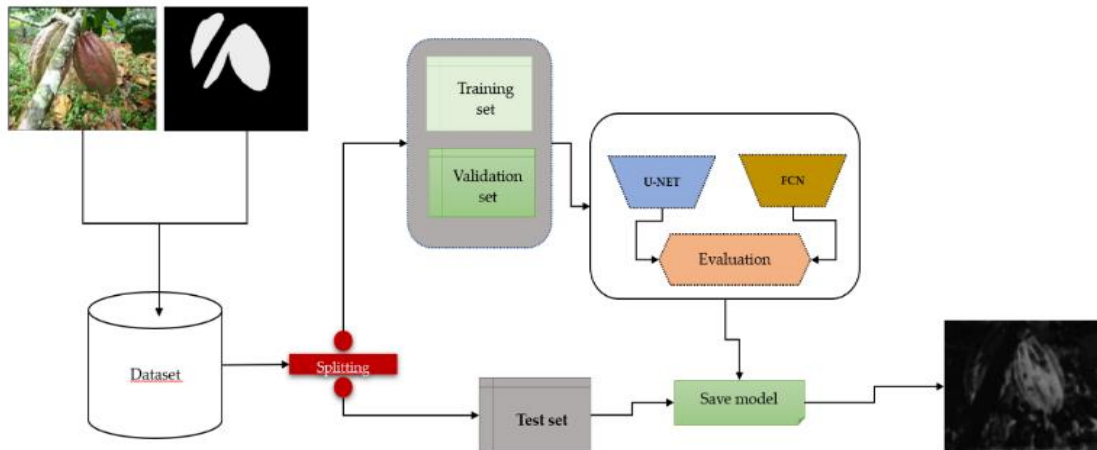
Tout d'abord, nous procédons au chargement de nos données, à savoir l'image originale et son masque. Ensuite, nous créons trois sections de l'ensemble de données, à savoir l'ensemble d'entraînement, l'ensemble de validation et l'ensemble de test. L'ensemble d'entraînement et l'ensemble de validation nous permettront d'apprendre le modèle, tandis que l'ensemble de test nous permettra d'évaluer les performances de notre modèle.

Par la suite, nous introduirons les données de l'ensemble d'entraînement et de l'ensemble de validation dans nos modèles, dans notre étude il s'agit de U-Net et de FCN, afin de former nos modèles en les évaluant. Nous utiliserons les métriques d'évaluation appropriées pour mesurer la précision et la performance de nos modèles.

Une fois que nous avons entraîné nos modèles, nous évaluons leur performance et sélectionnons celui qui donne les meilleurs résultats. Nous sauvegardons alors ce modèle optimal pour une utilisation future.

Enfin, nous procédons à des tests pour vérifier les performances de notre modèle en utilisant l'ensemble de test. Nous comparons les résultats de la segmentation obtenus par notre modèle avec les masques de référence pour déterminer l'efficacité et la précision de notre modèle. Nous utilisons des métriques pour évaluer la performance de notre modèle.

Le schéma de la figure 53 présente l'architecture générale de notre modèle :



**Figure 53 :** Architecture de la méthodologie de la détection et extraction des cabosses

#### 4.6. Résultats expérimentaux

Pour l'entraînement de notre algorithme a pris une taille de 16 lots à la fois pour mettre à jour les poids du modèle pendant 50 itérations à travers l'ensemble de données. Nous avons choisi l'optimiseur ADAM car il est efficace pour l'optimisation des réseaux de neurones et nous avons fixé un taux d'apprentissage de 0,001 pour contrôler l'ajustement des poids. Ces paramètres ont été déterminés afin d'obtenir la meilleure performance possible pour notre modèle d'apprentissage automatique. Pour évaluer les performances des modèles utilisés, nous avons utilisé les métriques suivantes :

L'exactitude (Accuracy) mesure à quelle fréquence l'algorithme classe correctement un point de données. Cette métrique est souvent utilisée pour évaluer les performances d'un modèle de classification binaire ou multi-classes, où l'objectif est de prédire la classe correcte pour chaque point de données. Sa formule est la suivante :

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (4-13)$$

La fonction de perte (Loss) est basée sur l'entropie croisée binaire. Elle est couramment utilisée dans les tâches de classification binaire, où l'objectif est de prédire une classe parmi deux options possibles [32]. La formule de cette fonction de perte est la suivante :

$$Loss = -\frac{1}{N} \sum_{i=1}^N y_i * \log(p(y_i)) + (1 - y_i) * \log(1 - p(y_i)) \quad (4-14)$$

L'indice de Jaccard (IoU), également appelé intersection sur union et coefficient de similarité de Jaccard, est une statistique utilisée pour évaluer la similitude et la diversité des

ensembles d'échantillons. Pour calculer le coefficient de Jaccard qui évalue la similarité entre des ensembles finis d'échantillons, on divise la taille de l'intersection par la taille de l'union des ensembles d'échantillons [125]. La formule de Jaccard est la suivante :

$$IoU = \frac{TP}{TP + FP + FN} \quad (4-15)$$

Le coefficient de Dice (Dice) mesure la similarité entre deux ensembles de pixels. Il n'est pas seulement une mesure du nombre de résultats positifs trouvés, mais il pénalise également les faux positifs trouvés par la méthode, comme la précision. Par conséquent, il est plus similaire à la précision qu'à l'exactitude. Le coefficient de Dice est utilisé pour mesurer la similitude entre deux ensembles de données. Il est calculé en divisant deux fois l'intersection des deux ensembles par la somme des éléments de chaque ensemble. Cette mesure est couramment utilisée dans les domaines de l'analyse d'images médicales, de la vision par ordinateur et de la segmentation d'images pour évaluer la qualité des résultats de l'algorithme de segmentation d'images [125].

$$Dice = \frac{2 * TP}{(TP + FP) + (TP + FN)} \quad (4-16)$$

#### 4.6.1. Etape d'apprentissage et de validation


Le tableau 20 présente les résultats de l'étape d'entraînement et validation des deux modèles utilisés à savoir U-Net et FCN.

**Tableau 20** : Performance de la phase d'entraînement et de validation

Modèles	Accuracy (%)	Loss (%)	IoU (%)	Dice (%)
U-Net	93.69	9.79	100.0	7.49
FCN	93.04	6.00	100.0	5.82

Le modèle U-Net atteint une précision de 93,69 % tandis que le modèle FCN présente une précision légèrement inférieure de 93,04 %. Les deux modèles sont donc très précis. En ce qui concerne la fonction de coût, le modèle FCN affiche une valeur plus faible de 6,00 % par rapport au modèle U-Net qui est de 9,79 %. Ces résultats indiquent que le modèle FCN a été légèrement plus performant dans la phase d'apprentissage et de validation sur la détection et l'extraction de cabosse. La figure ci-dessous présente l'histogramme des performances de la phase de validation.

Les deux modèles ont une IoU qui mesure la similitude entre les prédictions du modèle et les annotations de référence de 100%, ce qui est très encourageant et montre que les deux modèles sont capables de bien segmenter les images.




**Figure 54:** Histogramme des performances de la phase de validation

Le modèle U-Net a un coefficient de Dice de 7,49% tandis que le modèle FCN a un coefficient de Dice légèrement inférieur de 5,82%. Cela indique que le modèle U-Net a été légèrement plus performant dans la segmentation des images. Les courbes Accuracy et Loss sont représentées ci-dessous.

**Tableau 21 :** Courbe Accuracy et Loss de chaque modèle lors de l'étape d'apprentissage

Modèles	Accuracy	Loss
U-Net		



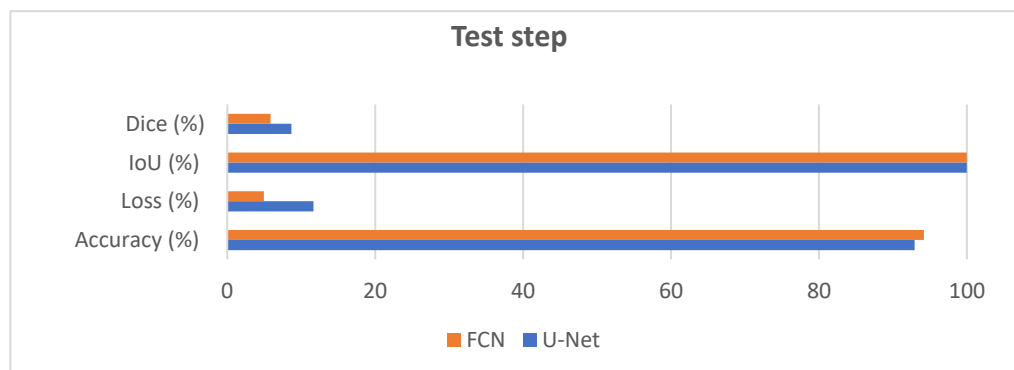
#### 4.6.2. Etape de test

**Tableau 22** : Récapitulatif des résultats des métriques lors de la phase de test du modèle

Models	Accuracy (%)	Loss (%)	IoU (%)	Dice (%)
U-Net	92,92	11,65	100	8,69
FCN	94,20	4,97	100	5,84

Le tableau 22 fournit une comparaison des résultats des métriques pour deux modèles différents de segmentation d'image, U-Net et FCN, pendant la phase de test. Les métriques évaluées sont l'Accuracy, la Loss, l'IoU et le Dice, qui fournissent des informations sur la précision, la généralisation et la qualité des prédictions de chaque modèle.






En analysant les résultats, nous pouvons observer que le modèle FCN obtient des scores supérieurs à U-Net pour la plupart des métriques. En effet, FCN atteint une Accuracy de 94,20%, une Loss de 4,97%, un IoU de 100% et un Dice de 5,84%, tandis que U-Net présente une Accuracy de 92,92%, une Loss de 11,65%, un IoU de 100% et un Dice de 8,69%. La figure 55 présente l'historique des performances de la phase de test.



**Figure 55** : Histogramme des performances de la phase de test

Cependant, il est important de noter que le modèle U-Net a obtenu une valeur de Dice plus élevée de 8,69%, ce qui indique une précision légèrement supérieure pour cette métrique. Le tableau 23 présente des exemples de test.

**Tableau 23** : Echantillons des résultats de test

U-Net			FCN		
					
					
					
					

## **Conclusion**

En conclusion, les applications de traitement d'images basées sur l'apprentissage en profondeur, telles que les algorithmes U-Net et FCN, ont prouvé leur efficacité pour détecter avec précision et extraire les cabosses de cacao de leur environnement naturel. Cela ouvre la voie à la collecte de données permettant d'évaluer la maturité des cabosses de cacao, la présence de maladies ou encore la quantité de cacao récolté dans des zones spécifiques, facilitant ainsi une gestion plus efficace des cultures. Les résultats de cette recherche démontrent que l'utilisation de l'apprentissage en profondeur dans le traitement d'images représente une solution pratique et précise pour surveiller et collecter des données dans l'industrie cacaoyère.

Les perspectives futures de cette recherche incluent l'optimisation de la méthode de détection des cabosses de cacao pour des conditions de terrain et de culture variables. De plus, la technologie pourrait être étendue à d'autres cultures similaires où une détection précise des fruits est essentielle. Enfin, cette technologie pourrait être utilisée en combinaison avec des drones pour une surveillance à grande échelle des plantations, offrant des avantages considérables pour la gestion et la planification de la production agricole à l'échelle industrielle.

## **Chapitre 5 : Classification des fèves de cacao par couplage de méthodes**

*(“Application based on Hybrid CNN-SVM and PCA-SVM Approaches for Classification of Cocoa Beans, AK Jean, M Diarra, B Abou Bakary, G Pierre, AK Jérôme, IJACSA, 2022”)*

### **Introduction**

Dans cette étude, nous avons cherché à améliorer la précision de la classification des fèves de cacao obtenues à partir de la fermentation des grains recueillis des cabosses de cacao après la récolte. Pour atteindre cet objectif, nous avons proposé deux méthodes de classification hybrides : CNN-SVM et PCA-SVM, en utilisant également des algorithmes de classification standard tels que CNN et SVM. Le modèle hybride CNN-SVM utilise un réseau convolutif pour extraire les caractéristiques des images et le SVM pour effectuer l'opération de classification. L'utilisation du PCA-SVM permet de réduire la taille de l'image tout en conservant les principales caractéristiques, grâce à l'analyse par composante principale en utilisant toujours le classificateur SVM. Les noyaux de fonction de base radiale, linéaire et polynomial ont été utilisés avec divers paramètres de régulation pour le SVM. Pour améliorer la performance de la classification, nous avons utilisé différents optimiseurs pour le classifieur Softmax du CNN, tels que l'algorithme de la descente de gradient stochastique (SGD), Adam et RMSprop. Nous avons mesuré la performance de nos modèles avec plusieurs métriques telles que la précision, le Recall, le F1 score, le MSE et le MCC.

Les résultats ont montré que notre modèle hybride CNN-SVM est plus robuste et a obtenu le meilleur score avec une valeur de 98,32%. Le modèle PCA-SVM a également obtenu de bons résultats, avec un score de 97,65%, dépassant les algorithmes de classification standard CNN et SVM. Ces résultats ont confirmé l'efficacité de nos approches hybrides pour la classification des fèves de cacao.

### **5.1. Généralités**

La Côte d'Ivoire est le premier producteur mondial de cacao [126] et le cacao est une culture commerciale importante dans le monde. La culture de cacao permet d'obtenir des fèves issues des graines de cabosse mûres de la plante *Theobroma* [127]. Les fèves de cacao sont la principale matière première pour la fabrication du chocolat [128] et la première étape de ce processus est la fermentation. La fermentation est une étape indispensable dans le processus de transformation du cacao, elle a un impact sur la saveur, la couleur et l'arôme des produits à base de cacao [129]. Les fèves de cacao non fermentées n'ont pas toute la saveur du chocolat, mais la fermentation déclenche des modifications chimiques au sein de la fève de cacao qui



contribuent au développement de la saveur du chocolat [130]. Une fois la récolte effectuée, les agriculteurs ouvrent les cabosses de cacao, extraient les graines de cacao avec la pulpe et remplissent des boîtes ou des conteneurs en bois pour commencer la fermentation [131]. Utiliser des fèves de cacao séchées de qualité issu de la fermentation permet d'obtenir de meilleurs produits finis. Le processus de détection de la qualité des graines de cacao séchées est une tâche fastidieuse et nécessite une attention particulière d'où la nécessité de faire appel à la vision par ordinateur qui permettra à partir d'une image de spécifier la catégorie de celle-ci. Ces dernières années, la vision par ordinateur joue un rôle important dans la production agricole avec l'utilisation du machine Learning et plus précisément des réseaux de neurones convolutifs du deep Learning [132]. Nous pouvons noter ici les techniques populaires d'analyse des images dans l'apprentissage automatique tels que le Support vector machine (SVM), le Réseau Neural Artificiel (ANN), les réseaux de neurones convolutifs (CNN), les indices de végétation à différence normalisée (NDVI), les outils statistiques comme l'analyse de corrélation et de régression etc [133]. Il y a eu également plusieurs travaux ont été menés dans ce domaine et nous pouvons citer certains à savoir, Oliviera et al. ont utilisé des caractéristiques artisanales calculées à partir des fèves fournies par les outils d'analyse d'images puis le prédicteur des forêts de décision aléatoires a été utilisé pour classer les échantillons. Cette expérience a donné une précision de 92% [134] ; Adhitya et al. ont comparé dans leur travaux deux méthodes d'extraction en l'occurrence le GLCM et le CNN, et l'étude a montré que l'utilisation de l'extraction de caractéristiques de texture GLCM peut donner des résultats plus fiables que l'extraction de caractéristiques CNN pour la classification finale [135]. Kaghi et al. ont utilisé un CNN AlexNet préformé comme extracteur de caractéristiques génériques d'une image 2D dont les dimensions ont été réduites à l'aide de PCA + TSNE, et enfin classifié à l'aide d'un algorithme d'apprentissage automatique simple comme KNN, Naïves Bayes Classifier. Ces résultats pourraient égaler un classificateur Softmax de CNN [136]; Barbon et al. ont utilisé des méthodes basées sur le machine learning à savoir les approches J48, Naïve Bayes, K-NN, Random Forest, SVM, MLP et Fuzzy pour prédire la durée de stockage de la viande de porc et ces méthodes ont fourni les précisions qui varient de 78,26 à 94,41% [137]; Santos Pereira et al. proposent une étude qui prédit la maturation du fruit de la papaye à l'aide de l'imagerie numérique et de forêts aléatoires avec deux ensembles de données (validation croisée et ensemble de prédiction) qui sont utilisées pour les expériences. Ils ont obtenu une performance de classification de 94,3% sur l'ensemble de validation croisée [138]. A. et Renjith fournissent une architecture spéciale pour identifier les caractéristiques des différentes classes de fruits Durian, le modèle de traitement d'image permet de diviser la

classification en deux parties : l'extraction de caractéristiques et la classification du fruit utilisé. L'utilisation de la détection des bords et l'extraction des couleurs permettent une extraction correcte des caractéristiques du durian, la performance est mesurée en utilisant des techniques d'apprentissage automatique non destructif telles que SVM, GNB, Random Forest. Les résultats obtenus fournissent la meilleure précision de 89.3% en utilisant la technique SVM et 84,3% en utilisant Random Forest [139]; Harel et al. proposent des algorithmes de classification de la maturité. Leurs algorithmes ont été appliqués à la classification de la maturité des poivrons. La classification de la maturité a atteint une précision de 98,2% et 97,3% pour la classification en deux classes, entre les classes matures et immatures de poivrons rouges et jaunes, respectivement, et une précision de 89,5% et 97,3% pour la classification en quatre classes de maturité. L'algorithme de forêt aléatoire s'est montré très robuste [140].

Notre objectif est de développer une méthode efficace pour classer les fèves de cacao séchées. Pour cela, nous avons exploré différentes approches, notamment l'utilisation de réseaux de neurones convolutifs (CNN), de machines à vecteurs de support (SVM), d'une approche hybride CNN-SVM, ainsi que de l'analyse par composantes principales avec SVM (PCA-SVM). La méthode hybride combine les avantages des deux approches en commençant par extraire automatiquement les caractéristiques de l'image à l'aide du CNN, puis en effectuant la classification à l'aide du SVM. D'autre part, le PCA-SVM utilise une technique de réduction de dimensionnalité pour réduire la taille de l'image tout en préservant ses principales caractéristiques, avant de procéder à la classification à l'aide du SVM.

Nous avons appliqué ces méthodes pour détecter la catégorie des fèves de cacao séchées et avons comparé leurs performances pour identifier la méthode la plus performante.


## **5.2. Jeu de données**

Le jeu de données utilisés pour cette étude a été développé au chapitre 3 dans la section 3.1.2. Ces échantillons de fèves de cacao ont été triés avec soin en fonction de leur qualité, leur taille et leur forme. Cette classification minutieuse a permis de sélectionner des échantillons homogènes pour l'étude, assurant ainsi la représentativité de l'échantillon. Chaque catégorie de fève de cacao sélectionnée a ensuite été photographiée sous différents angles et conditions d'éclairage afin de garantir une capture complète de leurs caractéristiques physiques et morphologiques. Les catégories des fèves sont représentées comme suit :

- (A) Fèves de la catégorie 1 : il s'agit des fèves de cacao fermentées et séchées de qualité supérieur.

- (B) Fèves de la catégorie 2 : il s'agit des fèves de cacao fermentées et séchées de qualité intermédiaire.
- (C) Fèves de la catégorie 3 : il s'agit des fèves de cacao non fermenté et séchées.

La figure 56 présente les images des fèves séchées.



**Figure 56 :** Images des trois catégories de fèves de cacao

Notre prochaine étape consistera à prétraiter les données que nous avons collectées afin d'extraire les graines de chaque image.

Le prétraitement des données est une étape fondamentale et cruciale dans tout processus d'analyse d'images, car il vise à nettoyer et normaliser les données brutes afin de les rendre plus facilement exploitables et informatives. Dans le contexte spécifique de notre étude sur les fèves de cacao, ce prétraitement revêt une importance particulière pour garantir la qualité et la précision des résultats obtenus lors de la détection des fèves.

La première technique utilisée est la binarisation de l'image. Cette méthode permet de convertir une image en niveaux de gris en une image binaire, où les pixels sont représentés soit par des valeurs 0 (noir) ou 1 (blanc). Elle est essentielle pour simplifier la détection des fèves, car elle réduit le bruit et les détails inutiles, mettant en évidence les zones d'intérêt représentant les fèves de cacao. Nous avons choisi cette méthode en raison de son efficacité pour séparer clairement les fèves du reste de l'image et ainsi faciliter leur identification ultérieure.

Ensuite, nous passons à la cartographie des composants connectés avec leurs propriétés régionales correspondantes. Cette étape est cruciale pour regrouper les pixels

appartenant à chaque fève en un seul objet détecté. En analysant les composants connectés, nous pouvons distinguer et isoler individuellement chaque fève de cacao, ce qui est essentiel pour effectuer des analyses spécifiques sur chacune d'entre elles. Cette méthode permet une détection précise et détaillée des fèves, tout en facilitant leur caractérisation individuelle.

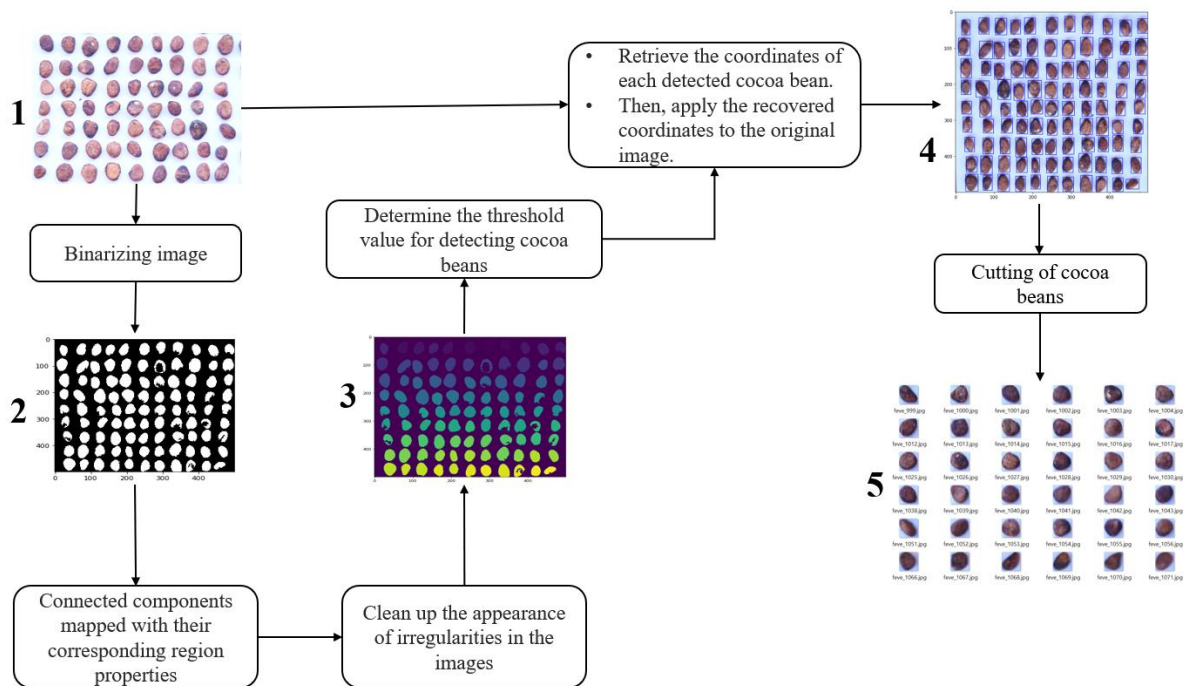
Un autre aspect important du prétraitement concerne l'élimination des irrégularités de l'apparence des images. Cela peut inclure des opérations telles que la réduction du bruit, l'égalisation de l'histogramme ou la correction des défauts d'éclairage. Ces mesures sont importantes car elles permettent d'améliorer la qualité des images traitées, réduisant ainsi les erreurs de détection potentielles causées par des artefacts indésirables. Nous justifions ces choix pour assurer la fiabilité des résultats et garantir que notre algorithme de détection repose sur des images nettes et uniformes.

Une étape importante dans le prétraitement des images de fèves de cacao consiste à déterminer la valeur seuil appropriée pour détecter les fèves de manière efficace. La valeur seuil est essentielle pour convertir l'image binaire en une image avec des pixels marqués comme fèves et d'autres comme arrière-plan. Trouver la valeur seuil optimale peut être un défi, car elle dépend des propriétés spécifiques des images, telles que l'éclairage, le contraste et la texture. Il est important d'ajuster correctement la valeur seuil pour éviter la sous-détection ou la sur-détection des fèves de cacao dans l'image.

Enfin, nous récupérons les coordonnées de chaque fève de cacao détectée. Cette étape nous permet de localiser précisément chaque fève dans l'image et de recueillir des informations spatiales importantes pour les analyses ultérieures.

Les techniques de prétraitement choisies sont essentielles pour garantir la qualité et la fiabilité de notre processus de détection des fèves de cacao. La binarisation, la cartographie des composants connectés, l'élimination des irrégularités de l'apparence des images, la détermination de la valeur seuil et la récupération des coordonnées des fèves détectées sont toutes des étapes fondamentales pour rendre les données brutes plus facilement analysables et pour obtenir des résultats précis et informatifs lors de notre étude sur les fèves de cacao.

Ce processus nous permettra d'obtenir des données plus précises et de réduire les erreurs potentielles lors de l'analyse ultérieure. La figure 57 présente l'étape énumérée.



**Figure 57** : Pré-traitement et extraction des fèves de cacao

Une fois l'étape de prétraitement des données effectuée, nous avons obtenu un jeu de données composé de 3470 images de fèves de cacao. Parmi celles-ci, 917 images appartiennent à la catégorie 1, 1675 images à la catégorie 2 et 878 images à la catégorie 3.

Pour maximiser l'efficacité de notre modèle, nous avons ensuite divisé cet ensemble de données en trois parties distinctes : 60% ont été utilisées pour l'entraînement du modèle, 20% pour tester sa performance et 20% pour valider ses prédictions. Cette stratégie nous permettra de vérifier l'exactitude de notre modèle et de nous assurer qu'il peut généraliser ses prédictions à de nouvelles données.

### 5.3. Extraction de caractéristique

Dans notre étude, nous avons utilisé deux méthodes d'extraction de caractéristiques : le CNN et le PCA. Pour le CNN, nous avons utilisé un modèle qui se compose de deux couches convolutives, chacune ayant 32 filtres et un noyau de taille 3x3 avec une fonction d'activation Relu. L'utilisation du CNN et du PCA dans notre étude sur les fèves de cacao permet de tirer parti de leurs avantages spécifiques, obtenir des caractéristiques distinctes et mener des expérimentations pour évaluer leur contribution respective. Cette approche nous offre une grande flexibilité dans l'analyse des données et nous permet de mieux comprendre les caractéristiques importantes des images de fèves de cacao pour une analyse plus approfondie et précise.

L'objectif de la couche convolutive est de générer une carte de caractéristiques en appliquant un filtre qui analyse l'image dans son ensemble. Chacune des couches convolutives est suivie d'une couche maxpooling de noyau 2x2, qui est une technique de sous-échantillonnage. Le sous-échantillonnage de la couche maxpooling consiste à extraire la valeur la plus significative de chaque motif de la carte de caractéristiques. Cette couche a pour but de réduire le nombre de paramètres et de calculs dans le réseau, ce qui permet d'améliorer les performances du réseau et d'éviter le sur-apprentissage. Enfin une couche Flatten qui permet d'aplatir la carte de caractéristique et de réduire sa dimension. Le tableau 24 donne la description du CNN.

**Tableau 24** : Description de l'architecture du CNN

Layer	Output Shape	Parameter Size
Convolutional 1	(58, 58, 32)	896
Pooling	(29, 29, 32)	0
Convolutional 2	(27, 27, 32)	9248
Pooling	(13, 13, 32)	0
Flattening	5408	0
Total parameter		703 012
Trainable parameter		703 012
Non-Trainable parameter		0

L'analyse en composantes principales (PCA) est une technique statistique couramment utilisée dans diverses applications telles que la réduction de dimensionnalité, la compression de données, l'extraction de caractéristiques et la visualisation de données. En particulier, PCA permet de transformer un ensemble de variables corrélées  $X$  en un plus petit nombre  $y$ , avec  $y < X$  de variables non corrélées appelées composantes principales. Cette transformation permet de conserver autant que possible la variabilité des données originales.

L'application la plus courante de PCA est la réduction de dimensionnalité, où les données peuvent être très volumineuses et contiennent de nombreuses variables corrélées. La réduction de dimensionnalité permet de simplifier la tâche d'analyse des données tout en maintenant une grande partie de la variation de données. Cela peut être utile dans de nombreuses applications, telles que l'analyse de données de surveillance ou l'analyse de données de laboratoire [141].

## 5.4. Classification

La classification est une opération couramment utilisée en apprentissage automatique. Elle permet d'attribuer une étiquette de classe à chaque exemple d'un ensemble de données.

Cette tâche est souvent réalisée à l'aide d'algorithmes d'apprentissage automatique qui apprennent à distinguer les différentes classes d'un problème donné.

Il existe de nombreux types de tâches de classification, chacun nécessitant des approches de modélisation spécialisées. La classification binaire permet de distinguer entre deux classes, tandis que la classification multi classe peut distinguer entre plusieurs classes. La classification hiérarchique permet de classer les données dans une structure arborescente, tandis que la classification de séquence permet de classer les séquences de données.

Dans notre étude, nous avons utilisé deux types de classifieurs pour notre tâche de classification : le classifieur Softmax et le classifieur SVM [142]. Le classifieur Softmax est souvent utilisé pour la classification multi classe, tandis que le classifieur SVM est efficace pour la classification binaire et la classification de séquence. Ces deux approches de modélisation ont été choisies en fonction de la nature de notre ensemble de données et de notre tâche de classification spécifique.

#### **5.4.1. Classifieur Softmax**

Le classificateur Softmax est un modèle mathématique qui permet de classer des données en leur assignant une étiquette de classe. Il est considéré comme une généralisation de la forme binaire de la régression logistique, une technique d'apprentissage automatique couramment utilisée pour la classification binaire.

Dans le domaine de la vision par ordinateur, le classificateur Softmax est souvent utilisé pour classer des vecteurs de caractéristiques extraits à partir d'images. Ces vecteurs représentent des informations importantes sur l'image, telles que les formes, les couleurs, les textures, etc.

Le fonctionnement du classificateur Softmax consiste à définir une fonction de mise en correspondance  $F$  qui prend en entrée un ensemble de données  $x$  et qui fait correspondre chaque entrée à une étiquette de classe de sortie. Cette fonction utilise une matrice de poids  $W$  qui est calculée à partir des données d'entraînement.

Lorsque de nouvelles données sont présentées au classificateur Softmax, la fonction  $F$  calcule un produit scalaire entre les données d'entrée  $x$  et la matrice de poids  $W$ . Ce produit scalaire donne une mesure de la similitude entre les données d'entrée et chaque classe de sortie. La fonction Softmax est ensuite appliquée pour convertir ces mesures en probabilités de chaque classe de sortie [143].

$$F(x_i, W) = W \cdot x_i \quad (5-17)$$

La perte de charnière est une fonction de coût utilisée dans l'apprentissage automatique pour les tâches de classification multi-classes. Elle mesure la différence entre les prédictions du modèle et les véritables étiquettes de classe des exemples d'entraînement. Plus précisément, la perte de charnière calcule des probabilités logarithmiques non normalisées pour chaque étiquette de classe. Ces probabilités sont obtenues en évaluant la sortie du modèle pour chaque classe et en prenant le logarithme des résultats obtenus. Ces probabilités logarithmiques sont ensuite utilisées pour calculer la perte de charnière en utilisant une formule basée sur l'entropie croisée. L'entropie croisée est une mesure de la divergence entre deux distributions de probabilité, dans ce cas, la distribution de probabilité produite par le modèle et la distribution de probabilité des étiquettes de classe réelles. Ainsi, la perte de charnière est équivalente à une perte d'entropie croisée pondérée par les probabilités logarithmiques non normalisées pour chaque étiquette de classe. Cette perte est utilisée pour entraîner le modèle à améliorer ses prédictions et à mieux s'adapter aux données d'entraînement.

$$Loss = \max(0, 1 - y \cdot f(x)) \quad (5-18)$$

La fonction de score de Softmax est une méthode couramment utilisée pour effectuer une classification multi-classes en machine Learning. Elle prend en entrée le score final d'un exemple donné, qui est calculé à partir des caractéristiques de l'exemple et des poids du modèle. La fonction de score de Softmax utilise une transformation exponentielle pour normaliser les scores et les convertir en probabilités. Cette transformation prend en compte le score de chaque classe et l'ajuste en fonction du score total pour toutes les classes, afin que la somme des probabilités pour toutes les classes soit égale à 1.

Plus précisément, la fonction de score de Softmax calcule la probabilité d'appartenance à chaque classe en prenant l'exponentielle du score pour cette classe, et en divisant le résultat par la somme des exponentielles de tous les scores de classe. Cela donne une probabilité normalisée pour chaque classe, qui représente la confiance du modèle en cette classe pour l'exemple donné [143]. L'équation mathématique de la fonction de score de Softmax est la suivante :

$$f_j(z) = \frac{e^{z_j}}{\sum_{k=1}^n e^{z_k}} \quad (5-19)$$

La fonction de perte de Softmax est utilisée en apprentissage automatique pour évaluer la performance d'un modèle de classification. Elle peut être considérée comme une mesure de



l'entropie de deux probabilités. Cette notion est exprimée mathématiquement par l'équation suivante :

$$H(p, q) = - \sum_{i=1}^n p_i \log(q_i) \quad (5-20)$$

En apprentissage automatique, il est fréquent d'utiliser des algorithmes d'optimisation pour régler les paramètres du modèle et réduire la fonction de perte. Il existe plusieurs types d'algorithmes d'optimisation, chacun présentant ses avantages et ses inconvénients particuliers. Parmi les trois algorithmes les plus répandus, on peut citer le SGD, Adam et RMSprop. Ce sujet a été abordé dans la section 1.3 du chapitre 1.

#### 5.4.2. Classifier SVM

Ce sujet a été abordé dans la section 2.3.4 du chapitre 2. Nous utilisons dans notre étude les noyaux du SVM suivants :


- le noyau linéaire ;
- le noyau polynomial ;
- le noyau RBF (Radial Basis Function).

### 5.5. Méthodologie de l'étude

La méthodologie de notre étude est décomposée en trois étapes principales : le prétraitement, l'extraction de caractéristiques et la classification.

- **la première étape**, qui a été présentée dans la section 5.2, consiste à préparer les données brutes en effectuant des opérations telles que le nettoyage, la normalisation ou la transformation des données. Cette étape permet d'obtenir des données plus cohérentes et exploitables pour la suite de l'analyse ;
- **la deuxième étape**, qui a été présentée dans la section 5.3, l'extraction de caractéristiques, est réalisée afin de mettre en évidence les informations les plus pertinentes dans les données prétraitées. Elle consiste à identifier les caractéristiques importantes pour la tâche de classification en utilisant des techniques telles que l'analyse en composantes principales ou les réseaux de neurones ;
- **enfin, la troisième étape**, qui a été présentée dans la section 5.4, consiste à classer les données prétraitées et caractérisées en utilisant des algorithmes de classification tels que Softmax et SVM. Cette étape permet de prédire des classes ou des catégories pour les nouvelles données qui n'ont pas été utilisées pour entraîner le modèle.

La figure 59 présente le schéma général de l'architecture de cette étude.



**Figure 58** : Architecture générale de la classification des fèves de cacao

## 5.6. Résultats expérimentaux

### 5.6.1. Cas du CNN et Softmax

En considérant les performances de trois optimiseurs différents (SGD, Adam et RMSprop) appliqués à un CNN avec la fonction Softmax, le tableau 13 ci-dessous présente les résultats obtenus en termes de : exactitude, précision, perte, score F1, rappel, coefficient de corrélation Matthews et erreur quadratique moyenne :

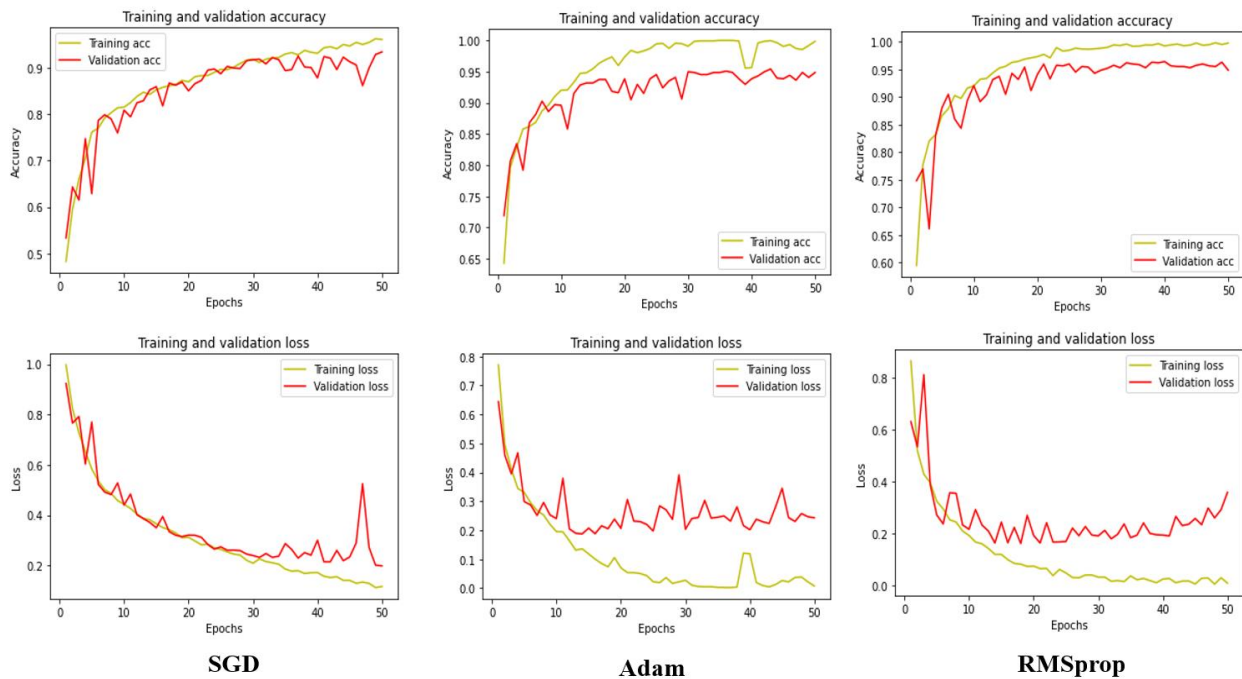
**Tableau 25** : Performance générale du classificateur Softmax

Optimizer	Accuracy	Loss	Precision	F1 score	Recall	MCC	MSE
SGD	92,95	17,93	93,37	92,95	92,95	89,2	3,41
Adam	95,64	17,18	95,65	95,64	95,63	93,18	2,37
RMSprop	94,63	36,99	94,83	94,62	94,63	91,73	3,18

Le tableau 25 fournit les résultats de performance du classificateur softmax pour trois optimiseurs différents, SGD, Adam et RMSprop.

Le premier point à noter est que les trois optimiseurs ont des performances similaires en termes d'exactitude, avec un score qui varie de 92,95 à 95,64%. Cependant, Adam est clairement le meilleur en termes de précision, avec un score de 95,65%.

Concernant la fonction de perte, on constate que Adam a la perte la plus faible avec 17,18, tandis que RMSprop a la perte la plus élevée avec 36,99. Cela indique que l'optimiseur Adam a réussi à minimiser l'erreur de prédiction de manière efficace et a obtenu des résultats de prédiction plus précis. La figure 59 présente les courbes de perte et d'exactitude de chaque optimiseur.



**Figure 59 :** Illustration des courbes Loss et Accuracy


La précision est une mesure importante pour les modèles de classification et Adam est le meilleur en termes de précision, avec un score de 95,65%. Les autres optimiseurs ont également des performances de précision décentes, avec des scores compris entre 93,37% et 94,83%.

Le score F1 est une mesure combinée de la précision et du rappel, et Adam a le meilleur score F1, avec un score de 95,64%. SGD et RMSprop ont également des scores F1 décent, mais Adam a la performance la plus élevée sur cette métrique.

En ce qui concerne le rappel, Adam est le meilleur, avec un score de 95,63%. Les autres optimiseurs ont également des performances de rappel décentes, avec des scores compris entre 92,95% et 94,63%.

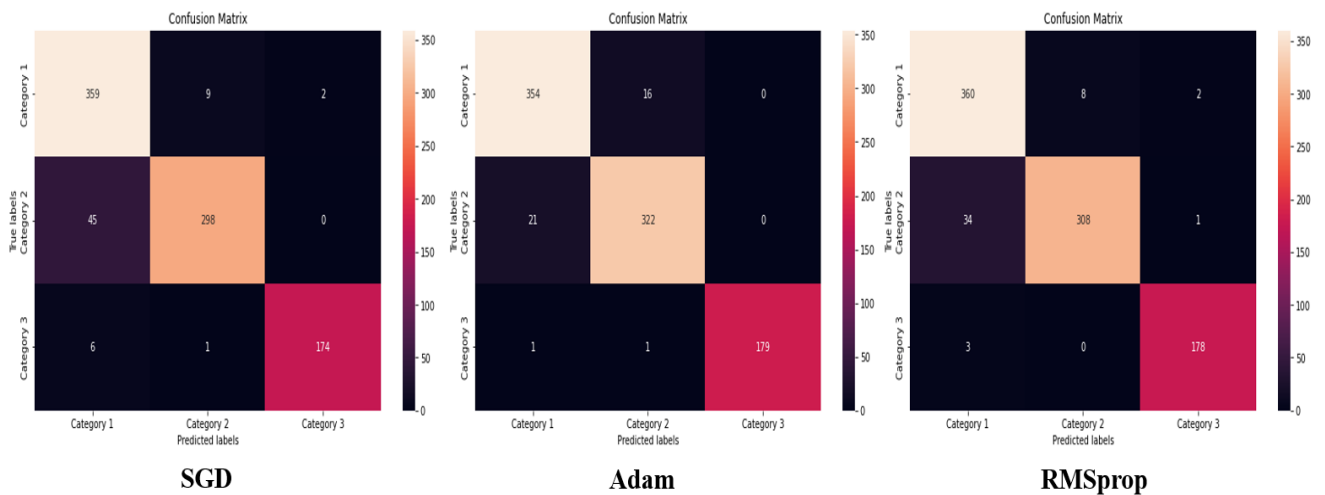
Le coefficient de corrélation de Matthews est une mesure qui reflète la qualité de la classification. Sur cette métrique, Adam a obtenu un score de 93,18%, il s'agit de la valeur la plus élevée parmi les trois optimiseurs. SGD est également à un score de 89,2% sur cette métrique, tandis que RMSprop a un score de 91,73%.

Enfin, concernant l'erreur quadratique moyenne, Adam a obtenu la valeur la plus basse avec 2,37 et indique que les prédictions d'Adam sont plus proches des valeurs réelles que celles des autres optimiseurs. La figure 60 fait l'histogramme des performances des optimiseurs.



**Figure 61 :** Histogramme des performances des optimiseurs

La matrice de confusion de chaque optimiseur est présentée sur la figure 61.



**Figure 60 :** Matrice de confusion des optimiseurs de Softmax

### 5.6.2. Cas du SVM

**Tableau 26 :** Performances générales du SVM

Models	Accuracy	Precision	F1 score	Recall	MCC	MSE
SVM (rbf ; C=1)	93,96	94,08	93,94	93,95	90,65	6,37
SVM (rbf ; C=100)	97,32	97,33	97,31	97,31	95,82	3,35
SVM (linear ; C=1)	93,4	93,55	93,38	93,4	89,79	7,94
SVM (linear ; C=100)	91,39	91,52	91,36	91,38	86,64	9,95
SVM (poly ; C=1)	95,75	95,82	95,74	95,74	93,41	5,25
SVM (poly ; C=100)	95,97	96,02	95,97	95,97	93,73	5,03


Le tableau 27 montre les performances générales du SVM (Support Vector Machine) pour différents types de noyaux (rbf, linear, et poly) et différents paramètres de régularisation (C=1 et C=100).

Tout d'abord, il est important de noter que l'Accuracy (exactitude) est élevée pour tous les modèles, avec des valeurs allant de 91,39% à 97,32%. Cela signifie que les modèles sont capables de classifier les données avec une grande précision.

Ensuite, en regardant les autres métriques, nous observons que les performances varient en fonction du type de noyau et de la valeur de C. En général, nous pouvons remarquer que les modèles avec le noyau rbf ont de meilleures performances que les modèles avec le noyau linéaire et poly, en termes de précision, F1-score, recall et MCC. Cela peut être dû au fait que le noyau rbf est plus flexible et peut mieux s'adapter aux données.

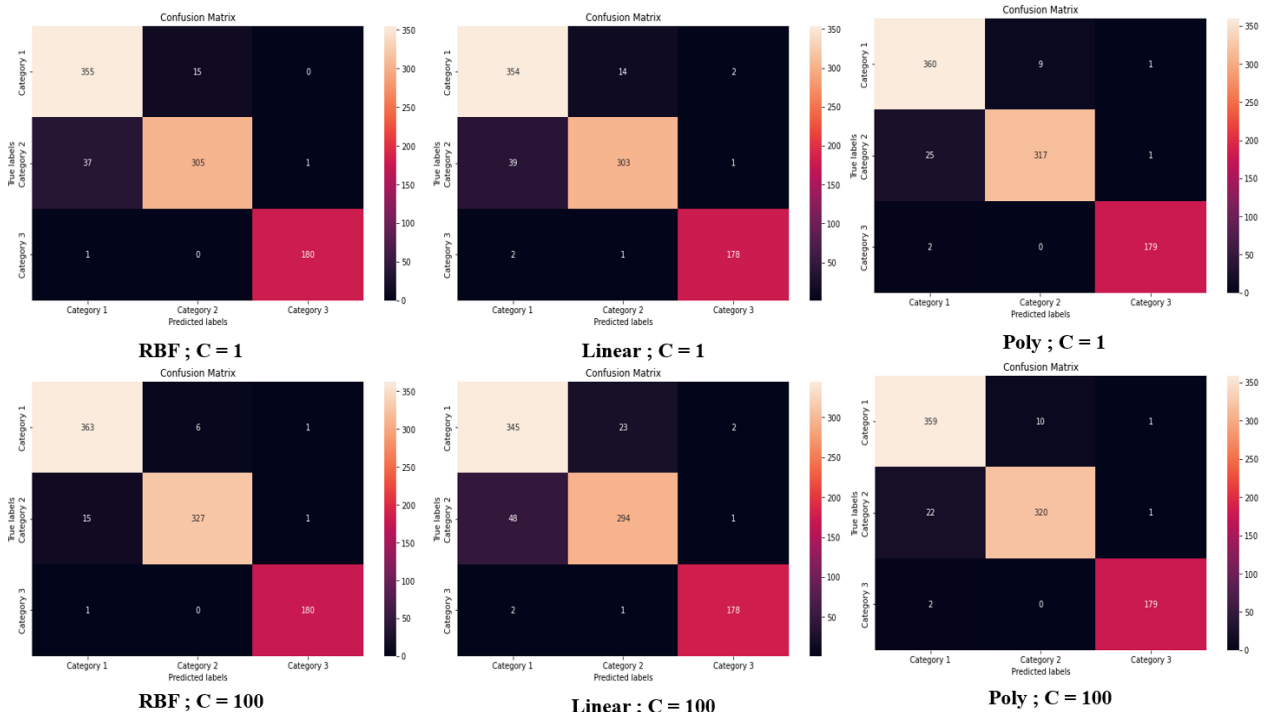
Concernant le paramètre de régularisation C, nous observons que les modèles avec C=100 ont de meilleures performances que les modèles avec C=1. Nous constatons que la régularisation C permet de contrôler la complexité du modèle, et une valeur plus élevée de C permet de donner plus de poids à la classification correcte des données d'entraînement.

Enfin, on peut remarquer que le modèle avec le noyau rbf et C=100 a les meilleures performances globales, avec une Accuracy de 97,32%, une précision de 97,33%, un F1-score de 97,31%, un Recall de 97,31% et un MCC de 95,82%. Le choix du noyau et du paramètre de régularisation peut avoir un impact significatif sur les performances du modèle SVM, et il est important de les ajuster de manière appropriée pour obtenir les meilleures performances possibles. La figure 62 présente l'histogramme des performances du SVM.



**Figure 62:** Histogramme des performances du SVM

La matrice de confusion de chaque paramètre du modèle SVM est présentée sur la figure 63.



**Figure 63 : Matrice de confusion du SVM**

### 5.6.3. Cas du CNN et SVM


**Tableau 27 : Performances générales du CNN avec SVM**

Models	Accuracy	Precision	F1 score	Recall	MCC	MSE
CNN - SVM (rbf ; C=1)	95,08	95,29	95,06	95,07	92,44	4,92
CNN - SVM (rbf ; C=100)	98,32	98,34	98,32	98,32	97,39	1,67
CNN - SVM (linear ; C=1)	95,86	95,95	95,85	95,86	93,59	4,47
CNN - SVM (linear ; C=100)	95,86	95,95	95,85	95,86	93,59	4,47
CNN - SVM (poly ; C=1)	95,41	95,61	95,4	95,41	92,96	5,25
CNN - SVM (poly ; C=100)	98,1	98,11	98,09	98,09	97,04	1,9

Le tableau 27 présente les résultats de la classification en utilisant le CNN combiné avec le SVM pour différents noyaux SVM (rbf, linéaire, poly) et différents paramètres de régularisation (C=1, C=100). Les résultats sont évalués en utilisant plusieurs métriques telles que l'exactitude (Accuracy), la précision (Precision), le score F1, le rappel (Recall), le coefficient de corrélation de Matthews (MCC) et l'erreur quadratique moyenne (MSE).

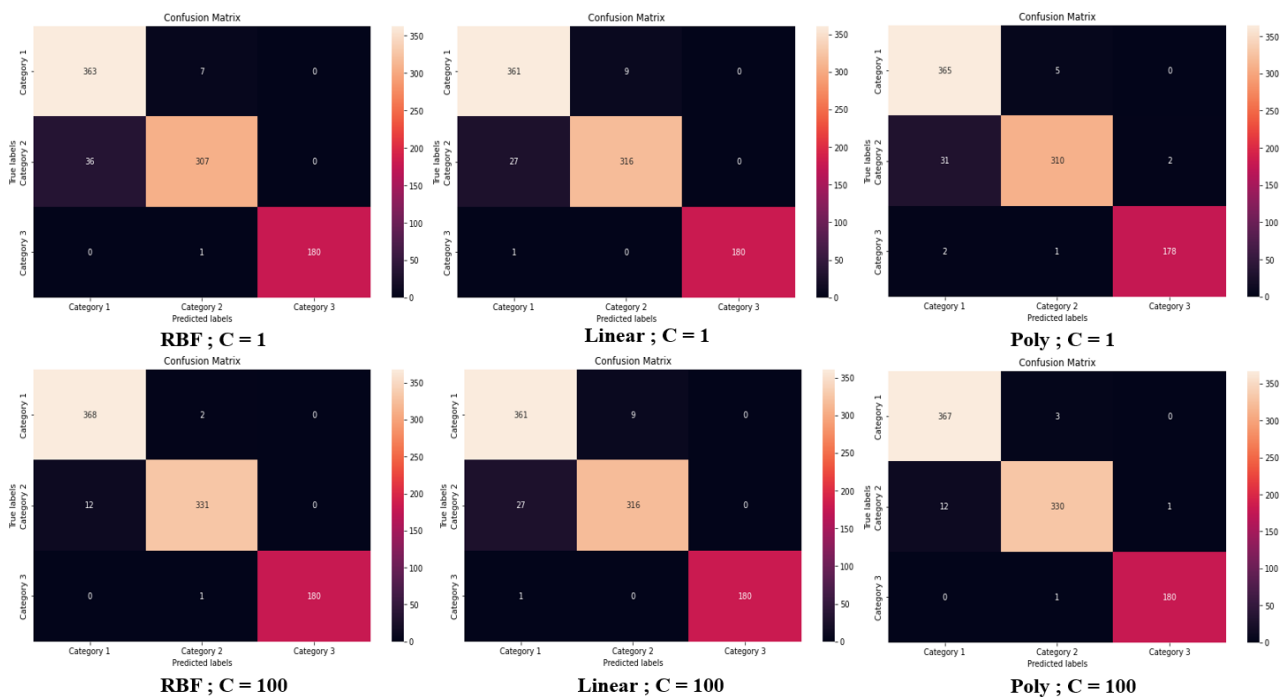
Les résultats montrent que le CNN combiné avec le SVM donne des performances élevées pour la classification des images en utilisant différentes valeurs de paramètres. En général, les performances sont améliorées avec des paramètres de régularisation plus élevés (C=100). Le noyau rbf et le noyau poly donnent des résultats similaires, avec des performances plus élevées pour le noyau rbf avec un paramètre de régularisation plus élevé (C=100). Le noyau linéaire donne également de bonnes performances, mais un peu moins élevées que les autres noyaux pour la plupart des métriques.

Les performances élevées de la classification peuvent être attribuées aux avantages combinés du CNN et du SVM. Le CNN est capable d'extraire des caractéristiques discriminantes à partir d'images, tandis que le SVM peut utiliser ces caractéristiques pour effectuer une classification précise. En combinant les deux approches, il est possible d'obtenir des performances de classification très élevées. La figure 65 fait l'historgramme des performances des optimiseurs.



**Figure 65:** Histogramme des performances des paramètres avec CNN - SVM

La matrice de confusion de chaque paramètre du modèle hybride CNN - SVM est présentée sur la figure 64.



**Figure 64 :** Matrice de confusion des différents paramètres du modèle hybride CNN - SVM

#### 5.6.4. Cas du PCA et SVM

**Tableau 28** : Performances générales du PCA avec SVM

Models	Accuracy	Precision	F1 score	Recall	MCC	MSE
PCA - SVM (rbf ; C=1)	95,41	95,49	95,4	95,41	92,89	5,21
PCA - SVM (rbf ; C=100)	97,65	97,67	97,64	97,65	96,34	3,02
PCA - SVM (linear ; C=1)	93,4	93,55	93,38	93,4	89,79	7,94
PCA - SVM (linear ; C=100)	91,39	91,52	91,36	91,38	86,64	9,95
PCA - SVM (poly ; C=1)	92,73	93,13	92,74	92,72	88,81	10,96
PCA - SVM (poly ; C=100)	97,2	97,2	97,19	97,2	95,64	3,13

Le tableau 29 présente les performances générales du PCA avec SVM pour différents types de noyaux (rbf, linéaire et polynomiale) et différents paramètres de régularisation C. Les performances sont évaluées à l'aide de différentes métriques, notamment l'exactitude (accuracy), la précision (precision), le score F1 (F1 score), le rappel (recall), le coefficient de corrélation de Matthews (MCC) et l'erreur quadratique moyenne (MSE).

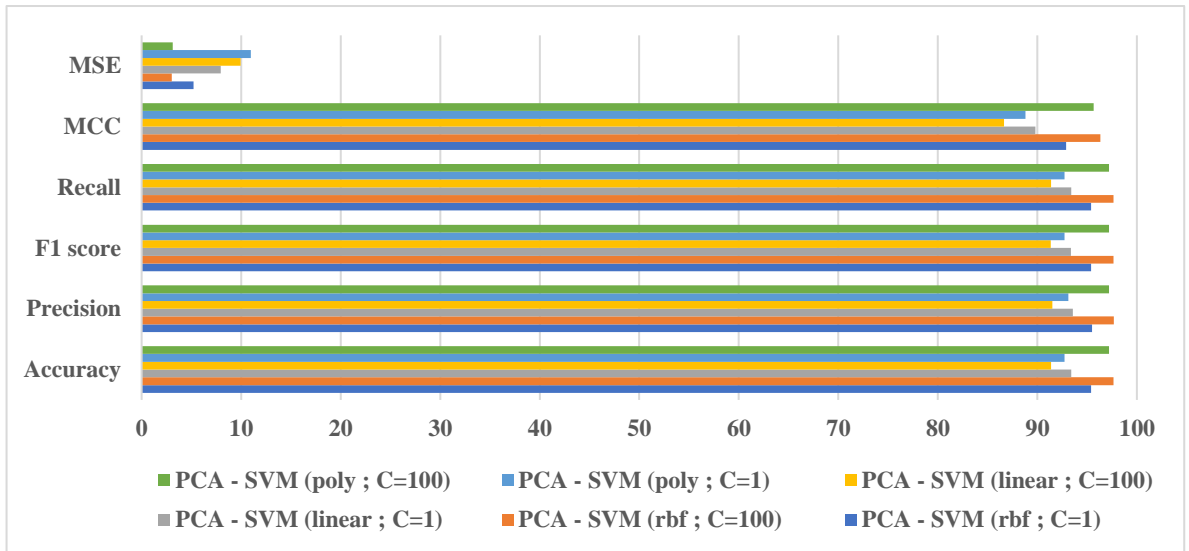
En général, on peut observer que l'exactitude, la précision, le score F1, le rappel et le MCC sont tous assez élevés pour les différents types de noyaux et les différents paramètres de régularisation. Cependant, nous pouvons observer que les performances varient en fonction du type de noyau et du paramètre de régularisation.

En particulier, pour le noyau rbf, nous observons que l'exactitude, la précision, le score F1, le rappel et le MCC sont tous très élevés lorsque le paramètre de régularisation C est égal à 100, avec une exactitude de 97,65 % et signifie que le noyau rbf avec un paramètre de régularisation élevé peut être très efficace pour classer les données.

En revanche, pour les noyaux linéaire et polynomial, nous observons que les performances sont généralement moins élevées que celle du noyau rbf avec une régulation de 100. Pour le noyau linéaire, on observe que l'exactitude est la plus basse de tous les types de noyaux et de tous les paramètres de régularisation, avec une exactitude de seulement 93,4 %. Pour le noyau polynomial, on peut observer que l'exactitude est plus élevée que pour le noyau linéaire, mais moins élevée que pour le noyau rbf, avec une exactitude maximale de 97,2 % pour le paramètre de régularisation C égal à 100.


Enfin, l'erreur quadratique moyenne est généralement assez faible pour tous les types de noyaux et tous les paramètres de régularisation, et suppose que le modèle est assez précis dans sa prédiction des classes. La figure 66 fait l'historique des performances du modèle PCA - SVM.





**Figure 66 :** Histogramme des performances des paramètres avec PCA - SVM

La matrice de confusion de chaque paramètre du modèle hybride PCA - SVM est présentée sur la figure 67.



**Figure 67 :** Matrice de confusion des différents paramètres du modèle PCA - SVM

### 5.6.5. Comparaison des différentes méthodes

Dans le cadre de notre étude, nous procéderons à une comparaison des performances de plusieurs méthodes de classification : le CNN, le CNN-SVM, le SVM et le PCA-SVM. Nous présenterons les résultats de cette comparaison dans un tableau et à l'aide d'un histogramme qui nous permettra de visualiser facilement les différences de performances entre les différentes méthodes.

**Tableau 29** : Comparaison des performances des méthodes


Models	Accuracy
CNN - SVM (rbf ; C=100)	98,32
PCA - SVM (rbf ; C=100)	97,65
SVM (rbf ; C=100)	97,32
Softmax with Adam optimizer	95,64

Le tableau 29 présente une comparaison des performances de plusieurs méthodes de classification pour résoudre un problème spécifique. Les résultats montrent que le CNN-SVM obtient le meilleur résultat en termes d'exactitude avec un score de 98,32%, suivi de près par le PCA-SVM avec un score de 97,65% et le SVM classique avec un score de 97,32%. Ces résultats suggèrent que la combinaison de CNN et SVM peut fournir une performance de classification améliorée en exploitant les avantages de chaque méthode.

Cependant, il est important de noter que ces résultats dépendent du contexte et des paramètres spécifiques de chaque méthode, et ils peuvent ne pas être généralisables à d'autres problèmes ou ensembles de données. En outre, l'utilisation de l'optimiseur Adam avec la méthode Softmax ne donne pas les meilleurs résultats en termes d'exactitude.

La comparaison entre les résultats de la méthode CNN-SVM et de la méthode PCA-SVM est intéressante car elle montre que les deux méthodes ont des performances similaires en termes de précision. Cependant, la méthode PCA-SVM est plus simple que la méthode CNN-SVM car elle ne nécessite pas d'apprentissage en profondeur ni de réglage de nombreux paramètres. En revanche, la méthode CNN-SVM peut être plus puissante pour capturer des caractéristiques plus complexes des images.

Dans l'ensemble, ce tableau souligne l'importance de choisir la bonne méthode de classification en fonction du contexte et des caractéristiques de l'ensemble de données, en prenant en compte les avantages et les limites de chaque méthode. Il est également important de bien sélectionner les paramètres pour chaque méthode afin d'optimiser les performances. La figure 69 représente l'historgramme des performances des méthodes.



**Figure 68:** Histogramme des performances des méthodes de notre étude

### 5.6.6. Comparaison avec d'autres travaux

Les résultats obtenus à partir de nos expériences fournissent une preuve convaincante de notre approche, démontrant une nette amélioration par rapport à l'état de l'art. Les résultats sont présentés dans le Tableau 30, qui permet une comparaison directe avec les approches précédentes. En outre, un histogramme est également fourni pour visualiser les résultats et mettre en évidence les gains significatifs que nous avons réalisés grâce à notre approche.


**Tableau 30 :** Comparaison avec d'autres travaux

Models	Accuracy
Oliviera et al. [134]	92
CNN - SVM (rbf ; C=100)	98,32
PCA - SVM (rbf ; C=100)	97,65
SVM (rbf ; C=100)	97,32
Softmax with Adam optimizer	95,64

Le tableau 30 compare les résultats de différentes méthodes de classification de notre étude à celle utilisé dans les travaux de Oliviera et al. Les résultats montrent que la méthode CNN-SVM avec un noyau gaussien (rbf) et un paramètre de régularisation C=100 a obtenu la précision la plus élevée avec un score de 98,32%. Cette méthode utilise un CNN pour extraire des caractéristiques à partir des images, suivi d'un classificateur SVM pour classer les images.

Les autres méthodes comparées dans le tableau sont aux : PCA-SVM, SVM, le Softmax avec l'optimiseur Adam. Ces méthodes ont également obtenu des scores élevés, avec des précisions respectives de 97,65%, 97,32%, et 95,64%. Tous ces valeurs sont supérieures aux résultats obtenus dans les études de la littérature.

Cependant, il est important de noter que les données et les conditions expérimentales sont différentes entre les études et peuvent affecter les résultats et les comparaisons entre des études. La figure 69 représente l'historgramme des performances des méthodes et de la littérature.



**Figure 69** : Histogramme des performances des méthodes de notre étude et de la littérature

## Conclusion

Le secteur de la production de cacao est un domaine en constante évolution, et il est crucial de garantir une qualité élevée des produits pour répondre aux normes de l'industrie. Cela nécessite des méthodes automatisées pour évaluer la qualité des fèves de cacao, car il est difficile pour les humains de faire une évaluation précise de manière constante.

Dans cette étude, nous avons exploré l'utilisation de techniques de machine Learning pour classer les fèves de cacao en fonction de leur qualité. Nous avons utilisé une combinaison de CNN pour extraire les caractéristiques et du SVM pour la classification. Les résultats ont montré que cette méthode hybride a obtenu le meilleur score de toutes les méthodes utilisées, y compris celles de la littérature.

En outre, nous avons également utilisé l'analyse par composante principale pour réduire la taille des données, tout en conservant les caractéristiques les plus importantes. Cela a permis d'obtenir des résultats satisfaisants tout en minimisant le temps de calcul des classifieurs.

Pour améliorer davantage les performances de classification, nous envisageons d'utiliser des méthodes d'extraction de texture et des ensembles de CNN pré-entraînés. Ces techniques pourraient potentiellement augmenter la précision du système de classification et fournir des informations supplémentaires sur la qualité des fèves de cacao.

Cette étude a démontré que l'utilisation de méthodes automatisées de machine Learning pour évaluer la qualité des fèves de cacao peut être très prometteuse. Les résultats obtenus peuvent aider à améliorer la qualité des produits et à accroître l'efficacité de la récolte de cacao.

## Chapitre 6 : Détermination de la maturité des cabosses de cacao

*(“Fusion RGB and HSV Spaces for Cocoa Pod Maturity Identification using the Random Forest Method”, Kacoutchy Jean AYIKPA, Diarra MAMADOU, Abou Bakary BALLO, Pierre GOUTON, Kablan Jérôme ADOU; MDPI conference, Engineering, London, UK, 2022)*

### Introduction

La recherche de fèves de cacao de qualité est un défi majeur pour obtenir des produits finis de meilleure qualité et cela dépend largement de la récolte de la cabosse de cacao. La collecte d'une cabosse non mûre empêchera sa fermentation, tandis que les cabosses trop mûres commenceront à germer et entraîneront une perte de la culture. L'automatisation du processus de détermination de la maturité des cabosses à l'aide de la vision par ordinateur permettra de résoudre le problème mentionné ci-dessus. Dans cette perspective, nous proposons une fusion des espaces de couleur RGB (Rouge, Vert, Bleu) et HSV (Teinte, Saturation, Valeur) qui permettra de constituer une nouvelle image avec plus de caractéristiques sur la cabosse et l'algorithme de la Forêt Aléatoire est ensuite utilisé pour identifier la maturité des cabosses à partir de cette image.

Les résultats des différentes expériences menées en utilisant les espaces de couleur RGB, HSV et la fusion RGB et HSV montrent que la fusion des espaces de couleur a permis d'obtenir une précision plus élevée que l'utilisation d'un seul espace de couleur. En effet, les résultats ont montré que l'utilisation de la fusion RGB et HSV a permis d'obtenir une précision de 95%, tandis que l'utilisation de l'espace de couleur RGB seul a permis d'obtenir une précision de 93%, et l'utilisation de l'espace de couleur HSV seul a permis d'obtenir une précision de 91%. Ces résultats confirment l'efficacité de la méthode proposée pour identifier la maturité des cabosses de cacao. Des métriques ont été utilisées pour consolider les résultats obtenus à partir des différentes expériences et de confirmer l'efficacité de la méthode proposée.

### 6.1. Généralités

La qualité de la fève de cacao dépend en grande partie de la façon dont les cabosses sont récoltées. Pour obtenir des fèves de cacao de qualité, le planteur doit être méticuleux lors de la cueillette des cabosses, en ne sélectionnant que celles qui sont mûres. Cela peut prendre du temps, car toutes les cabosses n'atteignent pas la maturité en même temps, et le planteur doit être en mesure de déterminer si une cabosse est mature ou non. Il est essentiel que seules les cabosses mûres soient récoltées pour garantir un rendement optimal en fèves de cacao. Les

cabosses non mûres ne peuvent pas être utilisées pour la production de fèves de cacao car elles ne peuvent pas être fermentées, entraînant ainsi une perte pour le producteur.

Il existe cependant plusieurs variétés de cabosses de cacao, et la maturité des fruits peut être difficile à déterminer en se basant uniquement sur l'apparence de la cabosse. La couleur de la cabosse mature dépend de sa variété, ce qui rend la sélection des cabosses mûres plus complexe. Les planteurs doivent donc être familiers avec les caractéristiques de chaque variété de cacao afin de pouvoir récolter les cabosses mûres et obtenir des fèves de cacao de qualité. En fin de compte, le soin apporté à la récolte des cabosses de cacao est crucial pour garantir la qualité des fèves de cacao produites [144]. Lorsqu'il s'agit de déterminer la maturité d'une cabosse de cacao, la couleur de la cabosse est souvent un indicateur général. Cependant, il existe également une autre méthode pour évaluer la maturité des cabosses de cacao qui est le tapotement. Les planteurs peuvent tapoter doucement la cabosse avec leurs doigts pour écouter le son qu'elle émet. Si la cabosse est mûre, elle produira un son mat et sourd, indiquant que les fèves de cacao à l'intérieur ont commencé à se détacher de la paroi de la cabosse. Si, en revanche, la cabosse produit un son clair et métallique, cela indique que les fèves ne sont pas encore mûres et qu'il est préférable de la laisser sur l'arbre pour un peu plus longtemps. Les cabosses qui ne sont pas encore mûres ne doivent pas être récoltées, car les fèves à l'intérieur n'ont pas atteint leur potentiel de saveur et de qualité. [145]. En raison de ces obstacles, l'exploitation de la vision par ordinateur avec des algorithmes d'apprentissage automatique est indispensable pour relever l'un des défis majeurs du secteur agricole. Cette étude a pour objectif de déterminer le niveau de maturité des cabosses de cacao en utilisant des techniques d'apprentissage automatique. Nous avons examiné différents espaces colorimétriques, en passant du RGB au HSV, et avons fusionné ces deux espaces pour évaluer l'impact sur la détection de la maturité. L'algorithme choisi pour cette étude est le Random Forest. Les travaux sur les images en couleur deviennent de plus en plus importants dans la plupart des applications de la vie réelle, car les images en couleur peuvent offrir de meilleures performances visuelles et sont bien plus adaptées à la compréhension visuelle humaine. Lee et al. ont présenté une méthode d'amélioration des images de couleur basée sur l'utilisation de l'histogramme d'intensité (HE) sans changer la teinte et la saturation dans l'espace couleur HSI. L'image de contre-jour et l'image de nuit ont été utilisées pour démontrer l'efficacité de la méthode d'amélioration des images en couleur proposée [146]. Dans un souci d'apporter une solution à la dégradation de la qualité des images issues par défaillances d'éclairage, Peen Li et al ont développé une nouvelle méthode d'amélioration de l'image par la fusion multi-algorithme dans les espaces de couleur RGB et HSV. A l'aide de l'algorithme Retinex multi-

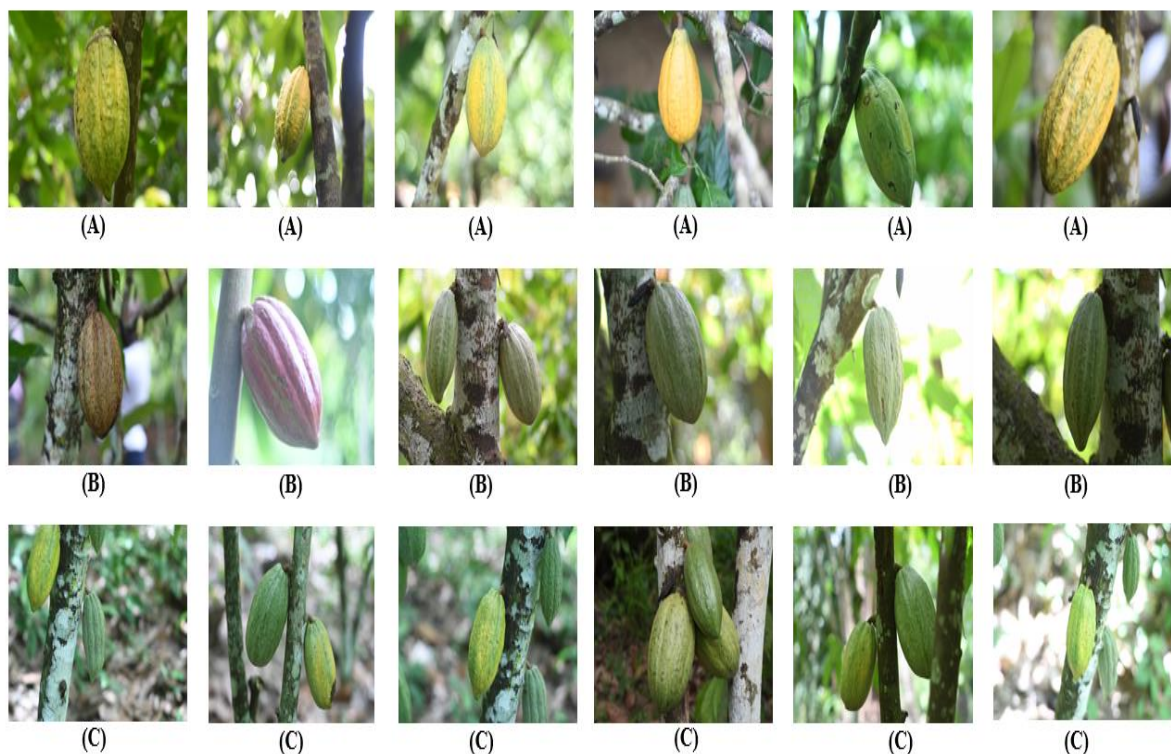
échelle amélioré et l'algorithme Gamma, une amélioration de la luminosité du canal V dans l'espace couleur HSV en espace couleur RGB. Les résultats expérimentaux montrent que le nouvel algorithme peut améliorer la luminosité et le contraste de l'image par rapport aux algorithmes MSR et MSRC [147]. Manchanda et al ont proposé une étude sur la fusion d'images visibles et infrarouges dans l'espace couleur HSV dans les domaines de la surveillance, de l'armée et de nombreuses autres applications réelles. Ainsi, un algorithme qui fusionne visible et infrarouge basé sur une transformation floue dans l'espace a été mené dans cette étude sur plusieurs ensembles de données d'images visibles et infrarouges. Ces travaux ont produit des résultats utiles ont rendu l'interprétation de la scène plus naturelle[148]. Xin Jin et al ont étudié un algorithme efficace de fusion d'images couleur multicateurs basé sur NSST et PCNN. L'étude a montré que les neurones du PCNN appréhendent le caractère et vont provoquer la luminosité similaire des neurones environnants pour capturer l'allumage. L'image couleur RGB est convertie en image couleur HSV. L'algorithme de fusion d'images en couleur proposé fusionne différentes positions de mise au point des images couleur, et l'image fusionnée contient plus d'informations sur la couleur, la texture et les détails [149]. Haleot et al. proposent une approche pour l'amélioration de l'image thermique basée sur une technique de fusion adaptative de l'espace multicolore. Dans son approche l'auteur s'est focalisé sur la fusion d'espaces multi-couleurs testé en deux principales étapes ; où dans la première étape les images thermiques sont mappées à partir de l'espace couleur RVB vers les espaces couleur Lab et HS ensuite dans la seconde étape la composante de luminance (L) dans l'espace couleur Lab sont améliorées par la méthode CLAHE [150]. Smith A et al ont utilisé une approche qui consiste à utiliser l'algorithme de classification Random Forest pour évaluer quantitativement une gamme d'alternatives d'échelles de segmentation d'images potentielles afin d'identifier la ou les échelles de segmentation qui prédisent le mieux les classes d'occupation du sol d'intérêt. Les résultats de ces expériences ont donné une précision moyenne de 85,2% [151] ; Suyoto et al ont étudié une technologie de classification pour le processus de sélection des grains de café civette et robusta. Dans cette recherche il est question d'extraction de caractéristiques de premier ordre avec l'algorithme SVM (Support-Vector-Machines) pour la reconnaissance des motifs des grains de café Civette et Robusta en utilisant l'analyse de la texture des images en niveaux de gris et l'extraction de caractéristiques. La précision de de l'identification de cette méthode est de 87,27% [152]. Oliveira et al. ont proposé un modèle d'apprentissage profond entraîné à identifier les cabosses de cacao à partir de leur environnement, afin de différencier les cabosses de cacao

mûres qui sont prêtes à être récoltées. Les résultats de cette expérience donnent une précision de 90% [153].

Notre étude vise à mettre en place un outil robuste pour automatiser la détection de la maturité des cabosses de cacao dans les plantations à l'aide du digital. Cette contribution pourra substituer la méthode traditionnelle de contrôle de l'état de la maturité des cabosses de cacao. La technique proposée pourrait profiter aux planteurs en leur permettant de déterminer de manière précise l'état de maturité des cabosses cacao.

## 6.2. Jeu de données

Cette étude a utilisé des images numériques de cabosses de cacao pour ses expériences. Le jeu de données utilisés pour cette étude a été développé au chapitre 3 dans la section 3.1.1. Les images de cabosses de cacao ont ensuite été classées selon des critères spécifiques pour permettre une analyse plus approfondie. La figure 70 présente quelques images de cabosses de cacao.



**Figure 70 :** (A) cabosse mature ; (B) cabosse non mature ; (C) cabosse mature et non mature

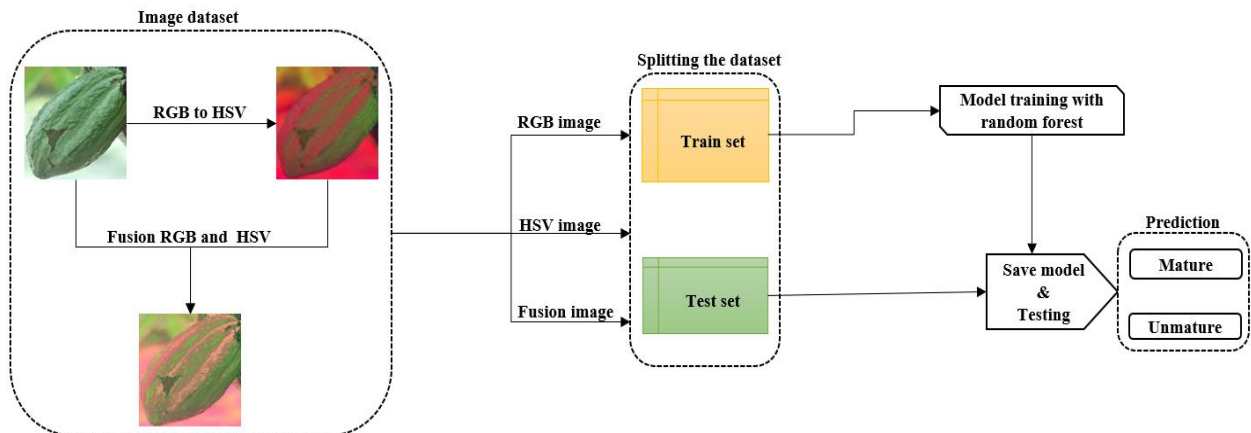
Pour notre étude, nous avons rassemblé un ensemble de données composé de 500 images de cabosses de cacao, dont 250 étaient mûres et 250 étaient non mûres. Ces images



ont été divisées en deux ensembles distincts, où 80% des données ont été utilisées pour l'entraînement du modèle et 20% pour les tests.

### 6.3. Méthodologie de l'étude

La méthodologie est représentée par la figure 71 ci – dessous :



**Figure 71 :** Architecture du modèle de prédiction de la maturité des cabosses de cacao

Notre méthodologie consistera à suivre les étapes suivantes :

- Nous allons convertir les images RGB en HSV, puis fusionner les données RGB et HSV ;
- Nous allons fractionner les données en utilisant les données de la rame pour former la forêt aléatoire ;
- Enfin, nous allons évaluer le modèle en utilisant les données de l'ensemble de test.

### 6.4. Fusion RGB - HSV

La fusion RGB et HSV est une technique qui permet de combiner des images en utilisant les informations de couleur de chacune des images. Cette technique est souvent utilisée en traitement d'image pour améliorer la qualité des images ou pour obtenir de nouvelles informations à partir de données brutes [154].

Dans notre cas, nous allons fusionner les images RGB et HSV en utilisant une méthode de pondération. Chaque image est multipliée par un poids différent qui détermine l'importance de cette image dans la fusion. Le poids peut être défini manuellement ou automatiquement en fonction des caractéristiques de l'image.

Ensuite, les images pondérées sont additionnées pour former une image fusionnée qui contient des informations de couleur à la fois en RGB et en HSV. Cette nouvelle image est utilisée pour améliorer la précision d'un modèle de traitement d'image ou pour créer une

nouvelle image qui combine les caractéristiques des images d'origine. L'équation de la fusion est la suivante :

$$imageFusion = \alpha * imageRGB + \beta * imageHSV + \delta \quad (6-17)$$

Où alpha et beta sont les poids respectifs des deux images et gamma est un paramètre de décalage. Après avoir effectué plusieurs expérimentations, nous avons déterminé manuellement les poids  $\alpha$  et  $\beta$  pour la fusion d'image. Nous avons identifié les valeurs optimales, attribuant  $\alpha$  à 0,2 et  $\beta$  à 0,8, tandis que nous avons maintenu  $\gamma$  à 0 (c'est-à-dire que l'influence de la troisième composante d'image est ignorée dans le processus de fusion). Ces choix ont été faits en fonction des résultats obtenus lors de nos manipulations.

## 6.5. Résultats expérimentaux

**Tableau 31** : Comparaison des performances des différentes méthodes utilisées

Color Space	Accuracy	Precision	F1 score	Recall	MCC	MSE
RGB	93.00	92.98	92.98	93.00	85.23	7.00
HSV	91.00	90.99	90.99	91.00	81.97	9.00
Fusion RGB-HSV	95.00	94.99	94.99	95.00	89.96	5.00

Le tableau 31 fournit les résultats de trois méthodes de classification basées sur différents espaces de couleurs : RGB, HSV et une fusion de RGB et HSV. Chacune de ces méthodes a été évaluée en termes d'exactitude (accuracy), de précision (precision), de F1 score, de rappel (recall), de corrélation de Matthews (MCC) et d'erreur quadratique moyenne (MSE).

Les résultats montrent que la méthode de fusion RGB-HSV a la meilleure performance globale, avec une précision, un F1 score, un rappel et une corrélation de Matthews tous supérieurs à ceux des deux autres méthodes. L'exactitude de la méthode de fusion est également la plus élevée, à 95% et montre que la méthode est capable de classifier correctement la grande majorité des échantillons de l'ensemble de données.

La méthode basée sur l'espace de couleurs RGB a la deuxième meilleure performance, avec des scores globaux légèrement inférieurs à ceux de la méthode de fusion RGB-HSV. Cependant, l'exactitude de la méthode RGB est tout de même assez élevée, à 93%.

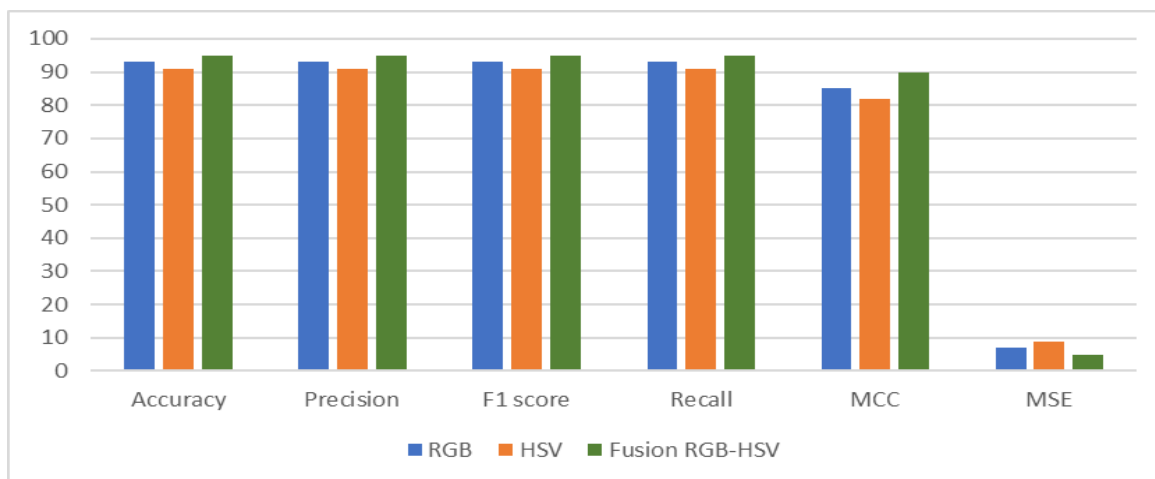
La méthode basée sur l'espace de couleurs HSV a la moins bonne performance globale, avec des scores globaux inférieurs à ceux des deux autres méthodes. L'exactitude de la méthode HSV est de 91%, ce qui est encore assez élevé mais inférieur à celui des deux autres méthodes. Les résultats montrent que la fusion des espaces de couleurs RGB et HSV est une approche efficace pour la classification d'images, avec une performance globale

supérieure à celle des méthodes RGB et HSV utilisées séparément. La matrice de confusion et la courbe ROC de chaque espace couleur présentée par le tableau 32.

**Tableau 32 : Courbe ROC et matrice de confusion**

Color Space	ROC Curve	Confusion Matrix											
RGB	<p>Some extension of Receiver operating characteristic to multi-class</p> <p>ROC curve of class mature (area = 0.92) ROC curve of class unmatured (area = 0.92)</p>	<p>Confusion Matrix</p> <table border="1"> <tr> <td rowspan="2">True labels</td> <td>Mature</td> <td>58</td> <td>3</td> </tr> <tr> <td>Unmatured</td> <td>4</td> <td>35</td> </tr> <tr> <td colspan="2"></td> <td>Mature</td> <td>Unmatured</td> </tr> </table>	True labels	Mature	58	3	Unmatured	4	35			Mature	Unmatured
True labels	Mature	58		3									
	Unmatured	4	35										
		Mature	Unmatured										
HSV	<p>Some extension of Receiver operating characteristic to multi-class</p> <p>ROC curve of class mature (area = 0.91) ROC curve of class unmatured (area = 0.91)</p>	<p>Confusion Matrix</p> <table border="1"> <tr> <td rowspan="2">True labels</td> <td>Mature</td> <td>48</td> <td>4</td> </tr> <tr> <td>Unmatured</td> <td>5</td> <td>43</td> </tr> <tr> <td colspan="2"></td> <td>Mature</td> <td>Unmatured</td> </tr> </table>	True labels	Mature	48	4	Unmatured	5	43			Mature	Unmatured
True labels	Mature	48		4									
	Unmatured	5	43										
		Mature	Unmatured										
Fusion RGB-HSV	<p>Some extension of Receiver operating characteristic to multi-class</p> <p>ROC curve of class mature (area = 0.95) ROC curve of class unmatured (area = 0.95)</p>	<p>Confusion Matrix</p> <table border="1"> <tr> <td rowspan="2">True labels</td> <td>Mature</td> <td>44</td> <td>3</td> </tr> <tr> <td>Unmatured</td> <td>2</td> <td>51</td> </tr> <tr> <td colspan="2"></td> <td>Mature</td> <td>Unmatured</td> </tr> </table>	True labels	Mature	44	3	Unmatured	2	51			Mature	Unmatured
True labels	Mature	44		3									
	Unmatured	2	51										
		Mature	Unmatured										

Pour avoir une vue d'ensemble des métriques de chaque espace de couleur, nous avons créé un histogramme, visible sur la figure.



**Figure 72 :** Histogramme des valeurs métriques

Pour apprécier la valeur ajoutée de notre étude et mesurer sa portée, nous allons la confronter à l'état de l'art. Cette comparaison permettra de positionner notre travail par rapport aux travaux précédents et de déterminer les avancées qu'il apporte en termes de résultats, de méthodologie ou de perspectives. Cette comparaison est présentée dans le tableau 33.

**Tableau 33 :** Comparaison avec les autres travaux

Methods	Accuracy
Oliveira et al.[153]	90.00
HSV	91.00
RGB	93.00
Fusion RGB-HSV	95.00

Le tableau 33 présente les résultats de la comparaison des méthodes de notre étude et celle de la littérature. Les résultats montrent que la méthode de notre étude est supérieure à celle proposée par Oliveira et al. avec un score de 90%.

## Conclusion

La culture du cacao est une industrie importante dans de nombreuses régions du monde. La qualité des produits finaux dépend de nombreux facteurs, notamment de la maturité des cabosses de cacao. Les méthodes traditionnelles pour évaluer la maturité des cabosses de cacao sont manuelles et prennent beaucoup de temps. Il est donc nécessaire de trouver des méthodes automatisées et fiables pour évaluer la maturité des gousses de cacao.

Dans cette optique, notre étude a exploré l'utilisation de l'analyse d'images fusionnées dans les espaces de couleurs RGB et HSV combinée à l'algorithme de forêt aléatoire pour identifier la maturité des cabosses de cacao. Les résultats expérimentaux ont montré que cette méthode a atteint une précision de 95% dans la classification de la maturité des cabosses de cacao. Ces résultats sont très prometteurs pour l'industrie du cacao, car cela peut permettre

une évaluation rapide et précise de la maturité des gousses de cacao, ce qui conduit à une récolte de produits de qualité.

Cependant, il reste encore beaucoup à faire pour améliorer la performance de cette méthode. L'une des pistes envisagées pour l'amélioration de la classification des cabosses de cacao est l'utilisation d'autres espaces de couleurs et des techniques d'optimisation. L'utilisation de ces autres espaces de couleurs pourrait permettre de capturer d'autres caractéristiques importantes des images de gousses de cacao pour améliorer la classification. Les techniques d'optimisation pourraient quant à elles permettre de trouver les meilleurs paramètres pour l'algorithme de forêt aléatoire, améliorant ainsi la précision de la méthode.

En outre, nous envisageons également l'utilisation de techniques de Deep Learning pour extraire les caractéristiques des images de cabosses de cacao, ainsi que des techniques classiques. Cette approche pourrait améliorer la précision de la classification en permettant de mieux capturer les caractéristiques complexes des images de cabosses de cacao.

## **Chapitre 7 : Classification de la maturité des cabosses de cacao à l'aide d'outils de similarité sur une base de données d'images : comparaison des extracteurs de caractéristiques et des espaces de couleurs**

*(“Classification of Cocoa Pod Maturity Using Similarity Tools on an Image Database: Comparison of Feature Extractors and Color Spaces”, Kacoutchy Jean AYIKPA, Diarra MAMADOU, Pierre GOUTON and Kablan Jérôme ADOU; MDPI Data, 2023)*

### **Introduction**

La Côte d’Ivoire est le premier producteur mondial du cacao qui est la principale matière première pour la production de chocolat et de produits dérivés.

Avoir une bonne récolte de cacao garantir la qualité et la quantité de la production, car une cabosse immature ou trop mûre ne peut pas donner des fèves de cacao de qualité. Il est crucial pour les coopératives d'agriculteurs de disposer des outils efficaces pour déterminer la maturité des cabosses de cacao à temps, car cela permet d'obtenir des fèves de meilleure qualité, d'éviter la perte de cabosses et de rentabiliser la récolte.

En plus des techniques standard, comme l'inspection visuelle, la pesée et bien d'autres, pour identifier la maturité des cabosses de cacao, des outils d'automatisation basé sur les mesures de similarité peuvent également être utilisés pour déterminer efficacement la maturité des cabosses de cacao. L'utilisation des mesures de similarité pour la classification des images sera d'un grand appui à la détection de la maturité de cabosse de cacao à partir des techniques standard. Notre étude a pour but d'évaluer le niveau de maturité des cabosses de cacao en utilisant une base de données d'images que nous avons créée. Pour mener à bien, nous avons utilisé deux types d'extracteurs de caractéristiques : l'un basé sur les réseaux de neurones convolutifs (CNN), en particulier le MobileNet, et l'autre basé sur l'analyse de texture à l'aide de la matrice de cooccurrence de niveaux de gris (GCLM). Nous avons ensuite employé des outils mathématiques de mesure de similarité tels que la distance Euclidienne, la distance de corrélation et la distance du chi carré pour classer les images de cabosses de cacao. Enfin, nous avons évalué les résultats à l'aide de métriques telles que l'exactitude et la précision.

Ces expériences ont été réalisées dans plusieurs espaces colorimétriques, tels que RGB, HSV, Lab et LUV, pour observer l'impact des espaces colorimétriques sur les méthodes d'extraction de caractéristiques et de manière générale sur la précision des outils de mesure de similarité utilisés sur les données. Les résultats de ces expériences ont montré que la mesure de distance du chi carré donnait la meilleure précision, avec un score de 99,61%. En utilisant le couple GCLM comme extracteur de caractéristiques et la mesure de distance du chi carré,

nous avons obtenu la meilleure précision dans l'espace Lab. Nous avons comparé les meilleurs résultats obtenus à partir de nos expériences à d'autres méthodes.

## **7.1. Généralités**

La Côte d'Ivoire est un pays situé en Afrique de l'Ouest, connu pour être le premier producteur mondial de cacao [155][156]. Le cacao est une culture importante pour l'économie du pays et est cultivé dans plusieurs régions, fournissant des moyens de subsistance à des milliers de personnes. Cependant, la qualité du cacao dépend fortement de la maturité des cabosses de cacao, qui doit être prise en compte lors de la récolte.

La qualité du cacao a un impact direct sur le prix de vente du produit. Lorsque le cacao est de haute qualité, il est généralement vendu à un prix plus élevé et permettra aux agriculteurs produisant un cacao de qualité supérieure de générer des revenus plus importants [157]. En améliorant la qualité du cacao grâce à des méthodes automatisées de détection de la maturité des cabosses de cacao, les agriculteurs pourraient donc obtenir des revenus plus élevés pour leur travail. L'amélioration de la qualité du cacao aura également des effets positifs sur l'environnement et la durabilité de l'industrie du cacao [158]. En effet, les cabosses de cacao immatures ne contiennent pas autant de fèves de cacao que les cabosses mûres, cela implique que plus de cabosses doivent être récoltées pour obtenir les quantités de fèves souhaitées. Cela entraînera une surexploitation des ressources naturelles et des terres agricoles, ainsi que des coûts plus élevés pour les agriculteurs en termes de main-d'œuvre et d'énergie. En améliorant la détection de la maturité des cabosses de cacao, il serait possible de réduire la quantité de cabosse récoltées et ainsi de réduire l'impact environnemental de l'industrie du cacao.

Il est important de rappeler que la Côte d'Ivoire est le plus grand producteur de cacao au monde, avec une production annuelle de plus de 2 millions de tonnes de fèves de cacao, et tous systèmes permettant l'amélioration de la qualité du cacao aura un impact significatif sur l'industrie du cacao dans le monde entier [159].

Dans ce contexte, la détection de la maturité des cabosses de cacao est un élément clé pour améliorer la qualité du produit final [160]. Cette détection pour la plupart du temps est effectuée manuellement, et il nécessite assez de temps avec des risques d'erreurs de la part des agriculteurs. Les avancées technologiques peuvent permettre de développer des méthodes automatisées pour détecter la maturité des cabosses de cacao, notamment en utilisant des images de cabosse de cacao [161].

En utilisant des méthodes automatisées pour classifier des cabosses de cacao selon leur maturité permettrait d'améliorer la qualité du produit final et d'optimiser les rendements. Cela impacterait positivement avec des répercussions positives sur les revenus des agriculteurs et la croissance économique du pays.

Les méthodes de classification sont largement utilisées dans diverses applications pour regrouper des données similaires. L'un des éléments clés de la classification de données est la mesure de similarité, qui permet de déterminer la proximité entre différentes observations ou exemples. Les méthodes de classification basées sur des mesures de similarité se concentrent sur la comparaison des caractéristiques de chaque élément pour évaluer leur ressemblance ou leur différence [162]. Elles sont donc essentielles pour les méthodes de classification et pour de nombreuses applications, telles que l'analyse de marché, la reconnaissance de motifs et la classification des images.

La méthode traditionnelle de détection de la maturité des cabosses de cacao repose sur l'expertise des cueilleurs, qui peut être subjective et varier d'un cueilleur à l'autre. L'utilisation de méthode automatisée pour la classification des images permettrait une évaluation plus objective et précise de la maturité des cabosses de cacao.

Plusieurs études ont été menées dans ce sens, Liao et al. ont proposé une méthode de segmentation des plants de riz en se basant sur l'espace colorimétrique, elle consiste au grisage de l'image. L'image est convertie de l'espace colorimétrique RGB dans l'espace colorimétrique YCrCb. Un indice de couleur  $2C_g - C_b - C_r$  est ensuite construit pour le grisage de l'image sur l'excès d'indice vert, ce qui réduit l'influence de la variation d'éclairage. Cette méthode a permis d'obtenir de meilleurs résultats de segmentation et réduit le coût de calcul par rapport à la méthode [163], Wen et al. ont proposé une approche basée sur l'espace colorimétrique YUV avec la méthode YUV-GAN qui élimine des nuages minces de bout en bout en apprenant indépendamment les composants de luminance et de chrominance, ce qui est efficace pour réduire le nombre de pixels clairs et sombres irrécupérables [164], Jawahar et al. ont dans leur étude utilisé une méthode basée sur l'espace colorimétrique basé sur Lab pour la segmentation de l'ulcère du pied diabétique [165], Cao et al. ont basé leur étude sur deux méthodes classiques de colorisation automatique, l'approche galloise et l'approche Gupta, ont été réalisées et les résultats expérimentaux démontrent que YCrCb et YIQ ont de meilleures performances en similarité de texture que Lab et LUV dans les deux méthodes de transfert de couleur [166], Chagas et al. ont évalué dans leur étude des modèles CNN pour la classification des images et ces modèles ont surpassé les méthodes conventionnelles [167], Behera et al. propose une méthode de classification de la maturité des fruits de papaye, en



utilisant le VGG-19 avec l'approche d'apprentissage par transfert et atteint une meilleure précision que la méthode existante [168], Espejo-Garcia et al. ont mis en place une solution basée sur l'extraction de caractéristiques à partir de couches profondes de plusieurs modèles CNN d'apprentissage par transfert pour la détection automatique des cultures et des mauvaises herbes [169]. Bueno et al ont étudié une technique pour déterminer le degré de maturité du cacao basé sur le son acoustique des cabosses de cacao. Leur approche a permis d'extraire des caractéristiques reconnaissables pour le processus de formation et ensuite appliquer le réseau de neurones convolutifs pour classer le son du cacao. Le modèle expérimental a donné une précision de 97,46 % du système de classification sur la question de maturité des cabosses non mures et mûres [170]; De Oliveira et al ont utilisé une approche en étudiant un modèle de classification basé sur le réseau profond construit sur le modèle Inception-Resnetv2 pour identifier les cabosses de cacao dans leur environnement afin de différencier les cabosses de cacao mûres avant la récolte. Les résultats obtenus à l'issue de leur étude ont donné une précision de 90% [171]; L'utilisation de paramètres combinés tels que la couleur, le pH et l'acidité ont été utilisés par Cubillos Bojacá et al pour identifier le degré de maturité des fruits de cacao. Cette approche donne des indicateurs de maturité aux planteurs pour une meilleure matière première dans l'industrie du chocolat [172]. Ma et al. ont développé une nouvelle stratégie pour construire des caractéristiques séquentielles à partir d'une seule image en mémoire à court terme (LSTM) avec l'utilisation de deux mesures de similarité basées sur les pixels, y compris l'appariement des pixels (PM) et l'appariement des blocs (BM), sont utilisées pour la sélection des candidats de séquence à partir de l'image entière. Ensuite, la structure séquentielle d'un pixel donné peut être construite en tant qu'entrée de LSTM en utilisant les premiers pixels correspondants avec des similitudes élevées [173].

Ce chapitre traite de la classification de la maturité des cabosses de cacao à partir de la base de données d'images de cabosses de cacao, en utilisant des techniques de traitement d'images. L'étude vise à comparer différents extracteurs de caractéristiques et espaces de couleurs pour déterminer la méthode la plus efficace pour classer la maturité des cabosses de cacao à partir d'images.


## **7.2. Jeu de données**

Le jeu de données utilisé dans cette étude a été décrit dans le chapitre 3 à la section 3.1.1. Nous avons procédé à l'extraction des cabosses sur les images suivi de la mise en place du processus d'augmentation de ces données. Le processus d'augmentation des données s'est

fait en deux opérations principales, il s'agit opération de transformation d'images, qui sont appliquées de manière aléatoire à chaque image d'entrée. Ces opérations sont les suivantes :

- La première transformation est une translation aléatoire horizontale et verticale de des pixels l'image ;
- La seconde transformation est une rotation aléatoire de l'image dans le sens horaire ou antihoraire avec un angle de rotation maximal de 0.4 radians.

En combinant ces deux opérations de transformation d'images, cette fonction permet de générer de nouvelles images à partir de l'ensemble de données d'origine pour augmenter la taille de l'ensemble de données et améliorer les performances du modèle en généralisant mieux sur les données de test. Cette méthode a permis d'obtenir un ensemble de données équilibré, avec un total de 9309 images de cabosses, dont 4660 images de cabosses mûres et 4649 images de cabosses non mûres. La figure 74 illustre clairement l'augmentation du nombre d'images de cabosses après l'extraction de données, ce qui a permis d'améliorer la qualité de nos méthodes de classification.



**Figure 73** : Image originale et image issu de l'augmentation

### 7.3. Extracteurs de caractéristiques

Les extracteurs de caractéristiques sont des algorithmes qui permettent de transformer des données brutes en une représentation pertinente et facilement exploitable pour effectuer des opérations telles que la classification, l'apprentissage automatique etc. Ils sont utilisés dans de nombreux domaines, tels que la vision par ordinateur, le traitement du langage naturel, la reconnaissance de la parole, la biologie et la chimie [174].

L'objectif des extracteurs de caractéristiques est de réduire la dimensionnalité des données, c'est-à-dire de passer d'un grand nombre de caractéristiques à un nombre beaucoup

plus petit. Ils permettent de simplifier les données, pour les rendre moins complexe lors des opérations de classification et ainsi de réduire les temps de calcul nécessaires pour réaliser les opérations de classification ou d'apprentissage.

Il existe plusieurs types d'extracteurs de caractéristiques des images [175] on peut citer entre autres :

- **les extracteurs de caractéristiques basés sur la couleur** : ces extracteurs utilisent la couleur comme caractéristique principale pour décrire une image ;
- **les extracteurs de caractéristiques basés sur la texture** : ces extracteurs utilisent les motifs de texture dans une image pour extraire des caractéristiques ;
- **les extracteurs de caractéristiques basés sur les contours** : ces extracteurs utilisent les contours et les bords de l'image pour extraire des caractéristiques ;
- **les Réseaux de neurones convolutifs (CNN)** : ces extracteurs utilisent des réseaux de neurones profonds pour extraire des caractéristiques d'une image. Les CNN ont connu un grand succès dans de nombreuses applications de traitement d'images, notamment la classification d'images et la détection d'objets [176] ;
- **les descripteurs de formes** : ces extracteurs de caractéristiques sont conçus pour extraire des caractéristiques basées sur la forme des objets dans une image ;
- **la transformée de Fourier** : cette technique transforme une image en une série de fréquences pour extraire des caractéristiques telles que les lignes horizontales et verticales.

Nous avons utilisé deux extracteurs de caractéristiques dans cette étude : le GCLM, qui est un extracteur basé sur la texture, ainsi que le MobileNet, qui est un extracteur basé sur les réseaux de neurones convolutifs.

### **7.3.1. Gray Level Co-Occurrence Matrix (GLCM)**

L'extracteur de caractéristiques GCLM (Grey Level Co-occurrence Matrix) est une technique d'analyse d'image qui se base sur la texture [177]. Elle permet de mesurer la relation entre les niveaux de gris des pixels dans une image en considérant la proximité spatiale de ces niveaux de gris. Cette technique permet ainsi d'extraire des caractéristiques importantes des images qui peuvent ensuite être utilisées dans des tâches de classification, de segmentation, de reconnaissance d'objet, etc.

Le GCLM calcule une matrice de co-occurrence de niveaux de gris pour chaque pixel de l'image, en considérant un certain nombre de directions et de distances [178]. La matrice ainsi obtenue est ensuite normalisée et peut être utilisée pour extraire différentes

caractéristiques, telles que l'énergie, l'homogénéité, l'entropie, la corrélation, etc. L'équation des différentes caractéristiques sont :

$$\text{Contrast} = \sum_{i,j=1}^N P_{i,j}(i-j)^2 \quad (7-18)$$


$$\text{Dissimilarity} = \sum_{i,j=1}^N P_{i,j}|i-j| \quad (7-19)$$

$$\text{Homogeneity} = \sum_{i,j=1}^N \frac{P_{i,j}}{(1+(i+j))^2} \quad (7-20)$$

$$\text{Energy} = \sqrt{\sum_{i,j=1}^N P_{i,j}^2} \quad (7-21)$$

$$\text{Correlation} = \sum_{i,j=1}^N P_{i,j} \left[ \frac{(i-\mu_i)(j-\mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (7-22)$$

Avec  $i, j$  représentant les coordonnées spatiales de la fonction  $P(i, j)$ ,  $N$  est le niveau de gris,  $\sigma$  représente la variance de GCLM, et la variance  $\mu$  représente la moyenne. Dans notre étude, pour chaque image, nous extrayons la caractéristique de chaque canal de l'image en utilisant différents patches de l'image avec l'extraction des paramètres mentionnés ci-dessus. La figure 75 présente l'extraction basée sur le GCLM.



**Figure 74 :** Processus d'extraction de caractéristique avec le GCLM

Le but de cette fonction est d'extraire des caractéristiques à partir d'une série d'images dans notre base de données. Elle suit les étapes suivantes :

Etape 1 : Pour chaque image de notre base de données, la fonction crée un cadre de données temporaire qui sera utilisé pour stocker les caractéristiques extraites de l'image en cours de traitement.

Etape 2 : La fonction calcule plusieurs propriétés de la matrice de co-occurrence en niveaux de gris (GLCM) pour chaque canal de couleur de l'image.

Etape 3 : Pour chaque canal de couleur, la fonction calcule les propriétés suivantes de la matrice de co-occurrence en niveaux de gris :

- Energie
- Corrélation
- Dissimilarité
- Homogénéité
- Contraste

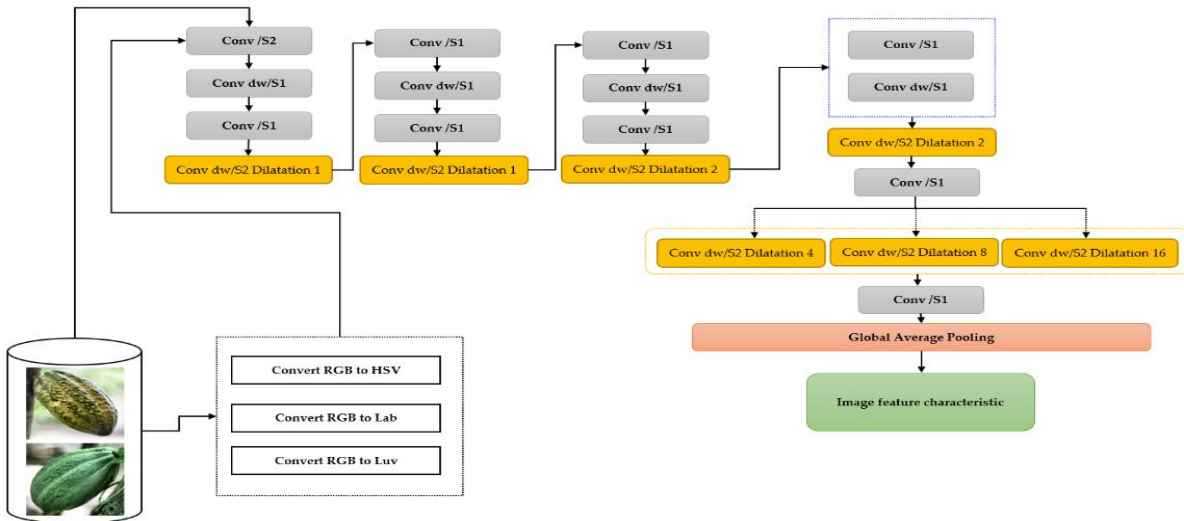
Etape 4 : Ensuite, pour chaque canal de couleur, la fonction calcule ces mêmes propriétés pour quatre matrices de co-occurrence de différents niveaux de gris, qui sont obtenues à l'aide de différents décalages (1, 3, 5, 7). Ces décalages déterminent la distance entre les pixels pris en compte pour calculer la matrice de co-occurrence.

Etape 5 : Enfin, la fonction ajoute toutes ces caractéristiques extraites dans le cadre de données temporaire. Une fois que tous les canaux de couleur ont été traités, le cadre de données temporaire est ajouté au cadre de données final.

Etape 6 : Après le traitement de toutes les images, la fonction renvoie le cadre de données final contenant les caractéristiques extraites de toutes les images

### **7.3.2. MobileNet**

Cette méthode a été décrite dans le chapitre 2 à la section 2.4.1. Dans cette étude nous allons nous intéresser à la partie convolution pour extraire les caractéristiques. La figure 76 présente l'extraction basée sur le CNN-MobileNet.



**Figure 75:** Illustration de l'extracteur de caractéristique de MobileNet

La Figure 76 représente le diagramme d'extraction de caractéristiques d'images basé sur le CNN MobileNet, et suit les étapes suivantes :

Etape 1 : Pour chaque image de la base de données, elle est fournie en entrée au réseau de neurones convolutifs MobileNet.

Etape 2 : L'image d'entrée est ensuite passée à travers plusieurs couches de convolution, où des filtres sont appliqués pour extraire les caractéristiques importantes. Une normalisation par lots (Batch Normalization) est réalisée après chaque couche de convolution pour améliorer la généralisation et accélérer la convergence. Une fonction d'activation est également utilisée pour les sorties de la couche de convolution afin d'introduire de la non-linéarité.

Etape 3 : Une couche de Global Average Pooling est ajoutée pour réduire la dimensionnalité de l'image tout en préservant les caractéristiques importantes. Les caractéristiques de l'image sont ensuite extraites.

## 7.4. Outils de mesure de similarité

La mesure de similarité est une mesure mathématique utilisée pour quantifier la ressemblance ou la différence entre deux éléments d'un ensemble de données. Elle est un élément crucial dans les méthodes de classification basées sur les mesures de similarité, car elle permet de regrouper les données selon des critères de similitude. La mesure de similarité est basée soit sur des caractéristiques spécifiques des données, telles que des attributs ou des variables numériques, ou elle peut être basée sur la similarité entre les profils de données [179]. On distingue plusieurs des outils mathématiques de mesure de similarité, nous utiliserons dans notre étude la distance Euclidienne, la distance de corrélation et distance du chi carré.

#### 7.4.1. Distance Euclidienne

La distance euclidienne, également connue sous le nom de norme euclidienne, est une mesure de distance couramment utilisée en géométrie, en analyse numérique et en statistique. Elle mesure la distance entre deux points dans un espace euclidien à  $n$  dimensions, où  $n$  est un entier positif [180]. En d'autres termes, la distance euclidienne est la longueur de la ligne droite qui relie deux points dans l'espace. L'équation de la distance euclidienne est la suivante :

$$d(X, Y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (7-23)$$

La distance euclidienne est souvent utilisée dans des domaines tels que l'apprentissage automatique et la classification de données. Par exemple, dans la classification de données, la distance euclidienne peut être utilisée pour mesurer la similitude entre des vecteurs de caractéristiques. Si les vecteurs sont similaires, leur distance euclidienne sera faible, ce qui indique qu'ils sont plus proches l'un de l'autre. Si les vecteurs sont très différents, leur distance euclidienne sera grande, ce qui indique qu'ils sont plus éloignés les uns des autres.

#### 7.4.2. Distance de corrélation

La distance de corrélation est une mesure de la similarité entre deux variables aléatoires. Elle a été introduite en 2005 par Székely et Rizzo comme une alternative à la distance dite Euclidienne [181]. Contrairement à cette dernière, qui se fonde sur les écarts entre les valeurs des variables, la distance de corrélation se base sur la corrélation entre les variables. Elle se définit également comme la corrélation entre les rangs des variables [182]. Autrement dit, elle mesure la similarité entre les rangs des valeurs des deux variables. Cette définition est basée sur la théorie des rangs, qui stipule que la corrélation entre les rangs est indépendante de la distribution de probabilité sous-jacente. Cette propriété est importante car elle permet d'utiliser la distance de corrélation pour mesurer la similarité entre des variables dont les distributions ne sont pas connues ou ne sont pas normales. La distance de corrélation est utilisée pour mesurer la similarité entre des variables continues ou discrètes, et est particulièrement utile lorsque les variables ne sont pas linéairement liées. Elle est également utilisée pour mesurer la distance entre ensembles de données. La distance de corrélation entre les variables  $X$  et  $Y$  est définie par l'équation suivante :

$$dC(X, Y) = 1 - \frac{(x - \bar{x}) \cdot (y - \bar{y})}{\|x - \bar{x}\|_2 \|y - \bar{y}\|_2} \quad (7-24)$$

$\bar{x}$  et  $\bar{y}$  représente respectivement les moyennes de x et y.

### 7.4.3. Distance du chi carré

La distance du chi carré, également appelée distance chi carré, est une mesure statistique de la similarité ou de la divergence entre deux ensembles de données. Cette mesure est basée sur la comparaison entre les fréquences observées et les fréquences attendues dans un tableau de contingence [183]. Elle peut être utilisée dans divers domaines, tels que la biologie, la médecine, la sociologie, la psychologie, l'économie, etc.

Le concept de la distance du chi carré repose sur la distribution chi carré, une distribution de probabilité qui est utilisée dans les tests d'indépendance et de goodness-of-fit. Cette distribution est obtenue en sommant les carrés des écarts entre les fréquences observées et les fréquences attendues, divisés par les fréquences attendues [184]. La formule de la distance du chi carré utilise cette même méthode pour calculer une mesure de distance entre deux ensembles de données.

Le calcul de la distance du chi carré nécessite deux ensembles de données [185], qui peuvent être représentés sous forme de tableaux de contingence. Chaque ensemble de données doit être divisé en catégories ou en classes, et les fréquences observées de chaque catégorie doivent être comparées aux fréquences attendues. Les fréquences attendues peuvent être calculées à partir de diverses méthodes, telles que la méthode des proportions marginales, la méthode de la distribution de probabilité, la méthode de l'équi - distribution, etc. Une fois que les fréquences observées et attendues ont été calculées pour chaque catégorie, la distance du chi carré peut être calculée en utilisant la formule suivante :

$$X^2 = \frac{1}{2} \sum_{i=1}^n \frac{(x_i - y_i)^2}{(x_i + y_i)} \quad (7-25)$$

Plus la distance du chi carré est élevée, plus les ensembles de données sont différents. Si la distance du chi carré est nulle, cela signifie que les ensembles de données sont identiques. La valeur de la distance du chi carré peut également être comparée à une distribution de probabilité chi carré pour déterminer la significativité statistique de la différence entre les ensembles de données [186].


## 7.5. Architecture de la méthodologie

Notre méthodologie d'analyse des cabosses de cacao suit un processus rigoureux en six étapes pour assurer une classification précise des cabosses mures et non mures.



- **la première étape** consiste à convertir nos images dans les espaces couleurs HSV, Lab et Luv, pour nous permet d'analyser les couleurs et les nuances des cabosses de manière plus précise ;
- **la deuxième étape** consiste à extraire les caractéristiques des images à l'aide du CNN de MobileNet et du GCLM. Nous avons choisi ces deux techniques d'extraction de caractéristiques pour maximiser la précision de notre classification ;
- **la troisième étape** permettra de diviser nos données en deux parties, l'une contenant les éléments caractérisant les cabosses matures et l'autre les cabosses non matures. Cette étape nous permet de mieux comprendre les caractéristiques distinctives des deux types de cabosses ;
- **la quatrième étape** permettra d'utiliser des algorithmes de similarités pour mesurer les similitudes entre les données de test et les caractéristiques de base de chaque type de maturité. Nous réalisons ensuite la classification en utilisant ces résultats. Cette étape est cruciale pour assurer la précision de notre classification finale.

Notre méthodologie d'analyse des cabosses de cacao est rigoureuse et basée sur des techniques éprouvées pour assurer une classification précise et fiable des cabosses matures et non matures. Elle est résumée par le schéma suivant :



**Figure 76 :** Architecture Générale de la méthodologie d'analyse des cabosses de cacao

## 7.6. Résultats expérimentaux

Dans cette partie de notre étude, nous allons exposer les résultats obtenus à partir de diverses expériences réalisées, ainsi que les discussions qui en découlent. Nous avons pris

soin d'organiser cette présentation en fonction des espaces colorimétriques étudiés, afin de mettre en lumière leur influence sur les extracteurs de caractéristiques et les résultats de mesure de similarité pour la classification.

Nous présenterons les résultats de chaque métrique pour chaque expérience sous forme de tableau, et nous représenterons également les matrices de confusion et les courbes ROC. Les matrices de confusion sont un outil essentiel pour évaluer la précision de notre modèle de classification, en comparant les prédictions avec les résultats réels. Les courbes ROC, quant à elles, nous permettent de mesurer la capacité de notre modèle à discriminer entre les deux classes (cabosses mures et non mures).

Nous allons également prendre le temps d'analyser en détail les résultats obtenus, en mettant en évidence les points forts et les limites de chaque espace couleur. Cette analyse approfondie est essentielle pour comprendre les nuances et les complexités de notre modèle de classification.

### 7.6.1. RGB

**Tableau 34:** Evaluation des performances des algorithmes en RGB avec le CNN-MobileNet

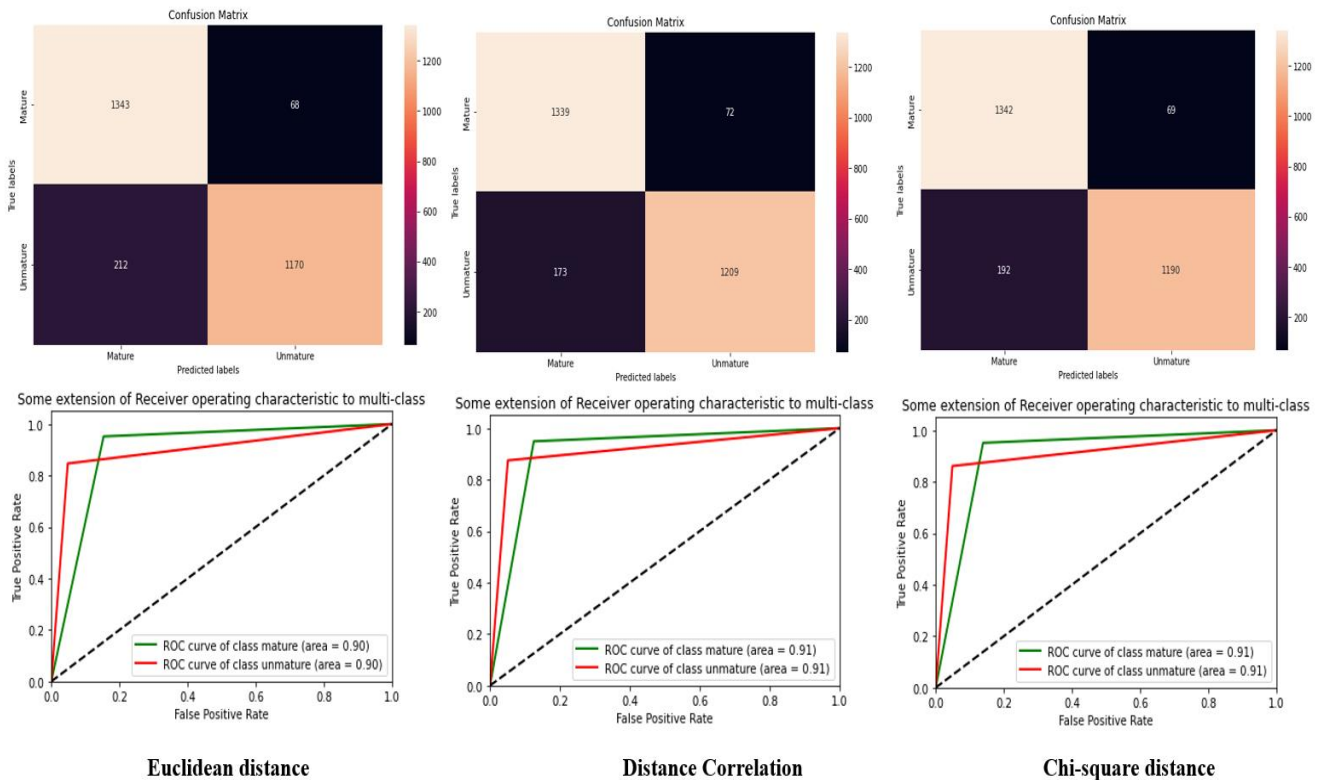
Feature extraction : CNN-MobileNet						
Similarity measure	Accuracy (%)	Precision (%)	MSE	F-score (%)	Recall (%)	MCC (%)
Euclidean distance	89.94	89.94	0.1002	89.94	89.97	80.35
Distance Correlation	91.21	91.21	0.0877	91.21	91.22	82.65
Chi-square distance	90.63	90.63	0.0934	90.63	90.65	81.60

Le tableau 34 donne les résultats de l'analyse de similarité effectuée à l'aide de différentes mesures de distance sur un modèle de feature extraction CNN-MobileNet. Chaque mesure de similarité a été évaluée en termes d'exactitude, de précision, d'erreur quadratique moyenne, de F-score, de rappel et de corrélation de Matthews. La mesure de similarité utilisée peut avoir une grande influence sur les performances globales du modèle. Dans ce cas, nous constatons que la Distance Correlation a donné les meilleurs résultats pour toutes les métriques évaluées, avec une Accuracy de 91,21 %, une précision de 91,21 %, un MSE de 0,0877, un F-score de 91,22 %, un rappel de 82,65 % et un MCC de 82,65 %. La Distance Correlation est la plus efficace pour déterminer la similitude entre les features extraites par le CNN-MobileNet.

Les mesures de distance euclidienne et de distance de chi-square ont également produit des résultats similaires, avec des scores compris entre 89,94 % et 90,63 %. Cela

indique que même si le choix de la mesure de similarité peut influencer les performances du modèle, les différences observées peuvent être négligeables dans la pratique.

Dans l'ensemble, le tableau 43 montre que le CNN-MobileNet est un modèle efficace pour l'extraction de features et que la Distance Correlation est une mesure de similarité efficace pour évaluer la similitude entre les features extraites. La figure 78 présente la matrice de confusion et la courbe ROC du tableau 34.



**Figure 77:** Matrice de confusion et courbe ROC de l'extracteur CNN-MobileNet

**Tableau 35 :** Evaluation des performances des algorithmes en RGB avec le GCLM

Feature extraction: GCLM						
Similarity measure	Accuracy (%)	Precision (%)	MSE	F-score (%)	Recall (%)	MCC (%)
Euclidean distance	88.18	88.18	0.1181	88.18	88.18	76.56
Distance Correlation	90.58	90.58	0.0941	90.58	90.58	81.16
Chi-square distance	89.11	89.11	0.1088	89.11	89.11	78.22

Les résultats de la classification d'images dans l'espace RGB avec l'extracteur GCLM sont présentés dans le tableau 35, en utilisant trois mesures de distance différentes : la distance euclidienne, la distance de corrélation et la distance de chi-square.

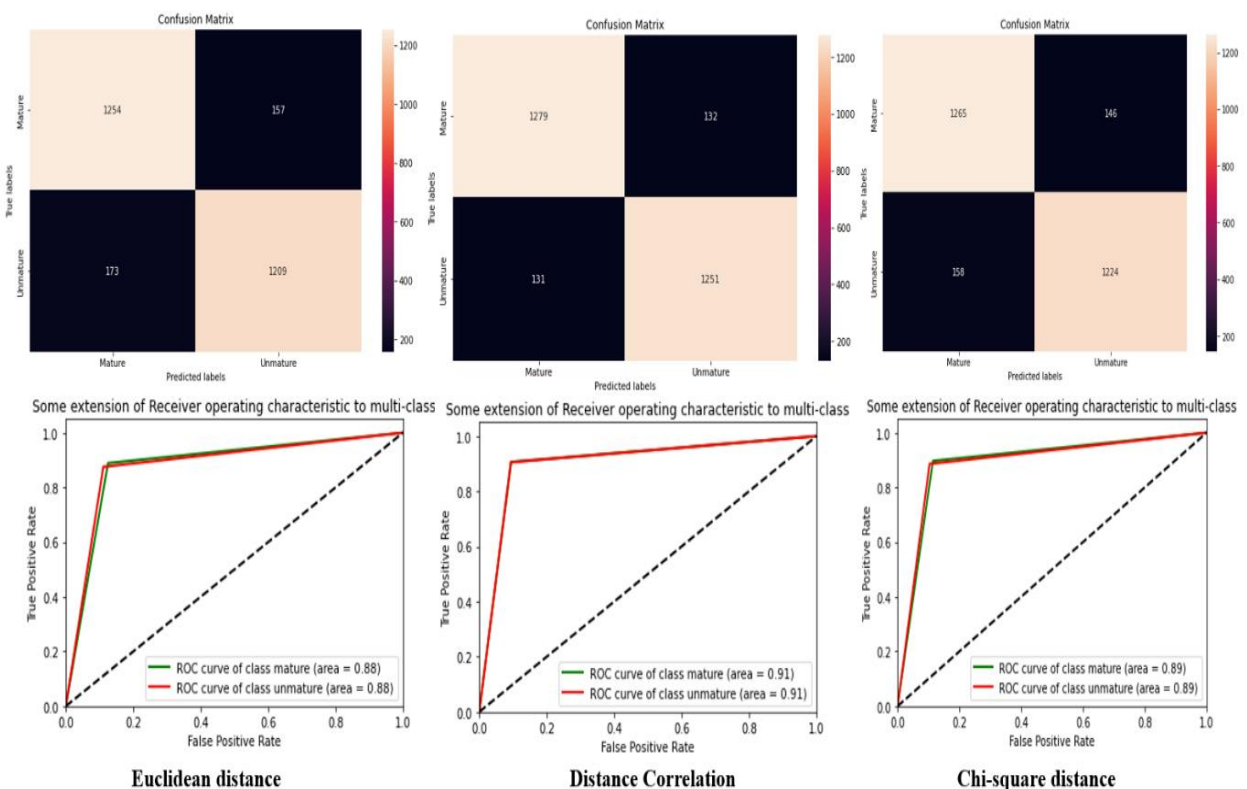
Dans un premier temps les résultats de la distance euclidienne montrent une précision de 88,18 %, une MSE de 0,1181, un F-score de 88,18 %, un rappel de 88,18 % et un MCC de

76,56 %. Ces résultats indiquent que cette mesure de distance est efficace, mais peut être améliorée pour obtenir des résultats plus précis.

Dans un second temps les résultats de la distance de corrélation montrent une précision de 90,58 %, une MSE de 0,0941, un F-score de 90,58 %, un rappel de 90,58 % et un MCC de 81,16 %. Ces résultats indiquent que la distance de corrélation est plus efficace que la distance euclidienne pour classifier les images dans l'espace RGB avec l'extracteur GCLM.

Enfin les résultats de la distance de chi-square montrent une précision de 89,11 %, une MSE de 0,1088, un F-score de 89,11 %, un rappel de 89,11 % et un MCC de 78,22 %. Ces résultats indiquent que la distance de chi-square fonctionne également bien pour classifier les images dans l'espace RGB avec l'extracteur GCLM, mais elle est légèrement moins performante que la distance de corrélation.

L'analyse des résultats montre que la mesure de distance de corrélation est la plus efficace pour classifier les images dans l'espace RGB avec l'extracteur GCLM. Cependant, la distance de chi-square fonctionne également bien et peut être utilisée comme alternative à la distance de corrélation, en fonction des besoins spécifiques de la classification. En outre, il est important de noter que l'efficacité de chaque mesure de distance dépend également des caractéristiques des images à classifier et de la complexité de la tâche de classification. La figure 79 présente la matrice de confusion et la courbe ROC du tableau 35.



**Figure 78 :** Matrice de confusion et courbe ROC de l'extracteur GCLM

## 7.6.2. HSV

**Tableau 36** : Evaluation des performances des algorithmes en HSV avec le CNN-MobileNet

Feature extraction: CNN-MobileNet						
Similarity measure	Accuracy (%)	Precision (%)	MSE	F-score (%)	Recall (%)	MCC (%)
Euclidean distance	85.06	85.06	0.1485	85.06	85.14	70.90
Distance Correlation	85.63	85.63	0.1432	85.63	85.67	71.71
Chi-square distance	84.76	84.76	0.1514	84.76	84.85	70.39

L'analyse des résultats obtenus du tableau 35 avec l'extracteur CNN de MobileNet dans l'espace HSV et en utilisant différentes mesures de distance montre que la précision de la mesure de similitude entre les images peut varier en fonction de la mesure de distance choisie.

Tout d'abord, en utilisant la distance Euclidienne pour mesurer la distance entre les images, nous avons obtenu une précision, une F-score et un MCC d'environ 85%, et est relativement élevé. Il montre que la distance Euclidienne peut être une mesure de distance appropriée pour mesurer la similitude entre les images dans l'espace HSV, bien que les autres mesures de distance aient également des résultats comparables.

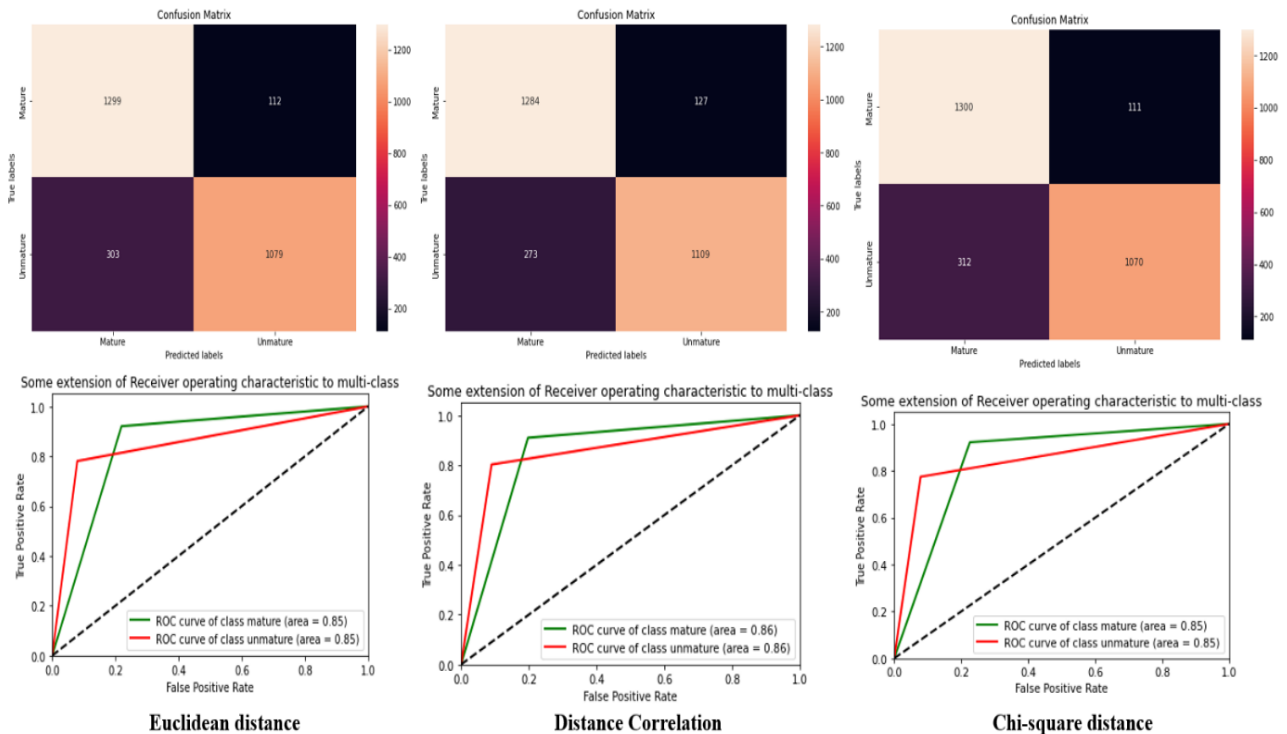
Ensuite, en utilisant la Distance Correlation pour mesurer la distance entre les images, nous avons obtenu des résultats légèrement supérieurs à ceux obtenus avec la distance Euclidienne. La précision, la F-score et le MCC sont tous supérieurs à 85%. Cela montre que la Distance Correlation peut être une mesure de distance plus précise pour mesurer la similitude entre les images dans l'espace HSV que la distance Euclidienne.

Enfin, en utilisant la Chi-square distance pour mesurer la distance entre les images, nous avons obtenu des résultats légèrement inférieurs à ceux obtenus avec les autres mesures de distance. La précision, la F-score et le MCC sont tous inférieurs à 85%. Elle indique que la Chi-square distance peut être une mesure de distance moins précise pour mesurer la similitude entre les images dans l'espace HSV.

En termes de MSE, les trois mesures de distance ont des valeurs comparables et montre que l'extracteur CNN de MobileNet est capable de capturer les caractéristiques importantes des images dans l'espace HSV.

De manière générale, l'analyse des résultats montre que l'extracteur CNN de MobileNet peut être utilisé pour extraire des caractéristiques à partir d'images dans l'espace HSV et que la Distance Correlation est la mesure de distance la plus précise pour mesurer la similitude entre les images que la distance Euclidienne et la distance de Chi-carré. Cependant, il convient de noter que ces résultats ont été obtenus à partir d'un ensemble de données

spécifique et que d'autres ensembles de données peuvent donner des résultats différents. La figure 80 présente la matrice de confusion et la courbe ROC du tableau 36.



**Figure 79** : Matrice de confusion et courbe ROC de l'extracteur CNN-MobileNet en HSV

**Tableau 37** : Evaluation des performances des algorithmes en HSV avec le GCLM

Feature extraction: GCLM						
Similarity measure	Accuracy (%)	Precision (%)	MSE	F-score (%)	Recall (%)	MCC (%)
Euclidean distance	84.17	84.17	0.1582	84.17	84.17	68.35
Distance Correlation	84.42	84.42	0.1432	84.42	84.42	68.85
Chi-square distance	87.25	87.25	0.1274	87.25	87.25	74.52


Le tableau 37 fournit les résultats de l'utilisation de trois distances différentes pour évaluer la performance de l'extracteur GCLM dans la classification des images.

D'abord, les résultats de la distance euclidienne montrent une précision de 84,17%, une MSE de 0,1582, un F-score de 84,17%, un rappel de 84,17% et une MCC de 68,35%. Ces résultats indiquent que la distance euclidienne est relativement précise dans la classification des images, mais peut avoir du mal à distinguer les images similaires.

Ensuite, les résultats de la distance de corrélation donnent une précision de 84,42%, une MSE de 0,1432, un F-score de 84,42%, un rappel de 84,42% et une MCC de 68,85%. Ces résultats sont similaires à ceux de la distance euclidienne, ce qui suggère que la distance de corrélation peut être utilisée comme une alternative efficace à la distance euclidienne.

Enfin, les résultats de la distance du chi carré a donné une précision de 87,25%, une MSE de 0,1274, un F-score de 87,25%, un rappel de 87,25% et une MCC de 74,52%. Ces résultats sont les meilleurs parmi les trois distances utilisées, et montre que la distance du chi carré est la plus efficace pour distinguer les images similaires.

L'analyse des résultats dans l'espace HSV avec l'extracteur GCLM montre que la distance du chi carré est la plus efficace pour la classification des images. Cependant, la distance de corrélation peut également être utilisée comme alternative efficace à la distance euclidienne. Les résultats de cette analyse peuvent aider à guider le choix de la distance appropriée pour une tâche spécifique de classification d'images. La figure 81 présente la matrice de confusion et la courbe ROC du tableau 37.



**Figure 80 :** Matrice de confusion et courbe ROC de l'extracteur GCLM en HSV

### 7.6.3. Luv

**Tableau 38 :** Evaluation des performances des algorithmes en Luv avec le CNN-MobileNet

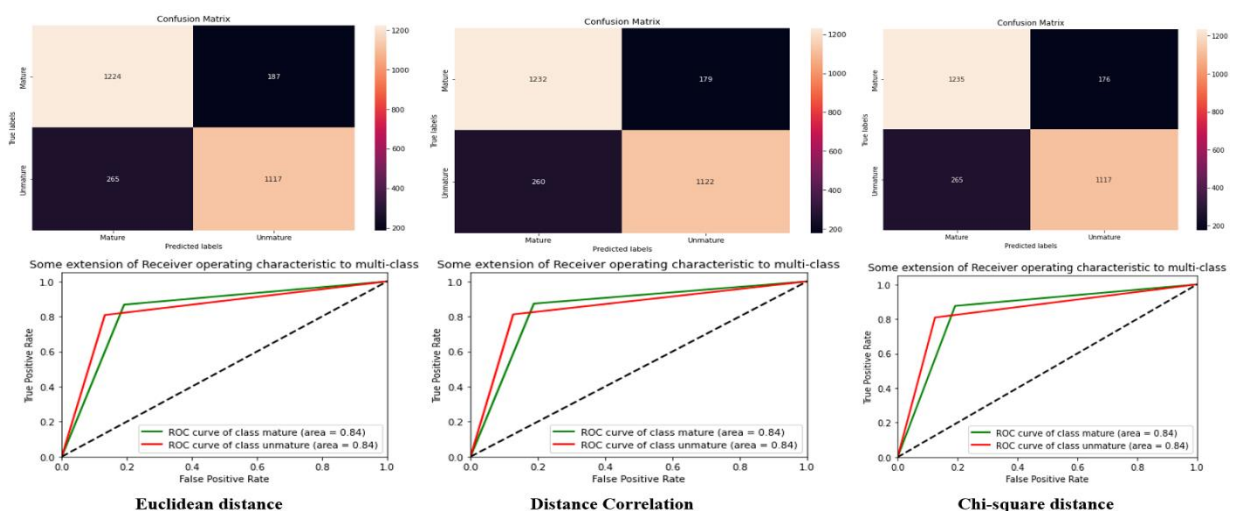
Feature extraction: CNN-MobileNet						
Similarity measure	Accuracy (%)	Precision (%)	MSE	F-score (%)	Recall (%)	MCC (%)
Euclidean distance	83.79	83.79	0.1618	83.79	83.81	67.71
Distance Correlation	84.26	84.26	0.1571	84.26	84.28	68.65
Chi-square distance	84.18	84.18	0.1578	84.18	84.21	68.53

L'analyse des résultats du tableau 38 montre que l'extracteur de caractéristiques CNN de MobileNet est capable de fournir des performances de classification d'images assez élevées dans l'espace Luv, avec une précision moyenne de 84%.

La mesure de distance Euclidienne a donné une précision de 83,79%, qui est légèrement inférieure à celle de la corrélation de distance et de la distance de chi-carré. La précision de la corrélation de distance a été la plus élevée avec une précision de 84,26%, suivie de près par la distance de chi-carré avec une précision de 84,18%.

Pour la précision, nous pouvons noter que les trois mesures de distance ont donné des résultats très proches, cela signifie que les caractéristiques extraites par l'extracteur de caractéristiques CNN de MobileNet sont suffisamment distinctes dans l'espace Luv pour permettre une classification précise des images. Le score F, qui combine la précision et le rappel, est également élevé pour les trois mesures de distance, avec une précision moyenne de 84,09%. Le rappel a été légèrement supérieur pour la mesure de corrélation de distance, qui a obtenu un score de 68,65%. Pour l'erreur quadratique moyenne (MSE), la mesure de corrélation de distance a donné la valeur la plus basse, à 0,1571, tandis que la distance de chi-carré a donné la valeur la plus élevée, à 0,1578.

Enfin, le coefficient de corrélation de Matthews (MCC) a donné des valeurs proches pour les trois mesures de distance, avec la mesure de corrélation de distance donnant la valeur la plus élevée, à 68,53%. En somme, l'analyse des résultats montre que l'extracteur de caractéristiques CNN de MobileNet fournit des performances de classification d'images élevées dans l'espace Luv, avec des performances similaires pour les mesures de distance Euclidienne, Corrélation de distance et Chi-carré. La mesure de corrélation de distance est toutefois légèrement plus précise pour évaluer les performances de classification du modèle. La figure 82 présente la matrice de confusion et la courbe ROC du tableau 47.



**Figure 81 :** Matrice de confusion et courbe ROC de l'extracteur CNN en Luv



**Tableau 39:** Evaluation des performances des algorithmes en Luv avec le GCLM

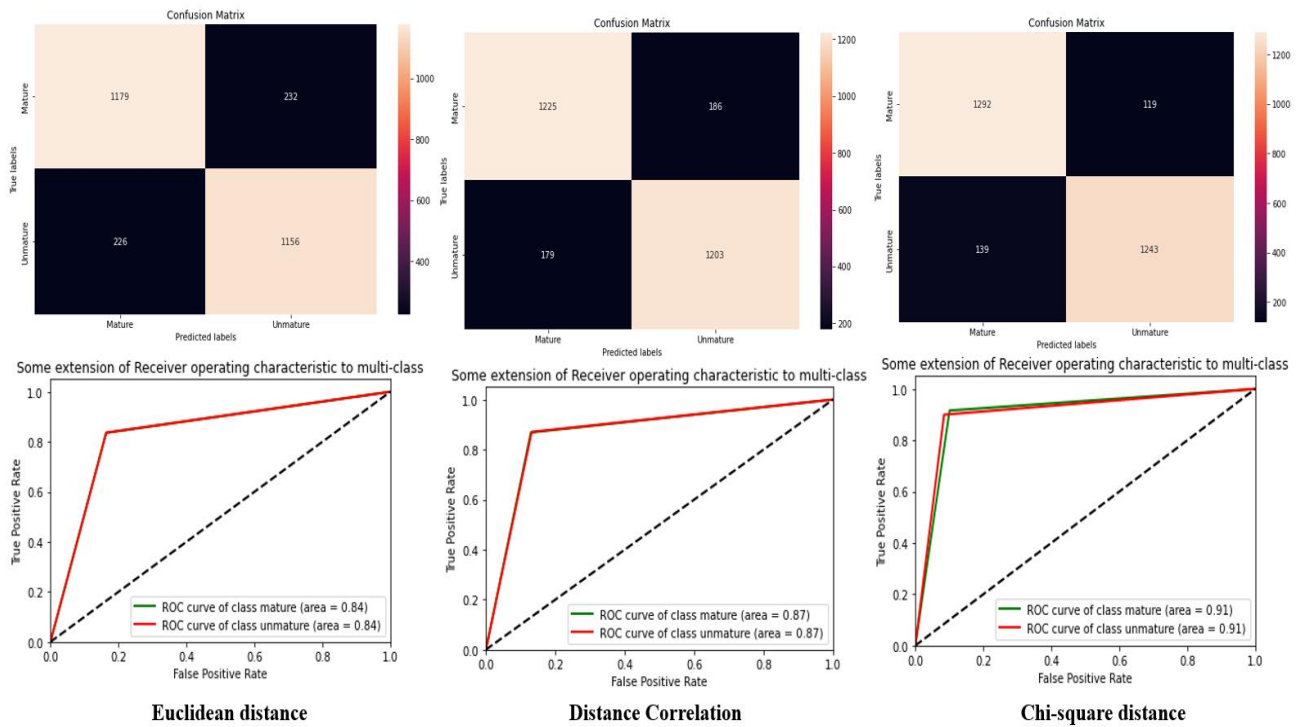
<b>Feature extraction: GCLM</b>						
<b>Similarity measure</b>	<b>Accuracy (%)</b>	<b>Precision (%)</b>	<b>MSE</b>	<b>F-score (%)</b>	<b>Recall (%)</b>	<b>MCC (%)</b>
Euclidean distance	83.60	83.60	0.1639	83.60	83.60	67.20
Distance Correlation	86.93	86.93	0.1306	86.93	86.93	73.86
Chi-square distance	90.76	90.76	0.0923	90.76	90.76	81.52

Le tableau 39 fournit des résultats pour l'analyse de similarité des caractéristiques extraites à partir du GCLM dans l'espace Luv en utilisant des mesures de similarité. Les résultats sont donnés pour trois mesures de similarité différentes : la distance euclidienne, la distance de corrélation et la distance du chi-carré.

Le tableau montre que la mesure de similarité la plus performante est la distance du chi-carré, avec un taux de précision de 90,76% et une valeur MSE de 0,0923. La distance de corrélation est la deuxième mesure de similarité la plus performante, avec un taux de précision de 86,93% et une valeur MSE de 0,1306. La distance euclidienne est la mesure de similarité la moins performante, avec un taux de précision de 83,60% et une valeur MSE de 0,1639.

Il est important de noter que la précision, le F-score, le rappel et le MCC pour chaque mesure de similarité sont égaux au taux de précision.

Ces résultats montrent que la mesure de similarité la plus performante pour l'analyse de caractéristiques extraites à partir de l'espace Luv est la distance du chi-carré, suivie de près par la distance de corrélation. La distance euclidienne est la mesure de similarité la moins performante. Ces résultats peuvent être utiles pour choisir la mesure de similarité appropriée pour les tâches de classification et de reconnaissance de formes impliquant l'espace Luv. Toutefois, il convient de noter que les performances peuvent varier selon les caractéristiques de l'ensemble de données et les objectifs de l'analyse. La figure 83 présente la matrice de confusion et la courbe ROC du tableau 39.



**Figure 82 :** Matrice de confusion et courbe ROC de l'extracteur GCLM en Luv

#### 7.6.4. Lab

**Tableau 40 :** Evaluation des performances des algorithmes en Lab avec le CNN-MobileNet

Feature extraction: CNN-MobileNet						
Similarity measure	Accuracy (%)	Precision (%)	MSE	F-score (%)	Recall (%)	MCC (%)
Euclidean distance	90.83	90.83	0.0916	90.83	90.83	81.70
Distance Correlation	92.48	92.48	0.0751	92.48	92.48	84.96
Chi-square distance	90.82	90.82	0.0916	90.82	90.83	81.72

Dans le tableau 40, le CNN - MobileNet a été utilisé pour extraire les caractéristiques des images de deux ensembles de données et mesurer les distances entre ces caractéristiques à l'aide de trois méthodes de mesure de distance différentes : la distance euclidienne, la distance de corrélation et la distance de chi-carré.

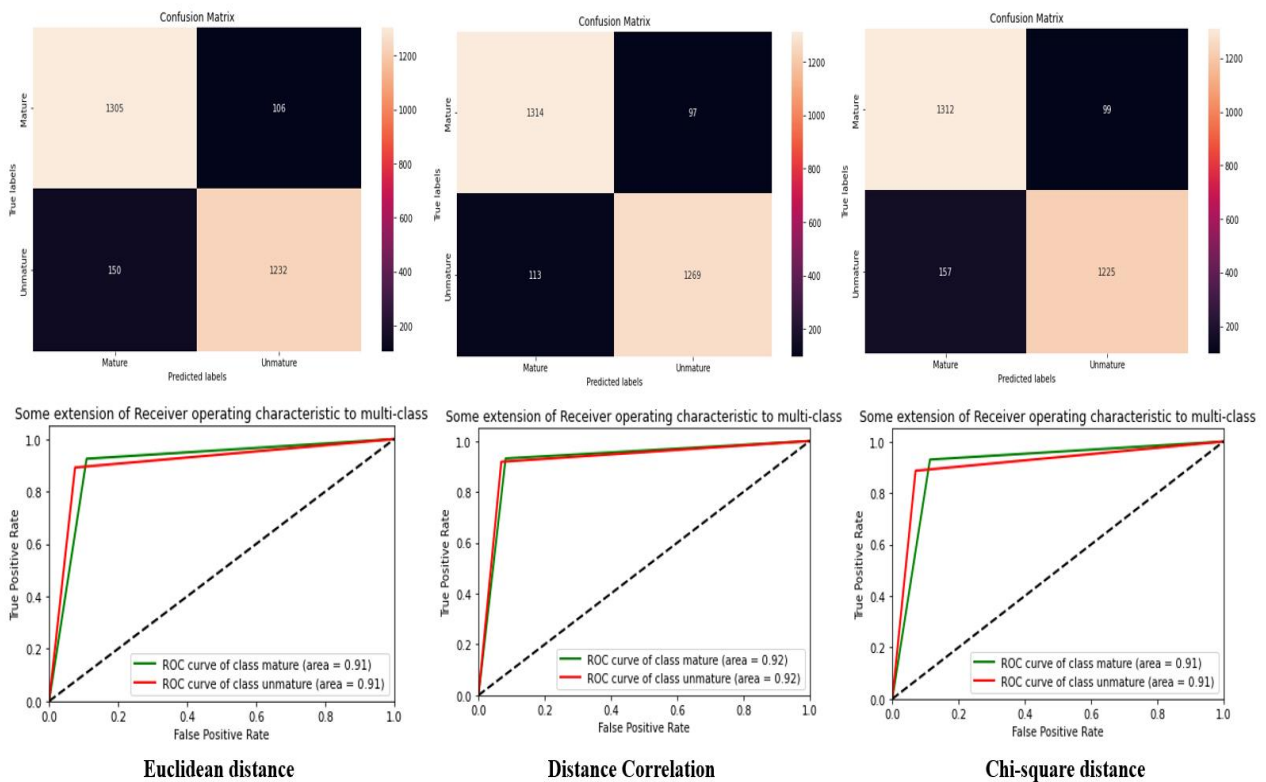
Les résultats montrent que la distance de corrélation a donné les meilleures performances parmi les trois méthodes de mesure de distance. Elle a obtenu le meilleur score d'exactitude (92,48%), de précision (92,48%), de score F (92,48%) et de rappel (92,48%). En outre, la distance de corrélation a également enregistré la plus faible erreur quadratique moyenne (MSE) parmi les trois méthodes.

En revanche, la distance euclidienne et la distance chi-carré ont obtenu des résultats similaires. Elles ont toutes deux enregistré une précision, un score F et un rappel de 90,83%,

ainsi qu'une erreur quadratique moyenne de 0,0916. Cependant, la distance chi-carré a enregistré une légère amélioration de la précision et du rappel par rapport à la distance euclidienne.

La corrélation de Matthews des trois méthodes ont enregistré des résultats similaires, avec un MCC de 81,70% pour la distance euclidienne, 84,96% pour la distance de corrélation et 81,72% pour la distance chi-carré.

Les résultats de cette analyse montrent que la distance de corrélation est la méthode de mesure de distance la plus efficace pour la classification d'images à l'aide de l'extracteur CNN-MobileNet. Cependant, la distance euclidienne et la distance chi-carré peuvent également être utilisées avec des performances similaires, en fonction des besoins spécifiques de chaque projet. La figure 84 présente la matrice de confusion et la courbe ROC du tableau 40.



**Figure 83 :** Matrice de confusion et courbe ROC de l'extracteur CNN en Lab

**Tableau 41 :** Evaluation des performances des algorithmes en Lab avec le GCLM

Feature extraction: GCLM						
Similarity measure	Accuracy (%)	Precision (%)	MSE	F-score (%)	Recall (%)	MCC (%)
Euclidean distance	99.39	99.39	0.0060	99.39	99.39	98.70
Distance Correlation	99.31	99.31	0.0068	99.31	99.31	98.64
Chi-square distance	99.60	99.60	0.0039	99.60	99.60	99.21


Le tableau 41 fournit une analyse approfondie de différentes distances mesurées en utilisant l'espace Lab avec le GCLM.

La première mesure de similarité a été faite avec la distance euclidienne, qui a une précision et une exactitude de 99,39 %. Cela signifie que la mesure de la distance entre les pixels dans l'espace Lab est très précise, avec une erreur quadratique moyenne (MSE) de 0,0060. Le score F et le rappel sont également très élevés, à 99,39 % et 98,70 % respectivement. Le coefficient de corrélation de Matthews (MCC) est également très élevé à 98,70 %, indiquant une très bonne corrélation entre les résultats prévus et les résultats réels.

La deuxième mesure de similarité a été faite avec la distance de corrélation, qui a une précision et une exactitude de 99,31 %. Cela indique une précision similaire à la distance euclidienne, mais avec une légère baisse dans les autres mesures de performance. Le MSE est légèrement plus élevé à 0,0068, et le score F et le rappel sont également légèrement plus bas à 99,31 % et 98,64 % respectivement. Le MCC est également légèrement plus bas à 98,64 %.

La troisième distance mesurée est la distance chi-carré, qui a la plus haute précision et exactitude de toutes les mesures avec une valeur de 99,60 %. Le MSE est également très faible à 0,0039. Le score F, le rappel et le MCC sont également très élevés à 99,60 %, 99,60 % et 99,21 % respectivement. Cela indique que la distance chi-carré est la meilleure mesure de distance pour cet ensemble de données dans l'espace Lab avec le GCLM.

L'analyse approfondie des mesures de distance pour l'ensemble de données dans l'espace Lab avec le GCLM. La distance chi-carré est la mesure la plus précise avec une précision et une exactitude de 99,60 %. Les autres mesures de distance telles que la distance euclidienne et la distance de corrélation sont également très précises avec des performances similaires mais légèrement inférieures à la distance chi-carré. La figure 85 présente la matrice de confusion et la courbe ROC du tableau 41.



**Figure 84 :** Matrice de confusion et courbe ROC de l'extracteur GCLM en Lab

## 7.7. Influence des espaces couleurs

En observant les espaces de couleur, nous avons remarqué leur impact sur nos données ainsi que sur les extracteurs de caractéristiques dans notre étude. Les résultats correspondants sont présentés dans le tableau 42.

**Tableau 42:** tableau qui synthétise les résultats de nos caractéristiques dans différents espaces de couleurs

Color Space	Similarity measure	Feature extractor	Precision (%)
RGB	Distance Correlation	CNN-MobileNet	91.21
RGB	Distance Correlation	GCLM	90.58
HSV	Distance Correlation	CNN-MobileNet	85.63
HSV	Chi-square distance	GCLM	87.25
Luv	Distance Correlation	CNN-MobileNet	84.26
Luv	Chi-square distance	GCLM	90.76
Lab	Distance Correlation	CNN-MobileNet	92.48
Lab	Chi-square distance	GCLM	99.60

Le tableau 42 montre l'impact des espaces couleurs sur les performances de deux extracteurs de caractéristiques différents pour des tâches de classification d'images.

Les résultats montrent que le choix de l'espace colorimétrique, de la mesure de distance et de l'extracteur de caractéristiques peut avoir un impact significatif sur les performances de la classification des images.

Premièrement, l'espace colorimétrique utilisé peut affecter la précision de la classification. Les résultats montrent que l'espace Lab donne les meilleurs résultats de précision pour les deux extracteurs de caractéristiques, tandis que l'espace HSV donne les résultats les plus faibles. Cela peut être dû au fait que l'espace Lab est conçu pour être perpétuellement uniforme, tandis que l'espace HSV est basé sur des coordonnées polaires et peut devoir être plus facilement interprétable pour la perception humaine.

De plus, le choix de la mesure de similarité peut également affecter les résultats. Les résultats montrent que la corrélation de distance dans l'espace RVB et Lab donne de meilleurs résultats de précision pour CNN-MobileNet et GCLM, tandis que la distance chi carré dans l'espace HSV donne de meilleurs résultats pour GCLM. Cela peut être dû à des différences dans la façon dont les mesures de similarité calculent les similarités entre les caractéristiques de l'image.

Enfin, le choix de l'extracteur de caractéristiques peut également avoir un impact sur les performances de classification. Les résultats montrent que les deux extracteurs de caractéristiques ont des performances différentes selon les espaces colorimétriques et les mesures de distance. En fin de compte, ces résultats soulignent l'importance de considérer le choix de l'espace colorimétrique, de la mesure de distance et de l'extracteur de caractéristiques pour obtenir les meilleurs résultats de classification d'image. Cela peut être particulièrement important pour les applications de vision par ordinateur où des performances de classification précises peuvent être critiques.

## 7.8. Comparaison avec les méthodes existantes

**Tableau 43** : Comparaison des travaux

<b>Models</b>	<b>Accuracy</b>
Oliveira et al [187]	90.00
Lab - CNN-MobileNet - Distance Correlation	92.48
Bueno et al [188]	97.46
<b>Lab - GCLM - Chi-square distance</b>	<b>99.60</b>

Les résultats obtenus dans notre étude sont particulièrement remarquables. Les scores que nous avons obtenus sont très intéressants et surpassent ceux rapportés dans la littérature, comme le montre clairement le tableau 43. Ces résultats attestent de l'efficacité de la méthodologie que nous avons utilisée, ainsi que de la qualité de notre jeu de données.

Cependant, il est important de noter que certaines limites doivent être prises en compte dans l'interprétation de ces résultats.

Oliveira et al. [187] ont utilisé le modèle Inception-ResNet-V2 pour détecter la maturité des cabosses de cacao, qui a été préformé sur une vaste base de données d'images et a été utilisé avec succès pour différentes tâches de reconnaissance d'images. En utilisant l'apprentissage par transfert avec ce modèle, il est possible de bénéficier de ses performances pour résoudre une tâche de reconnaissance d'image sans avoir besoin de la même quantité de données ou de temps de calcul. Cependant, ce modèle pré-entraîné peut ne pas convenir à la tâche cible et peut devoir être adapté en ajustant certaines couches du modèle ou en ajoutant de nouvelles couches. De plus, il existe souvent des différences entre les données utilisées pour former le modèle préformé et les données cibles, cela peut affecter les performances du modèle formé.

Bueno et al. [188] ont utilisé une technique qui utilise les données audios de l'exocarpe (partie externe) de la cabosse de cacao pour détecter la maturité des cabosses de cacao. Le cepstre à fréquence Mel a été utilisé pour extraire des caractéristiques reconnaissables pour le processus de maturation, et un réseau neuronal convolutif a été utilisé pour classer les cabosses de cacao. Ce processus a donné des résultats satisfaisants, mais il existe des limites à cette technique, de sorte que la qualité de l'enregistrement peut influencer la précision de l'analyse des données : si l'enregistrement est de mauvaise qualité, il peut être difficile d'extraire des informations fiables. De plus, la taille de l'ensemble de données (4465 fichiers audio) peut être considérée comme un petit échantillon par rapport à d'autres ensembles de données utilisés dans l'apprentissage automatique, ce qui peut limiter la précision de l'analyse et la généralisation des résultats obtenus à d'autres échantillons de fèves de cacao.

Pour notre étude, nous pouvons enregistrer des limites de différents aspects. Premièrement, l'utilisation de réseaux de neurones convolutifs (CNN) pour l'extraction de caractéristiques présente plusieurs limites. Premièrement, ils nécessitent souvent une grande quantité de données de formation pour fonctionner efficacement, ce qui peut être difficile à obtenir dans certaines situations. Deuxièmement, ils sont complexes et nécessitent beaucoup de temps de calcul pour être entraînés et utilisés. Enfin, ils peuvent être sensibles aux variations d'éclairage et autres perturbations de l'image, ce qui peut affecter leurs performances. L'extracteur de texture GCLM (Gray-Level Co-occurrence Matrix) est une technique qui permet d'extraire des caractéristiques de texture d'une image en mesurant la fréquence à laquelle différents niveaux de gris apparaissent ensemble dans l'image. Cette approche peut aider à extraire de manière robuste des caractéristiques de texture, mais peut-être moins efficace pour extraire des caractéristiques plus complexes telles que des formes ou des motifs.

## **Conclusion**

Cette étude approfondie s'est concentrée sur l'évaluation de l'efficacité des extracteurs de caractéristiques et l'influence des espaces colorimétriques sur ces extracteurs pour la classification de la maturité des cabosses de cacao à partir d'images de notre base de données. Plusieurs mesures de similarité ont été utilisées en conjonction avec les extracteurs de caractéristiques pour classer les images de cabosses en fonction de leur niveau de maturité. Les performances de classification ont été examinées sous différents angles en utilisant des extracteurs de caractéristiques basés sur les réseaux de neurones à convolution (CNN) et le gray-level co-occurrence matrix (GCLM) sur différents espaces colorimétriques tels que RGB, HSV, Lab et Luv. Les résultats ont montré que l'espace colorimétrique Lab avec l'utilisation du GCLM et la mesure de similarité Chi-square distance ont produit les meilleurs résultats avec une précision de 99,60%. L'utilisation de l'intelligence artificielle pour la détection de la maturité des cabosses de cacao peut offrir une multitude d'avantages pour les études futures. Pour enrichir notre base de données, nous prévoyons d'ajouter des images de cabosses de cacao à tous les stades de leur développement, depuis leur apparition sur l'arbre jusqu'à leur récolte. Cette initiative contribuera à améliorer notre compréhension de la croissance et de l'évolution de ces cabosses et nous permettra de prévenir les maladies qui pourraient nuire à la récolte.



## Conclusion et perspectives

Il est clair que l'utilisation des méthodes d'apprentissage automatique représente un outil puissant pour améliorer la qualité des récoltes de cacao et de café. En utilisant ces techniques, les producteurs peuvent obtenir une meilleure compréhension de leurs cultures et prendre des décisions plus éclairées en matière de gestion des cultures. En conséquence, les producteurs peuvent d'une réduction des coûts, une augmentation de la productivité et une meilleure qualité des produits finaux.

Il est important de noter que, comme pour toute technologie, l'utilisation des méthodes d'apprentissage automatique doit être effectuée de manière responsable et éthique. Cela implique notamment la collecte et l'utilisation de données de manière transparente et sécurisée, ainsi que l'implication des producteurs et des communautés concernées dans le processus.

En utilisant des algorithmes d'apprentissage automatique pour analyser les données sur les plantes de cacao et de café, il est possible de déterminer les facteurs qui affectent la qualité de la production et de mettre en place des stratégies pour les améliorer. Cela peut se faire en optimisant les pratiques d'irrigation et de fertilisation, en identifiant les meilleures conditions environnementales pour la croissance des plantes, et en utilisant des techniques de sélection de plants pour augmenter la qualité des récoltes.

Les perspectives pour l'utilisation des méthodes d'apprentissage automatique dans l'amélioration de la qualité des récoltes du cacao et du café sont prometteuses. Dans un futur proche, il est probable que ces techniques deviennent de plus en plus courantes dans les fermes et les usines de transformation de cacao et de café, permettant une meilleure gestion des cultures et une amélioration de la qualité des récoltes. De plus, l'utilisation des méthodes d'apprentissage automatique peut contribuer à rendre la production de cacao et de café plus durable en optimisant l'utilisation des ressources et en réduisant les impacts négatifs sur l'environnement.

Il y a plusieurs perspectives intéressantes pour poursuivre les recherches sur l'utilisation des méthodes d'apprentissage automatique pour améliorer la qualité de la production du cacao et du café. Tout d'abord, il serait utile de mieux comprendre les facteurs qui affectent la qualité de ces cultures, notamment en étudiant les différences géographiques et environnementales. Cela pourrait être fait en collectant des données sur les plantes de cacao et de café dans différentes régions du monde et en utilisant des algorithmes d'apprentissage automatique pour les analyser.

De plus, il serait intéressant d'explorer l'utilisation de techniques d'apprentissage automatique en temps réel pour suivre et optimiser les pratiques de production en cours. Par exemple, des capteurs pourraient être utilisés pour collecter des données sur les conditions environnementales et les utiliser pour ajuster en temps réel les pratiques d'irrigation et de fertilisation.

Enfin, il serait également intéressant d'étudier les méthodes d'apprentissage automatique pour améliorer la qualité du cacao et du café lors de la transformation des récoltes en produits finis. Par exemple, des algorithmes d'apprentissage automatique pourraient être utilisés pour optimiser les processus de torréfaction et de mélange pour obtenir des saveurs et des arômes de qualité supérieure.

## Références Bibliographiques

- [1] B. Yao Sadaïou Sabas, K. Gislain Danmo, K. Akoua Tamia Madeleine, et B. Jan, « Cocoa Production and Forest Dynamics in Ivory Coast from 1985 to 2019 », *Land*, vol. 9, n° 12, p. 524, déc. 2020, doi: 10.3390/land9120524.
- [2] d. Daouda et g. O. Gaston, « les politiques etatiques pour le developpement de la culture du cafe et du cacao en cote d'ivoire de 1957 a 1999 / state policies for the development of coffee culture and cocoa in cote d'ivoire from 1957 to 1999 », *Eur. J. Soc. Sci. Stud.*, vol. 5, n° 4, Art. n° 4, août 2020, doi: 10.46827/ejsss.v5i4.882.
- [3] A. Jambor, A. T. Toth, D. Koroshegyi, A. Jambor, A. T. Toth, et D. Koroshegyi, « The Export Competitiveness of Global Cocoa Traders », 2017, doi: 10.22004/AG.ECON.263954.
- [4] N. N. Suh et E. L. Molua, « Cocoa production under climate variability and farm management challenges: Some farmers' perspective », *J. Agric. Food Res.*, vol. 8, p. 100282, juin 2022, doi: 10.1016/j.jafr.2022.100282.
- [5] D. Minh, H. X. Wang, Y. F. Li, et T. N. Nguyen, « Explainable artificial intelligence: a comprehensive review », *Artif. Intell. Rev.*, vol. 55, n° 5, p. 3503-3568, juin 2022, doi: 10.1007/s10462-021-10088-y.
- [6] Y. Dong, J. Hou, N. Zhang, et M. Zhang, « Research on How Human Intelligence, Consciousness, and Cognitive Computing Affect the Development of Artificial Intelligence », *Complexity*, vol. 2020, p. 1-10, oct. 2020, doi: 10.1155/2020/1680845.
- [7] K. Warwick, *Artificial Intelligence: The Basics*, 0 éd. Routledge, 2013. doi: 10.4324/9780203802878.
- [8] G. Carleo *et al.*, « Machine learning and the physical sciences », *Rev. Mod. Phys.*, vol. 91, n° 4, p. 045002, déc. 2019, doi: 10.1103/RevModPhys.91.045002.
- [9] A. Darko, A. P. C. Chan, M. A. Adabre, D. J. Edwards, M. R. Hosseini, et E. E. Ameyaw, « Artificial intelligence in the AEC industry: Scientometric analysis and visualization of research activities », *Autom. Constr.*, vol. 112, p. 103081, avr. 2020, doi: 10.1016/j.autcon.2020.103081.
- [10] B. L, « Intelligence Artificielle : définition, histoire, utilisations, dangers », *Formation Data Science / DataScientest.com*, 20 novembre 2020. <http://datascientest.com/intelligence-artificielle-definition> (consulté le 30 janvier 2023).

- [11] M. Haenlein et A. Kaplan, « A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence », *Calif. Manage. Rev.*, vol. 61, n° 4, p. 5-14, août 2019, doi: 10.1177/0008125619864925.
- [12] T. Huynh-The, Q.-V. Pham, X.-Q. Pham, T. T. Nguyen, Z. Han, et D.-S. Kim, « Artificial intelligence for the metaverse: A survey », *Eng. Appl. Artif. Intell.*, vol. 117, p. 105581, janv. 2023, doi: 10.1016/j.engappai.2022.105581.
- [13] European Commission. Joint Research Centre., *AI watch: defining Artificial Intelligence: towards an operational definition and taxonomy of artificial intelligence*. LU: Publications Office, 2020. Consulté le: 30 janvier 2023. [En ligne]. Disponible sur: <https://data.europa.eu/doi/10.2760/382730>
- [14] E. Liddy, « Natural Language Processing », *Sch. Inf. Stud. - Fac. Scholarsh.*, janv. 2001, [En ligne]. Disponible sur: <https://surface.syr.edu/istpub/63>
- [15] S. Joseph, K. Sedimo, F. Kaniwa, H. Hlomani, et K. Letsholo, « Natural Language Processing: A Review », *Nat. Lang. Process. Rev.*, vol. 6, p. 207-210, mars 2016.
- [16] A. Faiola, C. Newlon, M. Pfaff, et O. Smyslova, « Correlating the effects of flow and telepresence in virtual worlds: Enhancing our understanding of user behavior in game-based learning », *Comput. Hum. Behav.*, vol. 29, n° 3, p. 1113-1121, mai 2013, doi: 10.1016/j.chb.2012.10.003.
- [17] L. Chen, Z. Su, X. He, X. Chen, et L. Dong, « The application of robotics and artificial intelligence in embroidery: challenges and benefits », *Assem. Autom.*, vol. 42, n° 6, p. 851-868, janv. 2022, doi: 10.1108/AA-07-2022-0183.
- [18] N. A. Barriga, « A Short Introduction to Procedural Content Generation Algorithms for Videogames », *Int. J. Artif. Intell. Tools*, vol. 28, n° 02, p. 1930001, mars 2019, doi: 10.1142/S0218213019300011.
- [19] J. Funge, X. Tu, et D. Terzopoulos, « Cognitive modeling: knowledge, reasoning and planning for intelligent characters », in *Proceedings of the 26th annual conference on Computer graphics and interactive techniques - SIGGRAPH '99*, Not Known: ACM Press, 1999, p. 29-38. doi: 10.1145/311535.311538.
- [20] B. G. Buchanan et R. G. Smith, « Fundamentals of Expert Systems », *Annu. Rev. Comput. Sci.*, vol. 3, n° 1, p. 23-58, 1988, doi: 10.1146/annurev.cs.03.060188.000323.
- [21] « Artificial Intelligence and its Application in Different Areas | Semantic Scholar ». <https://www.semanticscholar.org/paper/Artificial-Intelligence-and-its-Application-in-Pannu-Student/9a4d9a755134e612854db1897c03adb3983413df> (consulté le 21 février 2023).

- [22] R. I. Mukhamediev *et al.*, « Review of Artificial Intelligence and Machine Learning Technologies: Classification, Restrictions, Opportunities and Challenges », *Mathematics*, vol. 10, n° 15, p. 2552, juill. 2022, doi: 10.3390/math10152552.
- [23] P. P. Shinde et S. Shah, « A Review of Machine Learning and Deep Learning Applications », in *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)*, Pune, India: IEEE, août 2018, p. 1-6. doi: 10.1109/ICCUBEA.2018.8697857.
- [24] « scikit-learn: machine learning in Python — scikit-learn 1.2.1 documentation ». <https://scikit-learn.org/stable/> (consulté le 4 février 2023).
- [25] W. J. Zhang, G. Yang, Y. Lin, C. Ji, et M. M. Gupta, « On Definition of Deep Learning », in *2018 World Automation Congress (WAC)*, Stevenson, WA: IEEE, juin 2018, p. 1-5. doi: 10.23919/WAC.2018.8430387.
- [26] J. Gu *et al.*, « Recent advances in convolutional neural networks », *Pattern Recognit.*, vol. 77, p. 354-377, mai 2018, doi: 10.1016/j.patcog.2017.10.013.
- [27] N. Djarfour, T. Aïfa, K. Baddari, A. Mihoubi, et J. Ferahtia, « Application of feedback connection artificial neural network to seismic data filtering », *Comptes Rendus Geosci.*, vol. 340, n° 6, p. 335-344, juin 2008, doi: 10.1016/j.crte.2008.03.003.
- [28] « [PDF] Imagerie ultrasonore dans des matériaux complexes par focalisation en tous points : développement d'une méthode de débruitage des images basées sur la décomposition de l'opérateur de retournement temporel | Semantic Scholar ». <https://www.semanticscholar.org/paper/Imagerie-ultrasonore-dans-des-mat%C3%A9riaux-complexes-%3A-Villaverde/fb79ee8e762ca65f025b947e70a4041c151b2573> (consulté le 21 février 2023).
- [29] S. Bock et M. Weis, « A Proof of Local Convergence for the Adam Optimizer », in *2019 International Joint Conference on Neural Networks (IJCNN)*, Budapest, Hungary: IEEE, juill. 2019, p. 1-8. doi: 10.1109/IJCNN.2019.8852239.
- [30] A. A. Lydia et F. S. Francis, « Adagrad - An Optimizer for Stochastic Gradient Descent », vol. 6, n° 0972, 2019.
- [31] F. Alkhalid, « The effect of optimizers in fingerprint classification model utilizing deep learning », *Indones. J. Electr. Eng. Comput. Sci.*, vol. 20, p. 1098, nov. 2020, doi: 10.11591/ijeecs.v20.i2.pp1098-1102.
- [32] D. V. Babu, C. Karthikeyan, Shreya, et A. Kumar, « Performance Analysis of Cost and Accuracy for Whale Swarm and RMSprop Optimizer », *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 993, n° 1, p. 012080, déc. 2020, doi: 10.1088/1757-899X/993/1/012080.

- [33] « Café », *Wikipédia*. 24 janvier 2023. Consulté le: 2 février 2023. [En ligne]. Disponible sur: <https://fr.wikipedia.org/w/index.php?title=Caf%C3%A9&oldid=200750153>
- [34] M. R. Fernando, « Coffee Cultivation in Java, 1830–1917 », in *The Global Coffee Economy in Africa, Asia, and Latin America, 1500–1989*, S. Topik et W. G. Clarence-Smith, Éd., Cambridge: Cambridge University Press, 2003, p. 157-172. doi: 10.1017/CBO9780511512193.017.
- [35] M. A. Nunes, J. F. Bierhuizen, et C. Ploegman, « Studies On Productivity Of Coffee Iii-Differences In Photosynthesis Between Four Varieties Of Coffee », *Acta Bot. Neerlandica*, vol. 18, n° 3, p. 420-424, juin 1969, doi: 10.1111/j.1438-8677.1969.tb00604.x.
- [36] « Café Arabica et Robusta: quelle différence et que choisir? - Javry Coffee », *Javry.com*. <https://javry.com/fr/posts/cafe-arabica-et-robusta-quelle-difference-et-que-choisir> (consulté le 26 avril 2023).
- [37] O. Ovalle-Rivera, P. Läderach, C. Bunn, M. Obersteiner, et G. Schroth, « Projected Shifts in Coffea arabica Suitability among Major Global Producing Regions Due to Climate Change », *PLOS ONE*, vol. 10, n° 4, p. e0124155, avr. 2015, doi: 10.1371/journal.pone.0124155.
- [38] J. Leiter, « Grounds for Agreement: The Political Economy of the Coffee Commodity Chain », *Contemp. Sociol. J. Rev.*, vol. 34, n° 6, p. 639-640, nov. 2005, doi: 10.1177/009430610503400624.
- [39] F. Hakorimana et H. Akçaöz, « The Climate Change and Rwandan Coffee Sector », *Turk. J. Agric. - Food Sci. Technol.*, vol. 5, n° 10, p. 1206, oct. 2017, doi: 10.24925/turjaf.v5i10.1206-1215.1376.
- [40] FAO, *L'atlas des résultats du recensement des exploitants et exploitations agricole (REEA): Recensement des exploitants et exploitations agricoles 2015-2016*. Rome, Italy: FAO, 2019. Consulté le: 13 avril 2023. [En ligne]. Disponible sur: <https://www.fao.org/documents/card/fr?details=CA3111FR%2f>
- [41] « Histoire de la culture du cacao », *Wikipédia*. 17 mars 2023. Consulté le: 29 avril 2023. [En ligne]. Disponible sur: [https://fr.wikipedia.org/w/index.php?title=Histoire\\_de\\_la\\_culture\\_du\\_cacao&oldid=202372061](https://fr.wikipedia.org/w/index.php?title=Histoire_de_la_culture_du_cacao&oldid=202372061)

- [42] A. Coulibaly, K. DAGNOGO, S. Daouda, N. Silue, A. Dembele, et G. Biego, « Daily Intake of Aflatoxins from Cocoa (*Theobroma cacao*) Product in Cote D’ivoire », *Int. J. Sci. Res. IJSR*, vol. 5, p. 1517-1522, mai 2016.
- [43] B. Losch, « PROBLEMATIQUES GENERALES La libéralisation de la filière cacaoyère ivoirienne et les recompositions du marché mondial du cacao : vers la fin des « pays producteurs » et du marché international ? », *Ol. Corps Gras Lipides*, vol. 8, n° 6, p. 566-576, nov. 2001, doi: 10.1051/ocl.2001.0566.
- [44] O. Koff, L. Samagaci, B. Goualie, et S. Niamke, « Diversity of Yeasts Involved in Cocoa Fermentation of Six Major Cocoa-Producing Regions in Ivory Coast », *Eur. Sci. J. ESJ*, vol. 13, n° 30, p. 496, oct. 2017, doi: 10.19044/esj.2017.v13n30p496.
- [45] A. A. Alexis, Y. G. René, D. Olivier, B. Ismaël, K. Z. Jules, et A. Amoncho, « Les caractéristiques agronomiques des vergers de cacaoyer (*Theobroma cacao* L.) en Côte d’Ivoire », . *Vol.*, vol. 2, n° 1.
- [46] « CATALOGUE\_JNCC\_2017.pdf ». Consulté le: 11 février 2023. [En ligne]. Disponible sur: [http://www.conseilcafecacao.ci/docs/2016/CATALOGUE\\_JNCC\\_2017.pdf](http://www.conseilcafecacao.ci/docs/2016/CATALOGUE_JNCC_2017.pdf)
- [47] M. Franzen et M. Borgerhoff Mulder, « Ecological, economic and social perspectives on cocoa production worldwide », *Biodivers. Conserv.*, vol. 16, n° 13, p. 3835-3849, oct. 2007, doi: 10.1007/s10531-007-9183-5.
- [48] C. Cilas et P. Bastide, « Challenges to Cocoa Production in the Face of Climate Change and the Spread of Pests and Diseases », *Agronomy*, vol. 10, n° 9, Art. n° 9, sept. 2020, doi: 10.3390/agronomy10091232.
- [49] « Commission internationale de l’éclairage », *Wikipédia*. 30 mars 2022. Consulté le: 9 février 2023. [En ligne]. Disponible sur: [https://fr.wikipedia.org/w/index.php?title=Commission\\_internationale\\_de\\_l%27%C3%A9clairage&oldid=192397168](https://fr.wikipedia.org/w/index.php?title=Commission_internationale_de_l%27%C3%A9clairage&oldid=192397168)
- [50] « Colorimétrie », *Wikipédia*. 22 décembre 2020. Consulté le: 4 février 2023. [En ligne]. Disponible sur: <https://fr.wikipedia.org/w/index.php?title=Colorim%C3%A9trie&oldid=177909740>
- [51] « Espace de couleur », *Wikipédia*. 14 janvier 2023. Consulté le: 4 février 2023. [En ligne]. Disponible sur: [https://fr.wikipedia.org/w/index.php?title=Espace\\_de\\_couleur&oldid=200444779](https://fr.wikipedia.org/w/index.php?title=Espace_de_couleur&oldid=200444779)
- [52] S. Krig, « Image Pre-Processing », in *Computer Vision Metrics*, Cham: Springer International Publishing, 2016, p. 35-74. doi: 10.1007/978-3-319-33762-3\_2.

- [53] P. Ganesan, B. S. Sathish, K. Vasanth, V. G. Sivakumar, M. Vadivel, et C. N. Ravi, « A Comprehensive Review of the Impact of Color Space on Image Segmentation », in *2019 5th International Conference on Advanced Computing & Communication Systems (ICACCS)*, Coimbatore, India: IEEE, mars 2019, p. 962-967. doi: 10.1109/ICACCS.2019.8728392.
- [54] F. Garcia-Lamont, J. Cervantes, A. López, et L. Rodriguez, « Segmentation of images by color features: A survey », *Neurocomputing*, vol. 292, p. 1-27, mai 2018, doi: 10.1016/j.neucom.2018.01.091.
- [55] GrantMeStrength, « Espaces de couleurs RVB - Win32 apps », 23 septembre 2022. <https://learn.microsoft.com/fr-fr/windows/win32/wcs/rgb-color-spaces> (consulté le 27 avril 2023).
- [56] « Trouver le seuil d'une image (Thresholding) », *FIRST Robotics Competition Documentation*. <https://docs.wpilib.org/en/stable/docs/software/vision-processing/wpilibpi/image-thresholding.html> (consulté le 27 avril 2023).
- [57] « Comment décrivons-nous les couleurs? Modèles de couleurs indépendants », *Portail des produits du groupe PCC*. <https://www.products.pcc.eu/fr/blog/comment-decrivons-nous-les-couleurs-modeles-de-couleurs-independants/> (consulté le 27 avril 2023).
- [58] P. Bolon *et al.*, « Analyse d'images: Filtrage et segmentation ».
- [59] J.-P. Bordes, « Numérique et agriculture de précision », *Ann. Mines - Responsab. Environ.*, vol. N° 87, n° 3, p. 87, 2017, doi: 10.3917/re1.087.0087.
- [60] « Dinamis – Dispositif Institutionnel National d'Approvisionnement Mutualisé en Imagerie Satellitaire ». <https://dinamis.data-terra.org/> (consulté le 11 février 2023).
- [61] H. Senior, « Ceres Imaging: A Pioneer in Aerial Data », *AgtechThinking - technology & entrepreneurship in agriculture*, 3 novembre 2021. <https://agtechthinking.com/2021/11/03/ceres-imaging-a-pioneer-in-aerial-data/> (consulté le 13 avril 2023).
- [62] « Imagerie Satellite Haute Résolution Dans EOSDA LandViewer », 30 septembre 2020. <https://eos.com/fr/products/high-resolution-images/> (consulté le 11 février 2023).
- [63] « Imagerie satellite pour l'aménagement des territoires : retour sur la journée technique du 7 novembre 2017 », *Cerema*. <http://www.cerema.fr/fr/actualites/imagerie-satellite-amenagement-territoires-retour-journee> (consulté le 27 avril 2023).
- [64] « Multispectral imaging », *Wikipedia*. 29 janvier 2023. Consulté le: 11 février 2023. [En ligne]. Disponible sur: [https://en.wikipedia.org/w/index.php?title=Multispectral\\_imaging&oldid=1136255475](https://en.wikipedia.org/w/index.php?title=Multispectral_imaging&oldid=1136255475)



- [65] « FICHER\_LIE\_A\_60542.pdf ». Consulté le: 11 février 2023. [En ligne]. Disponible sur: [https://www.testoon.com/Fichier/A/FICHER\\_LIE\\_A\\_60542.pdf](https://www.testoon.com/Fichier/A/FICHER_LIE_A_60542.pdf)
- [66] « Fichier:Agriculture thermographie aeriene.jpg - La Librairie Thermographique ». [http://www.thethermograpiclibrary.org/index.php?title=Fichier:Agriculture\\_thermographie\\_aeriene.jpg](http://www.thethermograpiclibrary.org/index.php?title=Fichier:Agriculture_thermographie_aeriene.jpg) (consulté le 27 avril 2023).
- [67] « Crop diseases ». <https://www.agric.wa.gov.au/pests-weeds-diseases/diseases/crop-diseases> (consulté le 14 février 2023).
- [68] J. Lu, L. Tan, et H. Jiang, « Review on Convolutional Neural Network (CNN) Applied to Plant Leaf Disease Classification », *Agriculture*, vol. 11, n° 8, p. 707, juill. 2021, doi: 10.3390/agriculture11080707.
- [69] « Planetoscope - Statistiques : Production mondiale de café ». <https://www.planetoscope.com/boisson/791-.html> (consulté le 17 novembre 2021).
- [70] « Quels sont les meilleurs cafés d'Afrique? », 4 mai 2020. <https://graine-de-cafe.com/meilleurs-cafes-afrique/> (consulté le 17 novembre 2021).
- [71] J. Jepkoech, D. M. Mugo, B. K. Kenduiywo, et E. C. Too, « Arabica coffee leaf images dataset for coffee leaf disease detection and classification », *Data Brief*, vol. 36, p. 107142, juin 2021, doi: 10.1016/j.dib.2021.107142.
- [72] S. Giraddi, S. Desai, et A. Deshpande, « Deep Learning for Agricultural Plant Disease Detection », in *ICDSMLA 2019*, A. Kumar, M. Paprzycki, et V. K. Gunjan, Éd., in *Lecture Notes in Electrical Engineering*, vol. 601. Singapore: Springer Singapore, 2020, p. 864-871. doi: 10.1007/978-981-15-1420-3\_93.
- [73] A. Ramcharan, K. Baranowski, P. McCloskey, B. Ahmed, J. Legg, et D. P. Hughes, « Deep Learning for Image-Based Cassava Disease Detection », *Front. Plant Sci.*, vol. 8, p. 1852, oct. 2017, doi: 10.3389/fpls.2017.01852.
- [74] M. H. Saleem, S. Khanchi, J. Potgieter, et K. M. Arif, « Image-Based Plant Disease Identification by Deep Learning Meta-Architectures », *Plants*, vol. 9, n° 11, p. 1451, oct. 2020, doi: 10.3390/plants9111451.
- [75] A. Afifi, A. Alhumam, et A. Abdelwahab, « Convolutional Neural Network for Automatic Identification of Plant Diseases with Limited Data », *Plants*, vol. 10, n° 1, p. 28, déc. 2020, doi: 10.3390/plants10010028.
- [76] J. Xiao, J. Wang, S. Cao, et B. Li, « Application of a Novel and Improved VGG-19 Network in the Detection of Workers Wearing Masks », *J. Phys. Conf. Ser.*, vol. 1518, n° 1, p. 012041, avr. 2020, doi: 10.1088/1742-6596/1518/1/012041.

- [77] G. Yang, G. Chen, C. Li, J. Fu, Y. Guo, et H. Liang, « Convolutional Rebalancing Network for the Classification of Large Imbalanced Rice Pest and Disease Datasets in the Field », *Front. Plant Sci.*, vol. 12, p. 671134, juill. 2021, doi: 10.3389/fpls.2021.671134.
- [78] H. Shao, R. Tang, Y. Lei, J. Mu, Y. Guan, et Y. Xiang, « Rice Ear Counting Based on Image Segmentation and Establishment of a Dataset », *Plants*, vol. 10, n° 8, p. 1625, août 2021, doi: 10.3390/plants10081625.
- [79] G. Shobha et S. Rangaswamy, « Machine Learning », in *Handbook of Statistics*, Elsevier, 2018, p. 197-228. doi: 10.1016/bs.host.2018.07.004.
- [80] « 1.4. Support Vector Machines », *scikit-learn*. <https://scikit-learn/stable/modules/svm.html> (consulté le 28 novembre 2021).
- [81] Y. Akbulut, A. Sengur, Y. Guo, et F. Smarandache, « NS-k-NN: Neutrosophic Set-Based k-Nearest Neighbors Classifier », *Symmetry*, vol. 9, n° 9, p. 179, sept. 2017, doi: 10.3390/sym9090179.
- [82] M. S. Alam et S. T. Vuong, « Random Forest Classification for Detecting Android Malware », in *2013 IEEE International Conference on Green Computing and Communications and IEEE Internet of Things and IEEE Cyber, Physical and Social Computing*, Beijing, China: IEEE, août 2013, p. 663-669. doi: 10.1109/GreenCom-iThings-CPSCoM.2013.122.
- [83] I. Kurt, M. Ture, et A. T. Kurum, « Comparing performances of logistic regression, classification and regression tree, and neural networks for predicting coronary artery disease », *Expert Syst. Appl.*, vol. 34, n° 1, p. 366-374, janv. 2008, doi: 10.1016/j.eswa.2006.09.004.
- [84] S. Wan, Y. Liang, Y. Zhang, et M. Guizani, « Deep Multi-Layer Perceptron Classifier for Behavior Analysis to Estimate Parkinson's Disease Severity Using Smartphones », *IEEE Access*, vol. 6, p. 36825-36833, 2018, doi: 10.1109/ACCESS.2018.2851382.
- [85] A. H. Jahromi et M. Taheri, « A non-parametric mixture of Gaussian naive Bayes classifiers based on local independent features », in *2017 Artificial Intelligence and Signal Processing Conference (AISP)*, Shiraz: IEEE, oct. 2017, p. 209-212. doi: 10.1109/AISP.2017.8324083.
- [86] L. Santos, F. N. Santos, P. M. Oliveira, et P. Shinde, « Deep Learning Applications in Agriculture: A Short Review », in *Robot 2019: Fourth Iberian Robotics Conference*, M. F. Silva, J. Luís Lima, L. P. Reis, A. Sanfeliu, et D. Tardioli, Éd., in *Advances in Intelligent Systems and Computing*, vol. 1092. Cham: Springer International Publishing, 2020, p. 139-151. doi: 10.1007/978-3-030-35990-4\_12.

- [87] V. S. Magomadov, « Deep learning and its role in smart agriculture », *J. Phys. Conf. Ser.*, vol. 1399, n° 4, p. 044109, déc. 2019, doi: 10.1088/1742-6596/1399/4/044109.
- [88] O. Attallah, « MB-AI-His: Histopathological Diagnosis of Pediatric Medulloblastoma and its Subtypes via AI », *Diagnostics*, vol. 11, n° 2, p. 359, févr. 2021, doi: 10.3390/diagnostics11020359.
- [89] Y. Zheng, C. Yang, et A. Merkulov, « Breast cancer screening using convolutional neural network and follow-up digital mammography », in *Computational Imaging III*, A. Ashok, J. C. Petrucci, A. Mahalanobis, et L. Tian, Éd., Orlando, United States: SPIE, mai 2018, p. 4. doi: 10.1117/12.2304564.
- [90] N. Dong, L. Zhao, C. H. Wu, et J. F. Chang, « Inception v3 based cervical cell classification combined with artificially extracted features », *Appl. Soft Comput.*, vol. 93, p. 106311, août 2020, doi: 10.1016/j.asoc.2020.106311.
- [91] T. Rahman *et al.*, « Transfer Learning with Deep Convolutional Neural Network (CNN) for Pneumonia Detection Using Chest X-ray », *Appl. Sci.*, vol. 10, n° 9, p. 3233, mai 2020, doi: 10.3390/app10093233.
- [92] L. Ali, F. Alnajjar, H. A. Jassmi, M. Gocho, W. Khan, et M. A. Serhani, « Performance Evaluation of Deep CNN-Based Crack Detection and Localization Techniques for Concrete Structures », *Sensors*, vol. 21, n° 5, p. 1688, mars 2021, doi: 10.3390/s21051688.
- [93] T.-T. Wong et P.-Y. Yeh, « Reliable Accuracy Estimates from  $k$ -Fold Cross Validation », *IEEE Trans. Knowl. Data Eng.*, vol. 32, n° 8, p. 1586-1594, août 2020, doi: 10.1109/TKDE.2019.2912815.
- [94] M. A. Delbarre *et al.*, « Détection automatique des amyloses cardiaques en scintigraphie osseuse à l'aide du machine learning », *Rev. Médecine Interne*, vol. 42, p. A343, déc. 2021, doi: 10.1016/j.revmed.2021.10.314.
- [95] A. Yee-Rendon, I. Torres-Pacheco, A. S. Trujillo-Lopez, K. P. Romero-Bringas, et J. R. Millan-Almaraz, « Analysis of New RGB Vegetation Indices for PHYVV and TMV Identification in Jalapeño Pepper (*Capsicum annuum*) Leaves Using CNNs-Based Model », *Plants*, vol. 10, n° 10, p. 1977, sept. 2021, doi: 10.3390/plants10101977.
- [96] P. Jagoret, H. T. Ngnogue, E. Malézieux, et I. Michel, « Trajectories of cocoa agroforests and their drivers over time: Lessons from the Cameroonian experience », *Eur. J. Agron.*, vol. 101, p. 183-192, nov. 2018, doi: 10.1016/j.eja.2018.09.007.

- [97] N. Sitohang et R. Siahaan, « Fruit Characteristics of Cocoa in Various Altitude Place », *IOP Conf. Ser. Earth Environ. Sci.*, vol. 205, p. 012022, déc. 2018, doi: 10.1088/1755-1315/205/1/012022.
- [98] P. Lachenaud, D. Clément, X. Argout, S. Scalabrin, et F. Doaré, « The Guiana cacao genetic group ( *Theobroma cacao* L.): a new core collection in French Guiana », *Bot. Lett.*, vol. 165, n° 2, p. 248-254, avr. 2018, doi: 10.1080/23818107.2018.1465466.
- [99] M. J. Alwazzan, M. A. Ismael, et A. N. Ahmed, « A Hybrid Algorithm to Enhance Colour Retinal Fundus Images Using a Wiener Filter and CLAHE », *J. Digit. Imaging*, vol. 34, n° 3, p. 750-759, juin 2021, doi: 10.1007/s10278-021-00447-0.
- [100] N. K. E. Abbadi et E. S. Razaq, « Automatic gray images colorization based on lab color space », *Indones. J. Electr. Eng. Comput. Sci.*, vol. 18, n° 3, p. 1501, juin 2020, doi: 10.11591/ijeecs.v18.i3.pp1501-1509.
- [101] P. Wang, T. Niu, et D. He, « Tomato Young Fruits Detection Method under Near Color Background Based on Improved Faster R-CNN with Attention Mechanism », *Agriculture*, vol. 11, n° 11, p. 1059, oct. 2021, doi: 10.3390/agriculture11111059.
- [102] Y. J. Zhang, « A survey on evaluation methods for image segmentation », *Pattern Recognit.*, vol. 29, n° 8, p. 1335-1346, août 1996, doi: 10.1016/0031-3203(95)00169-7.
- [103] « Segmentation d'image », *Wikipédia*. 24 avril 2021. Consulté le: 17 février 2023. [En ligne]. Disponible sur: [https://fr.wikipedia.org/w/index.php?title=Segmentation\\_d%27image&oldid=182246252](https://fr.wikipedia.org/w/index.php?title=Segmentation_d%27image&oldid=182246252)
- [104] Y. J. Zhang, « Evaluation and comparison of different segmentation algorithms », *Pattern Recognit. Lett.*, vol. 18, n° 10, p. 963-974, oct. 1997, doi: 10.1016/S0167-8655(97)00083-4.
- [105] D. Coquin, « Quantitative evaluation of color image segmentation results using fuzzy neural network », présenté à International Symposium on Optomechatronic Technologies, Y. Otani, Y. Bellouard, J. T. Wen, D. Hodko, Y. Katagiri, S. K. Kassegne, J. Kofman, S. Kaneko, C. A. Perez, D. Coquin, O. Kaynak, Y. Cho, T. Fukuda, J. Yi, et F. Janabi-Sharifi, Éd., San Diego, CA, nov. 2008, p. 72661G. doi: 10.1117/12.807286.
- [106] R. Román-Roldán, J. F. Gómez-Lopera, C. Atae-Allah, J. Martínez-Aroza, et P. L. Luque-Escamilla, « A measure of quality for evaluating methods of segmentation and edge detection », *Pattern Recognit.*, vol. 34, n° 5, p. 969-980, mai 2001, doi: 10.1016/S0031-3203(00)00052-2.

- [107] F. Kraemer, A. Schaefer, A. Eitel, J. Vertens, et W. Burgard, « From Plants to Landmarks: Time-invariant Plant Localization that uses Deep Pose Regression in Agricultural Fields », 2017, doi: 10.48550/ARXIV.1709.04751.
- [108] P. Lottes, J. Behley, N. Chebrolu, A. Milioto, et C. Stachniss, « Joint Stem Detection and Crop-Weed Classification for Plant-specific Treatment in Precision Farming », 2018, doi: 10.48550/ARXIV.1806.03413.
- [109] S. G. Sodjinou, V. Mohammadi, A. T. Sanda Mahama, et P. Gouton, « A deep semantic segmentation-based algorithm to segment crops and weeds in agronomic color images », *Inf. Process. Agric.*, vol. 9, n° 3, p. 355-364, sept. 2022, doi: 10.1016/j.inpa.2021.08.003.
- [110] H. Krähmer *et al.*, « Weed surveys and weed mapping in Europe: State of the art and future tasks », *Crop Prot.*, vol. 129, p. 105010, mars 2020, doi: 10.1016/j.cropro.2019.105010.
- [111] P. Luo, G. Wang, L. Lin, et X. Wang, « Deep Dual Learning for Semantic Image Segmentation », in *2017 IEEE International Conference on Computer Vision (ICCV)*, Venice: IEEE, oct. 2017, p. 2737-2745. doi: 10.1109/ICCV.2017.296.
- [112] X. Li, Z. Liu, P. Luo, C. C. Loy, et X. Tang, « Not All Pixels Are Equal: Difficulty-aware Semantic Segmentation via Deep Layer Cascade », 2017, doi: 10.48550/ARXIV.1704.01344.
- [113] N. Xu, B. Price, S. Cohen, J. Yang, et T. Huang, « Deep Interactive Object Selection », 2016, doi: 10.48550/ARXIV.1603.04042.
- [114] H. Le, L. Mai, B. Price, S. Cohen, H. Jin, et F. Liu, « Interactive Boundary Prediction for Object Selection », in *Computer Vision – ECCV 2018*, V. Ferrari, M. Hebert, C. Sminchisescu, et Y. Weiss, Éd., in Lecture Notes in Computer Science, vol. 11218. Cham: Springer International Publishing, 2018, p. 20-36. doi: 10.1007/978-3-030-01264-9\_2.
- [115] H. Zhao, J. Shi, X. Qi, X. Wang, et J. Jia, « Pyramid Scene Parsing Network », 2016, doi: 10.48550/ARXIV.1612.01105.
- [116] F. Perazzi, J. Pont-Tuset, B. McWilliams, L. Van Gool, M. Gross, et A. Sorkine-Hornung, « A Benchmark Dataset and Evaluation Methodology for Video Object Segmentation », in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV: IEEE, juin 2016, p. 724-732. doi: 10.1109/CVPR.2016.85.

- [117] X. Liang, X. Shen, D. Xiang, J. Feng, L. Lin, et S. Yan, « Semantic Object Parsing with Local-Global Long Short-Term Memory », 2015, doi: 10.48550/ARXIV.1511.04510.
- [118] W. Byeon, T. M. Breuel, F. Raue, et M. Liwicki, « Scene labeling with LSTM recurrent neural networks », in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, USA: IEEE, juin 2015, p. 3547-3555. doi: 10.1109/CVPR.2015.7298977.
- [119] Z. Yan, H. Zhang, Y. Jia, T. Breuel, et Y. Yu, « Combining the Best of Convolutional Layers and Recurrent Layers: A Hybrid Network for Semantic Segmentation », 2016, doi: 10.48550/ARXIV.1603.04871.
- [120] Xuming He, R. S. Zemel, et M. A. Carreira-Perpinan, « Multiscale conditional random fields for image labeling », in *Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2004. CVPR 2004.*, Washington, DC, USA: IEEE, 2004, p. 695-702. doi: 10.1109/CVPR.2004.1315232.
- [121] S. Ioffe et C. Szegedy, « Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift », 2015, doi: 10.48550/ARXIV.1502.03167.
- [122] O. Ronneberger, P. Fischer, et T. Brox, « U-Net: Convolutional Networks for Biomedical Image Segmentation », 2015, doi: 10.48550/ARXIV.1505.04597.
- [123] E. Shelhamer, J. Long, et T. Darrell, « Fully Convolutional Networks for Semantic Segmentation », 2016, doi: 10.48550/ARXIV.1605.06211.
- [124] Y. Xing, L. Zhong, et X. Zhong, « An Encoder-Decoder Network Based FCN Architecture for Semantic Segmentation », *Wirel. Commun. Mob. Comput.*, vol. 2020, p. 1-9, juill. 2020, doi: 10.1155/2020/8861886.
- [125] M. A. Rahman et Y. Wang, « Optimizing Intersection-Over-Union in Deep Neural Networks for Image Segmentation », in *Advances in Visual Computing*, G. Bebis, R. Boyle, B. Parvin, D. Koracin, F. Porikli, S. Skaff, A. Entezari, J. Min, D. Iwai, A. Sadagic, C. Scheidegger, et T. Isenberg, Éd., in *Lecture Notes in Computer Science*, vol. 10072. Cham: Springer International Publishing, 2016, p. 234-244. doi: 10.1007/978-3-319-50835-1\_22.
- [126] « Fèves de cacao : production mondiale par pays 2022 », *Statista*. <https://fr.statista.com/statistiques/565101/production-mondiale-feves-cacao-volume-par-pays/> (consulté le 30 juillet 2022).
- [127] T. S. Guehi *et al.*, « Performance of different fermentation methods and the effect of their duration on the quality of raw cocoa beans: Fermentation's effect on the raw cocoa

- quality », *Int. J. Food Sci. Technol.*, vol. 45, n° 12, p. 2508-2514, déc. 2010, doi: 10.1111/j.1365-2621.2010.02424.x.
- [128] T. G. Schwan, J. Piesman, W. T. Golde, M. C. Dolan, et P. A. Rosa, « Induction of an outer surface protein on *Borrelia burgdorferi* during tick feeding. », *Proc. Natl. Acad. Sci.*, vol. 92, n° 7, p. 2909-2913, mars 1995, doi: 10.1073/pnas.92.7.2909.
- [129] L. Samagaci, H. Ouattara, S. Niamké, et M. Lemaire, « *Pichia kudrazevii* and *Candida nitrativorans* are the most well-adapted and relevant yeast species fermenting cocoa in Agneby-Tiassa, a local Ivorian cocoa producing region », *Food Res. Int.*, vol. 89, p. 773-780, nov. 2016, doi: 10.1016/j.foodres.2016.10.007.
- [130] M. V. Copetti, B. T. Iamanaka, J. L. Pereira, D. P. Lemes, F. Nakano, et M. H. Taniwaki, « Co-occurrence of ochratoxin a and aflatoxins in chocolate marketed in Brazil », *Food Control*, vol. 26, n° 1, p. 36-41, juill. 2012, doi: 10.1016/j.foodcont.2011.12.023.
- [131] L. J. R. Lima, M. H. Almeida, M. J. R. Nout, et M. H. Zwietering, « *Theobroma cacao* L., “The Food of the Gods”: Quality Determinants of Commercial Cocoa Beans, with Particular Reference to the Impact of Fermentation », *Crit. Rev. Food Sci. Nutr.*, vol. 51, n° 8, p. 731-761, sept. 2011, doi: 10.1080/10408391003799913.
- [132] S. Sood et H. Singh, « Computer Vision and Machine Learning based approaches for Food Security: A Review », *Multimed. Tools Appl.*, vol. 80, n° 18, p. 27973-27999, juill. 2021, doi: 10.1007/s11042-021-11036-2.
- [133] L. Saxena et L. Armstrong, « A survey of image processing techniques for agriculture », *Res. Outputs 2014 2021*, janv. 2014, [En ligne]. Disponible sur: <https://ro.ecu.edu.au/ecuworkspost2013/854>
- [134] M. M. Oliveira, B. V. Cerqueira, S. Barbon, et D. F. Barbin, « Classification of fermented cocoa beans (cut test) using computer vision », *J. Food Compos. Anal.*, vol. 97, p. 103771, avr. 2021, doi: 10.1016/j.jfca.2020.103771.
- [135] Y. Adhitya, S. W. Prakosa, M. Köppen, et J.-S. Leu, « Feature Extraction for Cocoa Bean Digital Image Classification Prediction for Smart Farming Application », *Agronomy*, vol. 10, n° 11, p. 1642, oct. 2020, doi: 10.3390/agronomy10111642.
- [136] B. Khagi, C. G. Lee, et G.-R. Kwon, « Alzheimer’s disease Classification from Brain MRI based on transfer learning from CNN », in *2018 11th Biomedical Engineering International Conference (BMEiCON)*, Chiang Mai: IEEE, nov. 2018, p. 1-4. doi: 10.1109/BMEiCON.2018.8609974.

- [137] A. P. A. C. Barbon, S. Barbon, R. G. Mantovani, E. M. Fuzyi, L. M. Peres, et A. M. Bridi, « Storage time prediction of pork by Computational Intelligence », *Comput. Electron. Agric.*, vol. 127, p. 368-375, sept. 2016, doi: 10.1016/j.compag.2016.06.028.
- [138] L. F. Santos Pereira, S. Barbon, N. A. Valous, et D. F. Barbin, « Predicting the ripening of papaya fruit with digital imaging and random forests », *Comput. Electron. Agric.*, vol. 145, p. 76-82, févr. 2018, doi: 10.1016/j.compag.2017.12.029.
- [139] Muthulakshmi. A et P. N. Renjith, « Classification of Durian Fruits based on Ripening with Machine Learning Techniques », in *2020 3rd International Conference on Intelligent Sustainable Systems (ICISS)*, Thoothukudi, India: IEEE, déc. 2020, p. 542-547. doi: 10.1109/ICISS49785.2020.9316006.
- [140] B. Harel, Y. Parmet, et Y. Edan, « Maturity classification of sweet peppers using image datasets acquired in different times », *Comput. Ind.*, vol. 121, p. 103274, oct. 2020, doi: 10.1016/j.compind.2020.103274.
- [141] *Principal Component Analysis*. in Springer Series in Statistics. New York: Springer-Verlag, 2002. doi: 10.1007/b98835.
- [142] Kowsari, Jafari Meimandi, Heidarysafa, Mendu, Barnes, et Brown, « Text Classification Algorithms: A Survey », *Information*, vol. 10, n° 4, p. 150, avr. 2019, doi: 10.3390/info10040150.
- [143] X. Qi, T. Wang, et J. Liu, « Comparison of Support Vector Machine and Softmax Classifiers in Computer Vision », in *2017 Second International Conference on Mechanical, Control and Computer Engineering (ICMCCE)*, Harbin: IEEE, déc. 2017, p. 151-155. doi: 10.1109/ICMCCE.2017.49.
- [144] S. Marty-Terrade et A. G. Marangoni, « Impact of Cocoa Butter Origin on Crystal Behavior », in *Cocoa Butter and Related Compounds*, Elsevier, 2012, p. 245-274. doi: 10.1016/B978-0-9830791-2-5.50014-1.
- [145] A. Vázquez-Ovando, « Efecto de la fermentación y del tostado sobre el contenido de aminos biogénicas en semillas de », *J. Negat. NO Posit. RESULTS*, n° 12, p. 958-979, déc. 2018, doi: 10.19230/jonnpr.2778.
- [146] S.-L. Lee et C.-C. Tseng, « Color image enhancement using histogram equalization method without changing hue and saturation », in *2017 IEEE International Conference on Consumer Electronics - Taiwan (ICCE-TW)*, Taipei, Taiwan: IEEE, juin 2017, p. 305-306. doi: 10.1109/ICCE-China.2017.7991117.



- [147] P. Li, Y. Huang, et K. Yao, « Multi-algorithm Fusion of RGB and HSV Color Spaces for Image Enhancement », in *2018 37th Chinese Control Conference (CCC)*, Wuhan: IEEE, juill. 2018, p. 9584-9589. doi: 10.23919/ChiCC.2018.8483674.
- [148] M. Manchanda et R. Sharma, « Fusion of visible and infrared images in HSV color space », in *2017 3rd International Conference on Computational Intelligence & Communication Technology (CICT)*, Ghaziabad, India: IEEE, févr. 2017, p. 1-6. doi: 10.1109/CICT.2017.7977384.
- [149] X. Jin, R. Nie, D. Zhou, Q. Wang, et K. He, « Multifocus Color Image Fusion Based on NSST and PCNN », *J. Sens.*, vol. 2016, p. 1-12, 2016, doi: 10.1155/2016/8359602.
- [150] R. A. Haleot, Z. M. Abood, et GhadaS. Karam, « Thermal Image Enhancement Algorithm Based on Adaptive Fusion Technique of Multi Color Space », *Int. J. Eng. Res. Adv. Technol.*, vol. 06, n° 09, p. 10-15, 2020, doi: 10.31695/IJERAT.2020.3637.
- [151] A. Smith, « Image segmentation scale parameter optimization and land cover classification using the Random Forest algorithm », *J. Spat. Sci.*, vol. 55, n° 1, p. 69-79, juin 2010, doi: 10.1080/14498596.2010.487851.
- [152] R. Z. H. Suyoto, M. Komarudin, G. F. Nama, et T. Yulianti, « Classification of Civet and Canephora coffee using Support-Vector Machines (SVM) algorithm based on order-1 feature extraction », *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 1173, n° 1, p. 012006, août 2021, doi: 10.1088/1757-899X/1173/1/012006.
- [153] J. R. C. P. de Oliveira et R. Ap. F. Romero, « Transfer Learning Based Model for Classification of Cocoa Pods », in *2018 International Joint Conference on Neural Networks (IJCNN)*, Rio de Janeiro: IEEE, juill. 2018, p. 1-6. doi: 10.1109/IJCNN.2018.8489126.
- [154] M. Kumar et S. R. Jindal, « Fusion of RGB and HSV colour space for foggy image quality enhancement », *Multimed. Tools Appl.*, vol. 78, n° 8, p. 9791-9799, avr. 2019, doi: 10.1007/s11042-018-6599-8.
- [155] A. (ed ) Hébert et P. Ammar-Khodja, *Les mondes du cacao*. CIRAD, 1999. Consulté le: 11 mars 2023. [En ligne]. Disponible sur: <https://agritrop.cirad.fr/507441/>
- [156] M. Wessel et P. M. F. Quist-Wessel, « Cocoa production in West Africa, a review and analysis of recent developments », *NJAS Wagening. J. Life Sci.*, vol. 74-75, n° 1, p. 1-7, déc. 2015, doi: 10.1016/j.njas.2015.09.001.
- [157] V. Blanchet et A. Carimentrand, *Dictionnaire du commerce équitable*. Editions Quæ, 2012. doi: 10.3917/quae.blanc.2012.01.

- [158] A. Ntiamoah et G. Afrane, « Environmental impacts of cocoa production and processing in Ghana: life cycle assessment approach », *J. Clean. Prod.*, vol. 16, n° 16, p. 1735-1740, nov. 2008, doi: 10.1016/j.jclepro.2007.11.004.
- [159] J. K. Gyan et B. Bajan, « MARKET ANALYSIS ON COCOA BEANS EXPORT: THE CASE OF GHANA AND COTE D'IVOIRE IN WEST AFRICA », *J. Agribus. Rural Dev.*, vol. 66, n° 4, janv. 2023, doi: 10.17306/J.JARD.2022.01646.
- [160] K. E. Rojas, M. C. García, I. X. Cerón, R. E. Ortiz, et M. P. Tarazona, « Identification of potential maturity indicators for harvesting cacao », *Heliyon*, vol. 6, n° 2, p. e03416, févr. 2020, doi: 10.1016/j.heliyon.2020.e03416.
- [161] A. M. Gallego *et al.*, « Analysis of fruit ripening in Theobroma cacao pod husk based on untargeted metabolomics », *Phytochemistry*, vol. 203, p. 113412, nov. 2022, doi: 10.1016/j.phytochem.2022.113412.
- [162] H. Najmeddine, F. Suard, A. Jay, P. Marechal, et M. Sylvain, « Mesures de similarité pour l'aide à l'analyse des données énergétiques de bâtiments », présenté à RFIA 2012 (Reconnaissance des Formes et Intelligence Artificielle), janv. 2012, p. 978. Consulté le: 12 mars 2023. [En ligne]. Disponible sur: <https://hal.science/hal-00656546>
- [163] J. Liao, Y. Wang, J. Yin, L. Liu, S. Zhang, et D. Zhu, « Segmentation of Rice Seedlings Using the YCrCb Color Space and an Improved Otsu Method », *Agronomy*, vol. 8, n° 11, p. 269, nov. 2018, doi: 10.3390/agronomy8110269.
- [164] X. Wen, Z. Pan, Y. Hu, et J. Liu, « Generative Adversarial Learning in YUV Color Space for Thin Cloud Removal on Satellite Imagery », *Remote Sens.*, vol. 13, n° 6, p. 1079, mars 2021, doi: 10.3390/rs13061079.
- [165] M. Jawahar, L. J. Anbarasi, S. G. Jasmine, et M. Narendra, « Diabetic Foot Ulcer Segmentation using Color Space Models », in *2020 5th International Conference on Communication and Electronics Systems (ICCES)*, Coimbatore, India: IEEE, juin 2020, p. 742-747. doi: 10.1109/ICCES48766.2020.9138024.
- [166] L. Cao, Y. Shang, J. Zhao, et Z. Li, « Comparison of Grayscale Image Colorization Methods in Different Color Spaces », in *Advances in Graphic Communication, Printing and Packaging*, P. Zhao, Y. Ouyang, M. Xu, L. Yang, et Y. Ren, Éd., in *Lecture Notes in Electrical Engineering*, vol. 543. Singapore: Springer Singapore, 2019, p. 290-300. doi: 10.1007/978-981-13-3663-8\_40.
- [167] P. Chagas *et al.*, « Evaluation of Convolutional Neural Network Architectures for Chart Image Classification », in *2018 International Joint Conference on Neural Networks (IJCNN)*, Rio de Janeiro: IEEE, juill. 2018, p. 1-8. doi: 10.1109/IJCNN.2018.8489315.

- [168] S. K. Behera, A. K. Rath, et P. K. Sethy, « Maturity status classification of papaya fruits based on machine learning and transfer learning approach », *Inf. Process. Agric.*, vol. 8, n° 2, p. 244-250, juin 2021, doi: 10.1016/j.inpa.2020.05.003.
- [169] B. Espejo-Garcia, N. Mylonas, L. Athanasakos, S. Fountas, et I. Vasilakoglou, « Towards weeds identification assistance through transfer learning », *Comput. Electron. Agric.*, vol. 171, p. 105306, avr. 2020, doi: 10.1016/j.compag.2020.105306.
- [170] G. E. Bueno, K. A. Valenzuela, et E. R. Arboleda, « Maturity classification of cacao through spectrogram and convolutional neural network », *J. Teknol. Dan Sist. Komput.*, vol. 8, n° 3, p. 228-233, juill. 2020, doi: 10.14710/jtsiskom.2020.13733.
- [171] J. R. C. P. de Oliveira et R. Ap. F. Romero, « Transfer Learning Based Model for Classification of Cocoa Pods », in *2018 International Joint Conference on Neural Networks (IJCNN)*, Rio de Janeiro: IEEE, juill. 2018, p. 1-6. doi: 10.1109/IJCNN.2018.8489126.
- [172] A. F. Cubillos Bojacá, M. C. García Muñoz, A. M. Calvo Salamanca, G. H. Carvajal Rojas, et M. P. Tarazona-Díaz, « Study of the physical and chemical changes during the maturation of three cocoa clones, EET8, CCN51, and ICS60 », *J. Sci. Food Agric.*, vol. 99, n° 13, p. 5910-5917, oct. 2019, doi: 10.1002/jsfa.9882.
- [173] A. Ma, A. Filippi, Z. Wang, et Z. Yin, « Hyperspectral Image Classification Using Similarity Measurements-Based Deep Recurrent Neural Networks », *Remote Sens.*, vol. 11, n° 2, p. 194, janv. 2019, doi: 10.3390/rs11020194.
- [174] S. Hakak, M. Alazab, S. Khan, T. R. Gadekallu, P. K. R. Maddikunta, et W. Z. Khan, « An ensemble machine learning approach through effective feature extraction to classify fake news », *Future Gener. Comput. Syst.*, vol. 117, p. 47-58, avr. 2021, doi: 10.1016/j.future.2020.11.022.
- [175] P. Forczmański et G. Kukharev, « Comparative analysis of simple facial features extractors », *J. Real-Time Image Process.*, vol. 1, n° 4, p. 239-255, juill. 2007, doi: 10.1007/s11554-007-0030-4.
- [176] A. K. Jean, M. Diarra, B. A. Bakary, G. Pierre, et A. K. Jérôme, « Application based on Hybrid CNN-SVM and PCA-SVM Approaches for Classification of Cocoa Beans », *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, n° 9, 2022, doi: 10.14569/IJACSA.2022.0130927.
- [177] X. Zhang, J. Cui, W. Wang, et C. Lin, « A Study for Texture Feature Extraction of High-Resolution Satellite Images Based on a Direction Measure and Gray Level Co-Occurrence Matrix Fusion Algorithm », *Sensors*, vol. 17, n° 7, Art. n° 7, juill. 2017, doi: 10.3390/s17071474.

- [178] B. Pathak et D. Barooah, « Texture Analysis Based On The Gray-Level Co-Occurrence Matrix Considering Possible Orientations », vol. 2, n° 9.
- [179] A. Kershenbaum et E. C. Garland, « Quantifying similarity in animal vocal sequences: which metric performs best? », *Methods Ecol. Evol.*, vol. 6, n° 12, p. 1452-1461, 2015, doi: 10.1111/2041-210X.12433.
- [180] F. C. Curriero, « On the Use of Non-Euclidean Distance Measures in Geostatistics », *Math. Geol.*, vol. 38, n° 8, p. 907-926, nov. 2006, doi: 10.1007/s11004-006-9055-7.
- [181] D. Edelmann, K. Fokianos, et M. Pitsillou, « An Updated Literature Review of Distance Correlation and Its Applications to Time Series », *Int. Stat. Rev.*, vol. 87, n° 2, p. 237-262, 2019, doi: 10.1111/insr.12294.
- [182] C. Fu, P. Wang, L. Zhao, et X. Wang, « A distance correlation-based Kriging modeling method for high-dimensional problems », *Knowl.-Based Syst.*, vol. 206, p. 106356, oct. 2020, doi: 10.1016/j.knosys.2020.106356.
- [183] R. LANGEHEINE, J. PANNEKOEK, et F. VAN DE POL, « Bootstrapping Goodness-of-Fit Measures in Categorical Data Analysis », *Sociol. Methods Res.*, vol. 24, n° 4, p. 492-516, mai 1996, doi: 10.1177/0049124196024004004.
- [184] D. Teguig, V. Le Nir, et B. Scheers, « Spectrum sensing method based on goodness of fit test using chi-square distribution », *Electron. Lett.*, vol. 50, n° 9, p. 713-715, 2014, doi: 10.1049/el.2014.0302.
- [185] S. Nishisato et J. G. Clavel, « A Note on Between-Set Distances in Dual Scaling and Correspondence Analysis », *Behaviormetrika*, vol. 30, n° 1, p. 87-98, janv. 2003, doi: 10.2333/bhmk.30.87.
- [186] H. Ren, S. Xiao, et H. Zhou, « A Chi-square Distance-based Similarity Measure of Single-valued Neutrosophic Set and Applications », *Int. J. Comput. Commun. Control*, vol. 14, n° 1, p. 78-89, févr. 2019, doi: 10.15837/ijccc.2019.1.3430.
- [187] J. R. C. P. de Oliveira et R. Ap. F. Romero, « Transfer Learning Based Model for Classification of Cocoa Pods », in *2018 International Joint Conference on Neural Networks (IJCNN)*, Rio de Janeiro: IEEE, juill. 2018, p. 1-6. doi: 10.1109/IJCNN.2018.8489126.
- [188] G. E. Bueno, K. A. Valenzuela, et E. R. Arboleda, « Maturity classification of cacao through spectrogram and convolutional neural network », *J. Teknol. Dan Sist. Komput.*, vol. 8, n° 3, p. 228-233, juill. 2020, doi: 10.14710/jtsiskom.2020.13733.

# Table des matières

Dédicace.....	I
Remerciements .....	II
Résumé .....	III
Abstract .....	V
Liste des tableaux .....	VI
Liste de figures.....	VIII
Liste des abréviations.....	XI
Sommaire .....	XII
<b>Introduction générale.....</b>	<b>1</b>
1. Contexte et motivation .....	1
2. Objectif.....	2
3. Contribution .....	2
4. Liste des publications .....	4
5. Organisation de la thèse .....	5
<b>Chapitre 1 : Etat de l'art .....</b>	<b>7</b>
Introduction .....	7
1.1. Intelligence artificielle (IA).....	7
1.1.1. Définition de l'intelligence artificielle.....	7
1.1.2. Histoire de l'IA .....	7
1.1.3. Différentes catégories d'IA.....	8
1.1.4. Applications de l'IA.....	9
1.1.5. Défis et les limites de l'IA .....	10
1.2. Machine Learning (ML).....	10
1.2.1. Définition du machine Learning .....	10
1.2.2. Types d'algorithmes de machine Learning .....	10
1.2.3. Fonctionnement du machine Learning.....	11
1.2.4. Différentes catégories d'algorithmes du machine Learning.....	11
1.3. Deep Learning (DL) .....	12
1.3.1. Définition du Deep Learning.....	12
1.3.2. Différents types de réseaux de neurones profonds.....	12
1.3.3. Différents algorithmes d'apprentissage des réseaux de neurones profonds .....	13
1.4. Café .....	15
1.4.1. Introduction à la culture du café et à ses origines .....	15
1.4.2. Différentes variétés de café .....	15

1.4.3. Production du café.....	16
1.4.4. Différentes maladies du café .....	16
1.4.5. Zones de culture du café.....	17
1.5. Cacao.....	18
1.5.1. Introduction .....	18
1.5.2. Histoire du cacao .....	18
1.5.3. Production du cacao .....	19
1.5.4. Transformation du cacao .....	19
1.6. Production du cacao en Côte d’ivoire.....	20
1.6.1. Introduction .....	20
1.6.2. Régions de production.....	20
1.6.3. Evolution de la production en chiffres de 2010 à 2020.....	21
1.6.4. Impact économique de la production de cacao .....	22
1.6.5. Danger de la production de cacao .....	22
1.7. Espaces couleurs.....	22
1.7.1. Introduction à l'espace couleur en imagerie .....	22
1.7.2. Espaces couleur courants en imagerie.....	23
1.7.3. Conversion entre différents espaces couleur .....	25
1.7.4. Utilisation de l'espace couleur dans les algorithmes de traitement d'image.....	26
1.8. Imagerie numérique dans le domaine de l’agriculture .....	27
1.8.1. Généralité .....	27
1.8.2. Imagerie aérienne .....	28
1.8.3. Imagerie satellitaire .....	28
1.8.4. Imagerie multispectrale .....	29
1.8.5. Imagerie thermique .....	30
1.8.6. Utilisation de l’imagerie numérique.....	31
Conclusion.....	32
<b>Chapitre 2 : Classification et reconnaissance des maladies des feuilles de café à l’aide des algorithmes du Machine Learning et du Deep Learning.....</b>	<b>33</b>
Introduction .....	33
2.1. Généralités.....	33
2.2. Jeu de données.....	35
2.3. Algorithmes d’apprentissage automatique .....	36
2.3.1. Apprentissage supervisé .....	37
2.3.2. L’apprentissage non supervise .....	37

2.3.3. Apprentissage par renforcement.....	37
2.3.4. Support Vector Machine (SVM).....	37
2.3.5. K-nearest neighbors (K-NN).....	38
2.3.6. Random Forest (RF).....	39
2.3.7. Régression Logistique (LR).....	39
2.3.8. Multi-layer Perceptron Classifier (MLP).....	40
2.3.9. Decision Tree Classifier (DTC).....	40
2.3.10. Gaussian Naive Bayes (GNB).....	41
2.4. Algorithmes de réseaux de neurones convolutifs (CNN).....	42
2.4.1. MobileNet.....	43
2.4.2. VGG-19.....	44
2.4.3. Inception-V3.....	45
2.4.4. DenseNet-201.....	45
2.4.5. ResNet-50.....	46
2.4.6. CNN personnalisé proposé.....	47
2.5. Méthodologie de l'étude.....	47
2.6. Paramétrage.....	48
2.6.1. Algorithmes d'apprentissage automatique.....	48
2.6.2. Algorithmes de réseaux de neurones convolutifs (CNN).....	49
2.6.3. Métrique d'évaluation.....	49
2.7. Résultats expérimentaux.....	50
2.7.1. Scénario 1 : Algorithmes d'apprentissage automatique.....	50
2.7.2. Scénario 2 : Algorithmes de réseaux de neurones convolutifs.....	54
2.7.3. Evaluation des algorithmes à l'aide des métriques.....	56
Conclusion.....	58
<b>Chapitre 3 : Mise en place d'une base de données d'images de cabosses et de fèves de cacao.....</b>	<b>59</b>
Introduction.....	59
3.1. Base de données d'images couleur sur le cacao.....	59
3.1.1. Cabosses de cacao.....	59
3.1.2. Fèves de cacao.....	67
3.2. Base de données d'images multispectrales.....	69
3.2.1. Cabosse de cacao.....	69
3.2.2. Fèves de cacao.....	72
Conclusion.....	83

<b>Chapitre 4 : Détection et extraction des cabosses de cacao en milieu naturel avec des méthodes de Deep Learning .....</b>	<b>84</b>
Introduction .....	84
4.1. Généralités.....	84
4.2. Collecte et annotation des jeux de données.....	86
4.3. Algorithme de U-NET.....	87
4.4. Algorithme de Fully Convolutional Network (FCN).....	88
4.5. Méthodologie de l'étude.....	89
4.6. Résultats expérimentaux .....	90
4.6.1. Etape d'apprentissage et de validation .....	91
4.6.2. Etape de test .....	93
Conclusion.....	95
<b>Chapitre 5 : Classification des fèves de cacao par couplage de méthodes .....</b>	<b>96</b>
Introduction .....	96
5.1. Généralités.....	96
5.2. Jeu de données.....	98
5.3. Extraction de caractéristique .....	101
5.4. Classification .....	102
5.4.1. Classifieur Softmax .....	103
5.4.2. Classifieur SVM.....	105
5.5. Méthodologie de l'étude.....	105
5.6. Résultats expérimentaux .....	106
5.6.1. Cas du CNN et Softmax .....	106
5.6.2. Cas du SVM .....	108
5.6.3. Cas du CNN et SVM.....	110
5.6.4. Cas du PCA et SVM.....	112
5.6.5. Comparaison des différentes méthodes.....	114
5.6.6. Comparaison avec d'autres travaux .....	115
Conclusion.....	116
<b>Chapitre 6 : Détermination de la maturité des cabosses de cacao.....</b>	<b>117</b>
Introduction .....	117
6.1. Généralités.....	117
6.2. Jeu de données.....	120
6.3. Méthodologie de l'étude.....	121
6.4. Fusion RGB - HSV .....	121



6.5. Résultats expérimentaux .....	122
Conclusion.....	124
<b>Chapitre 7 : Classification de la maturité des cabosses de cacao à l'aide d'outils de similarité sur une base de données d'images : comparaison des extracteurs de caractéristiques et des espaces de couleurs .....</b>	<b>126</b>
Introduction .....	126
7.1. Généralités.....	127
7.2. Jeu de données.....	129
7.3. Extracteurs de caractéristiques .....	130
7.3.1. Gray Level Co-Occurrence Matrix (GLCM) .....	131
7.3.2. MobileNet.....	133
7.4. Outils de mesure de similarité.....	134
7.4.1. Distance Euclidienne.....	135
7.4.2. Distance de corrélation.....	135
7.4.3. Distance du chi carré .....	136
7.5. Architecture de la méthodologie.....	136
7.6. Résultats expérimentaux.....	137
7.6.1. RGB.....	138
7.6.2. HSV .....	141
7.6.3. Luv .....	143
7.6.4. Lab.....	146
7.7. Influence des espaces couleurs .....	149
7.8. Comparaison avec les méthodes existantes .....	150
Conclusion.....	152
<b>Conclusion et perspectives.....</b>	<b>153</b>
<b>Références Bibliographiques .....</b>	<b>155</b>
<b>Table des matières .....</b>	<b>173</b>

**Titre :** Système d'aide pour améliorer la qualité des récoltes de café et du cacao à l'aide de l'intelligence artificielle

**Mots clés :** Machine Learning ; Deep Learning ; Cacao ; Café ; Espaces couleurs ; Agriculture intelligente.

**Résumé :** Cette thèse propose six contributions importantes dans le domaine de l'analyse de données pour les cultures de café et de cacao. Premièrement, une méthode de classification et de reconnaissance de maladies des feuilles de café a été développée en utilisant des techniques de Machine Learning et de Deep Learning. Deuxièmement, des bases de données dédiées au cacao ont été créées, comprenant des images couleur et multispectrales du cacao. Troisièmement, des techniques de Deep Learning ont été utilisées pour détecter et extraire les cabosses de cacao en milieu naturel. Quatrièmement, une méthode hybride a été proposée pour classer les fèves de cacao en fonction de leur degré de fermentation.

Cinquièmement, une méthode de fusion des espaces de couleur a été développée pour déterminer l'état de maturité des cabosses de cacao. Enfin, une autre méthode pour classifier la maturité des cabosses de cacao à partir d'une base de données d'images a été développée en utilisant des extracteurs de caractéristiques basés sur la texture et sur le Deep Learning. En conclusion, ces contributions ont permis d'utiliser les techniques les plus avancées de Machine Learning et de Deep Learning pour analyser et comprendre les cultures de café et de cacao, facilitant ainsi la prise de décisions pour les producteurs de ces cultures.

**Title:** A support system to Improve the Quality of Coffee and Cocoa harvests using Artificial Intelligence

**Keywords:** Machine Learning, Deep Learning, Cocoa, Coffee, Color space, Smart Agriculture.

**Abstract:** This thesis proposes six essential contributions to the field of data analysis for coffee and cocoa crops. First, a method for classifying and recognizing coffee leaf diseases was developed using Machine Learning and Deep Learning techniques. Second, databases dedicated to cocoa have been created, including color and multispectral images of cocoa. Third, Deep Learning techniques were used to detect and extract cocoa pods in the wild. Fourth, a hybrid method has been proposed to classify cocoa beans according to their degree of fermentation.

Fifth, a color space fusion method was developed to determine the ripeness status of cocoa pods. Finally, another method to classify the maturity of cocoa pods from an image database was developed using texture-based feature extractors and Deep Learning. In conclusion, these contributions have made it possible to use the most advanced techniques of Machine Learning and Deep Learning to analyze and understand coffee and cocoa crops, thus facilitating decision-making for the producers of these crops.