



HAL
open science

Imagerie couleur et hyperspectrale pour la détection et la caractérisation des maladies du bois de la vigne

Florian Rancon

► **To cite this version:**

Florian Rancon. Imagerie couleur et hyperspectrale pour la détection et la caractérisation des maladies du bois de la vigne. Autre. Université de Bordeaux, 2019. Français. NNT : 2019BORD0009 . tel-03140819

HAL Id: tel-03140819

<https://theses.hal.science/tel-03140819>

Submitted on 14 Feb 2021

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.

THÈSE PRÉSENTÉE
POUR OBTENIR LE GRADE DE
DOCTEUR DE
L'UNIVERSITÉ DE BORDEAUX

ÉCOLE DOCTORALE SCIENCES PHYSIQUES ET DE L'INGENIEUR
SPÉCIALITÉ : AUTOMATIQUE, PRODUCTIQUE, SIGNAL ET IMAGE, INGENIERIE
COGNITIVE

Par Florian RANÇON

**IMAGERIE COULEUR ET HYPERSPECTRALE POUR LA
 DÉTECTION ET LA CARACTÉRISATION DES MALADIES DU
 BOIS DE LA VIGNE**

Sous la direction de : Christian GERMAIN
(co-encadrant: Lionel BOMBRUN)

Soutenue le 13/02/2019

Membres du jury :

| | | |
|-----------------------|--|--------------------|
| M. ROUSSEAU, David | Professeur, Université d'Angers | Rapporteur |
| M. MACAIRE, Ludovic | Professeur, Université Lille 1 | Rapporteur |
| M. TISSEYRE, Bruno | Professeur, Montpellier Sup-Agro | Président |
| M. GERMAIN, Christian | Professeur, Bordeaux Sciences Agro | Directeur de thèse |
| M. BOMBRUN, Lionel | Maître de Conférence, Bordeaux Sciences Agro | Co-encadrant |

Titre : Imagerie couleur et hyperspectrale pour la détection et la caractérisation des maladies du bois de la vigne

Résumé :

Les maladies du bois de la vigne sont responsables de pertes économiques importantes pour la filière viticole. Ces maladies d'origine fongique se manifestent notamment par une dégradation de la partie boisée du matériel végétal et par l'apparition erratique de symptômes caractéristiques sur la partie foliaire. Cette thèse est dédiée à l'étude de ces maladies (principalement l'esca) à l'aide de deux capteurs imageurs en proxidtection.

La question de la détection des symptômes visibles est tout d'abord abordée à l'aide d'un capteur couleur RVB permettant d'acquérir une image par pied de manière automatique ou semi-automatique. La reconnaissance des symptômes est abordée en deux étapes, d'abord en considérant la classification à l'échelle de la feuille puis la détection à l'échelle du pied. La particularité de cette étude est l'inclusion de facteurs confondants dans le problème de classification, tirant partie de l'information de forme des symptômes de l'esca pour les différencier d'autres troubles et maladies. Dans ce but, une comparaison entre approches SIFT et approches *transfer learning* récentes est alors conduite. Les résultats nous poussent alors à considérer une architecture *deep learning* simple (RetinaNet) pour la détection des symptômes sur les images, permettant d'estimer un niveau d'atteinte pour chaque pied.

Le second capteur utilisé, une caméra hyperspectrale couvrant le spectre de 500 nm à 1300 nm, tente de répondre à une problématique plus expérimentale, à savoir le comportement spectral des pieds atteints par la maladie pouvant déboucher sur une détection précoce des pieds malades mais sans symptômes foliaires. Un protocole expérimental et une base de données de spectres sont alors constitués pour l'occasion. Les méthodes de réduction de la dimensionnalité permettent d'exploiter l'information hyperspectrale voire d'isoler les longueurs d'onde associées à chacune des deux classes. Les données ne permettent cependant pas, pour la plage de longueur d'onde mesurée et dans les conditions d'acquisition terrain, de réaliser une détection précoce de la maladie sur les pieds sans symptômes.

Les différences et similarités entre chacune de ces deux applications, en terme de constitution de base de données, d'algorithmes, de difficultés et de potentiel d'application en conditions réelles sont discutées tout au long du manuscrit.

Mots clés : Maladies du Bois de la Vigne, MBV, esca, BDA, SIFT, deep learning, imagerie couleur, imagerie hyperspectrale

Title : Color and hyperspectral imagery for detection and characterisation of grapevine wood diseases

Abstract :

Grapevine wood diseases in the vineyard are responsible for significant economic losses in the wine industry. These diseases of fungal origin are characterised by a degradation of the wooded part of the plant material and by the erratic appearance of characteristic symptoms on the leaf part. This thesis is dedicated to the study of these diseases (mainly esca disease) using two imaging sensors and proximal sensing.

The issue of visible symptom detection is first addressed using an RGB color sensor to acquire an image for each plant automatically or semi-automatically. The recognition of symptoms is approached in two stages, firstly by considering the classification at leaf-scale and then the detection at the plant-scale. The particularity of this study is the inclusion of confounding factors in the classification problem, taking advantage of the shape information of esca symptoms to differentiate them from other disorders and diseases. For this purpose, a comparison between SIFT approaches and recent transfer learning approaches is then conducted. The results then lead us to consider a simple deep learning architecture (RetinaNet) for the detection of the symptoms on the images, making it possible to estimate a level of disease severity for each vineplant.

The second sensor used, a hyperspectral camera covering the spectrum from 500 nm to 1300 nm, tries to tackle a more experimental problem, namely the spectral behavior of the diseased plants which may lead to early detection of diseased plants without foliar symptoms. An experimental protocol and a database of spectra are then formed for the occasion. The dimensionality reduction methods make it possible to exploit the hyperspectral information or even to isolate the wavelengths associated with each class. However, the data do not allow, for the measured wavelength range and in the field acquisition conditions, to perform early detection of the disease on the plant without symptoms.

The differences and similarities between each of these two applications, in terms of database constitution, algorithms, difficulties and application potential in real conditions are discussed throughout the manuscript.

Keywords : Grapevine Wood Disease, esca, BDA, SIFT, deep learning, color imaging, hyperspectral imaging

Unité de recherche

Laboratoire IMS UMR 5218 - Bâtiment A31, 351 Cours de la Libération, 33400 Talence

REMERCIEMENTS

Un grand merci à mes deux encadrants Lionel et Christian pour leur support durant ces trois années de thèse. Vous avez été tous les deux à votre manière une grande source d'enrichissement pour moi.

Merci aussi à ceux que j'ai pu côtoyer au quotidien dans le laboratoire, en particulier :

- Barna
- Florent
- Gary
- Benjamin
- Ouiame
- Mireille
- Marco
- Jean-Marie
- Brendan
- Les pensionnaires passés et actuels du bureau : Roxana, Ioana, Olivier, Samy, Anaïs, Andreia et Sarah pour avoir rythmé mes journées de travail.

Et bien sûr un grand merci à mes parents, mon frère Lionel, mon oncle Philippe, mes grand-parents et toute ma famille pour avoir toujours été une famille simple mais aimante.

PUBLICATIONS

En accord avec les conditions de confidentialité du projet, les communications suivantes ont été réalisées durant la thèse.

Reuves à comité de lecture

- *Spatial pattern analysis of flavescence dorée repartition in vineyards from the Bordeaux region* - Journal of Agricultural Informatics (paru, 2017 Vol. 8 No.2 :1-11 ISSN 2061-862X)
- *Comparison of SIFT encoded and Deep Learning features for the classification and detection of esca disease in Bordeaux vineyards* - Remote Sensing (paru, 2019 Vol. 1 No.1 :1)

Conférences et communications orales

- *Flavescence dorée repartition in Bordeaux vineyards : a distance histogram divergence approach* - Conférence EFITA 2017 (Montpellier) - Poster et résumé étendu
- *Détection de l'esca de la vigne par imagerie couleur* - ESA Connect 2018 (Angers) - Communication orale

TABLE DES MATIÈRES

| | | |
|-----|---|-----|
| 1 | INTRODUCTION | 1 |
| 1.1 | Contexte et objectifs de la thèse | 1 |
| 1.2 | Intégration de la thèse au projet Advantage | 1 |
| 1.3 | Déroulement du manuscrit et contributions | 2 |
| I | ÉTAT DE L'ART ET PRÉSENTATION DES PARCELLES | 5 |
| 2 | LES MALADIES DU BOIS DE LA VIGNE : ÉTAT DE L'ART ET MOYENS DE LUTTE | 6 |
| 2.1 | Historique de la maladie | 6 |
| 2.2 | Mode d'action | 9 |
| 2.3 | Description des symptômes | 12 |
| 2.4 | Facteurs de variabilité et impact de la maladie | 17 |
| 2.5 | Résumé des propriétés de la maladie | 18 |
| 2.6 | Inventaire des leviers d'actions | 19 |
| 2.7 | Motivation des choix méthodologiques et expérimentaux | 33 |
| 3 | PRÉSENTATION DES PARCELLES DE L'ÉTUDE | 37 |
| 3.1 | Description des parcelles et notations terrain | 37 |
| 3.2 | Prévalence des symptômes à la parcelle | 38 |
| 3.3 | Evolution temporelle | 39 |
| 3.4 | Répartition des symptômes | 42 |
| 3.5 | Conclusions | 42 |
| II | CLASSIFICATION ET DÉTECTION DES SYMPTÔMES FOLIAIRES DE L'ESCA PAR IMAGERIE RVB | 43 |
| 4 | DÉTECTION DE SYMPTOMES VISIBLES : ETAT DE L'ART ET PROTOCOLE EX- PÉRIMENTAL | 44 |
| 4.1 | Problématiques | 44 |
| 4.2 | Applications existantes en imagerie RVB | 45 |
| 4.3 | Protocole expérimental | 53 |
| 4.4 | Détermination des classes | 59 |
| 4.5 | Détail des classes d'intérêt | 61 |
| 4.6 | Choix des approches méthodologiques abordées au chapitre 5 | 65 |
| 5 | CLASSIFICATION DES SYMPTOMES VISIBLES DE L'ESCA : COMPARAISON DES MÉTHODES D'ENCODAGE SIFT ET DES MÉTHODES DEEP LEARNING | 67 |
| 5.1 | Méthodologie de comparaison | 67 |
| 5.2 | Expérimentations descripteurs SIFT | 70 |
| 5.3 | Approches Transfer Learning | 92 |
| 5.4 | Résumé : Comparaison entre les deux approches | 104 |
| 6 | DÉTECTION DES SYMPTOMES VISIBLES À L'ÉCHELLE DE LA PLANTE | 106 |
| 6.1 | Introduction | 106 |
| 6.2 | Paramètres de l'expérience | 111 |
| 6.3 | Résultats détection | 114 |
| 6.4 | Conclusions et perspectives | 128 |

| | | |
|------------|--|------------|
| III | ETUDE DES SYMPTÔMES DE L'ESCA PAR IMAGERIE HYPERSPECTRALE | 131 |
| 7 | APPLICATION DE L'IMAGERIE HYPERSPECTRALE : ETAT DE L'ART ET PROTOCOLE EXPÉRIMENTAL | 132 |
| 7.1 | Problématique | 132 |
| 7.2 | Exemples d'applications en agriculture | 133 |
| 7.3 | Problématiques méthodologiques associées à l'imagerie hyperspectrale | 135 |
| 7.4 | Définition du problème de classification | 139 |
| 7.5 | Protocole expérimental | 139 |
| 7.6 | Choix des classes et étiquetage | 144 |
| 7.7 | Redondance de l'information et influence de la résolution spectrale | 148 |
| 7.8 | Lissage spectral des données | 149 |
| 7.9 | Première correction radiométrique par la référence | 150 |
| 7.10 | Seconde correction des spectres | 151 |
| 7.11 | Conclusions | 154 |
| 8 | EXPLOITATION DES DONNÉES HYPERSPECTRALES DE LA BASE VIGNE | 155 |
| 8.1 | Méthodologie d'évaluation des performances | 156 |
| 8.2 | Performances avec le jeu de données entier | 157 |
| 8.3 | Performances avec bandes individuelles | 158 |
| 8.4 | Panorama des méthodes de réduction de la dimension | 160 |
| 8.5 | Transformation dans un nouvel espace | 161 |
| 8.6 | Sélection de bandes | 165 |
| 8.7 | Conclusions de la partie | 173 |
| IV | CONCLUSIONS ET PERSPECTIVES | 176 |
| 9 | CONCLUSIONS ET PERSPECTIVES | 177 |
| 9.1 | Conclusions sur les résultats | 177 |
| 9.2 | Considérations sur une potentielle application industrielle | 179 |
| 9.3 | Perspectives | 180 |
| V | ANNEXES | 202 |
| A | PUBLICATION ANALYSE DE LA RÉPARTITION DE LA FLAVESCENCE DORÉE | 203 |
| B | DISTANCES ET SIMILARITÉS UTILISÉES | 215 |
| C | MATRICE DE CONFUSION, COURBES ROC ET RP | 216 |
| C.1 | Matrice de confusion | 216 |
| C.2 | Courbes ROC | 217 |
| C.3 | Courbes RP | 218 |
| D | INDICES DE VÉGÉTATION | 220 |

ACRONYMES

ACP Analyse en Composantes Principales
AP Average Precision
AUC Aire sous la courbe
BDA Black Dead Arm
BRDF Bidirectional Reflectance Distribution Function
CN Compte Numérique
CNN Convolutional Neural Network
CYM Cyan Yellow Magenta
EM Expectation Maximization
FN Faux Négatif
FP Faux Positif
FUI Fond Unique Interministériel
FV Fisher Vectors
IFV Institut Français de la Vigne et du Vin
IMS Intégration du Matériau au Système
IoU Intersection of Union
IRM Imagerie par Résonance Magnétique
IV Indice de Végétation
KL Kullback-Leibler
LAI Leaf Area Index
LDA Analyse Discriminante Linéaire
MBV Maladies du Bois de la Vigne
MSC Multiplicative Scatter Correction
NDVI Normalized Difference Vegetation Index
OA Overall Accuracy
PCR Amplification en Chaîne par Polymérase
PIR Proche Infra-Rouge
RBF Radial Basis Function
ROC Receiver Operating Characteristic
RP Rappel Précision
RS Remote Sensing
RVB Rouge Vert Bleu
SAM Spectral Angle Mapper

SG Savitzky-Golay
SIFT Scale Invariant Feature Transform
SNV Standard Normal Variate
SVM Support Vector Machine
SWIR Short Wave Infra-Red
t-SNE t-distributed Stochastic Neighbor Embedding
TSV Teinte Saturation Valeur
UAV Unmanned Aerial Vehicle
ULM Ultra Léger Motorisé
VN Vrai Négatif
VP Vrai Positif

INTRODUCTION

1.1 CONTEXTE ET OBJECTIFS DE LA THÈSE

Ces travaux de thèse ayant été réalisés au sein du laboratoire IMS de l'université de Bordeaux ont pour contexte le problème viticole des Maladies du Bois de la Vigne (MBV), à savoir l'esca, le Black Dead Arm (BDA) et dans une moindre mesure l'eutypiose. Ces maladies fongiques lentes peuvent provoquer à terme la mort du cep, parfois de façon soudaine. Les pertes économiques importantes dues à la baisse de rendement et aux remplacements des pieds vont croissantes depuis l'interdiction en début de siècle de l'arsénite de sodium, seul traitement efficace contre les MBV. En contrepartie, il existe un moyen préventif sous la forme du traitement *Esquive WP* mais son efficacité n'empêche pas la présence des MBV dans les vignobles (efficacité rapportée d'environ 20%). La filière est donc à la recherche de nouveaux moyens de lutte en addition aux méthodes prophylactiques déjà connues depuis longtemps par les viticulteurs.

Dans un contexte où les technologies de l'information et de la communication deviennent prépondérantes en agriculture, cette thèse considère l'imagerie comme un outil innovant permettant de détecter les symptômes foliaires de la maladie au champ de façon automatisée, si possible de façon précoce. Plus particulièrement, l'imagerie en proxidtection (passage du capteur dans les rangs de vigne) est ici vue avec un intérêt particulier.

1.2 INTÉGRATION DE LA THÈSE AU PROJET ADVANTAGE

Cette thèse est directement intégrée au projet ADVANTAGE¹, piloté par Vegepolys/Agri Sud-Ouest Innovation et avec le support financier d'un Fond Unique Interministériel (FUI) et de la région Nouvelle Aquitaine. Ce projet à l'échelle du territoire français a pour objectif de fournir des solutions de lutte à la filière viticole contre les menaces des maladies du bois de la vigne. L'idée du projet ADVANTAGE est donc d'étudier sur 4 ans la conception de moyens intégrés, de la pépinière à la parcelle, afin d'assurer le contrôle et la prévention des maladies du bois de la vigne. Le projet intègre des parcelles viticoles françaises réparties principalement dans la région de Bordeaux et de la Bourgogne.

1.2.1 Apport du laboratoire IMS

Le laboratoire de l'Intégration du Matériau au Système (IMS) apporte au projet et à la thèse son expertise en terme d'analyse d'image. Le groupe Signal et Image se concentre ainsi sur le développement d'aspects méthodologiques génériques, qui sont ensuite amenés à servir des applications spécifiques. Parmi les applications abordées, on citera la

1. <https://www.maladie-du-bois-vigne.fr/Programmes-de-recherche/Les-projets-en-cours/Les-projets-de-biocontrôle/Projet-ADVANTAGE>

téledétection pour la vigne, les parcs à huître et la forêt ou la proxidétection pour la vigne ou les cultures basses. Dans le cadre du projet, le but est d'utiliser cette expertise en traitement d'image pour extraire l'information pertinente d'images de pieds de vignes malades. Le laboratoire possède de même plusieurs capteurs imageurs pouvant être utilisés dans un protocole de terrain adapté à la vigne, ce qui permet d'assurer l'intégralité du processus d'acquisition. Le but est ainsi de réaliser l'interface entre problématiques agricoles de terrain et problématiques méthodologiques. Cette orientation se retrouve notamment dans les liens avec l'école d'ingénieurs agronomes de Bordeaux (Bordeaux Sciences Agro) pour la recherche et l'enseignement.

1.2.2 Partenaires

Le laboratoire IMS est associé à plusieurs partenaires au sein du projet, dont les rôles sont détaillés dans le tableau 1.1.

Tableau 1.1 – Détail des différents partenaires au sein du projet ADVANTAGE

| <i>Nom</i> | <i>Rôle</i> |
|----------------------------|---|
| <i>Telespazio</i> | Téledétection, imagerie satellitaire/drone, traitement d'image |
| <i>Agrauxine</i> | Mise à disposition de parcelles, élaboration de solutions au champ |
| <i>IFV</i> | Mise à disposition de parcelles, transfert des connaissances vers le vignoble |
| <i>Mercier</i> | Applications au stade pépinière, traçabilité des plants |
| <i>Cybeletech</i> | Modélisation du comportement de la plante |
| <i>Bayer CropScience</i> | Mise à disposition de parcelles, élaboration de solutions au champ |
| <i>INRA-UMR SAVE</i> | Expertise sur les MBV, criblage de solutions candidates |
| <i>Université de Reims</i> | Expertise sur les MBV, criblage de solutions candidates |

1.3 DÉROULEMENT DU MANUSCRIT ET CONTRIBUTIONS

Durant la thèse, deux questions ont été abordées : l'imagerie Rouge Vert Bleu (RVB) pour la détection des symptômes visibles des maladies et l'imagerie hyperspectrale pour l'étude d'une potentielle détection précoce. La principale contribution de ces travaux est l'articulation d'éléments méthodologiques issus de l'état de l'art afin de répondre à un problème agricole concret.

Dans un premier temps, le [chapitre 2](#) est dédié à la constitution d'un état de l'art étendu sur la connaissance des Maladies du Bois de la Vigne (MBV) ainsi que sur les moyens de lutte mobilisables pour la filière. Les observations réalisées durant ce chapitre justifient alors la mise en place de deux protocoles d'acquisition utilisant respectivement l'imagerie couleur et hyperspectrale. Le [chapitre 3](#) décrit ensuite rapidement les parcelles expérimentales dans le bordelais. Elles seront utilisées pour les deux applications.

L'apport de l'imagerie couleur est abordé lors des chapitres [4](#) à [6](#). Un état de l'art plus approfondi sur l'utilisation de l'imagerie visible en agriculture et les différents algorithmes de traitement d'image utilisables est d'abord réalisé dans le [chapitre 4](#). Ce

chapitre définit également le protocole expérimental et la base de données d'images obtenue avec le capteur RVB. Le [chapitre 5](#) apporte une contribution sous la forme **d'une étude comparative des performances de classification de feuilles à l'aide d'approches d'encodage de descripteurs SIFT et d'approches réseaux de neurones convolutifs**. Sa particularité est de prendre en compte les autres symptômes (facteurs confondants de l'esca) dans le problème de classification. Enfin, le [chapitre 6](#) généralise les algorithmes de classification à l'échelle de la feuille en une architecture permettant de **détecter les symptômes d'esca à l'échelle de la plante, ouvrant ainsi la voie une solution originale pour la cartographie des MBV par proxidétection**.

L'apport de l'imagerie hyperspectrale est quant à lui abordé lors du [chapitre 7](#) et du [chapitre 8](#). Le [chapitre 7](#) propose un état de l'art sur les applications hyperspectrales en agriculture ainsi que sur les méthodes d'exploitation de la donnée (corrections, réduction de dimensionnalité). Un protocole d'acquisition est là aussi proposé, permettant de constituer une base de spectres dédiée à l'étude des symptômes visibles et des symptômes précoces. Le [chapitre 8](#) est alors consacré à l'exploitation de ces données, et propose une comparaison de plusieurs méthodes de réduction de la dimensionnalité. Cela aboutit à **la détermination des longueurs d'onde les plus discriminantes (par rapport aux feuilles saines) dans le cas des symptômes visibles et des organes de la vigne**. Ces travaux permettent de même de **mettre en évidence qu'il paraît peu envisageable d'effectuer une caractérisation précoce des symptômes d'esca à partir seulement d'images hyperspectrales dans la gamme de longueurs d'onde allant de 500nm à 1100nm**.

Enfin une conclusion mettant en perspective tous les aspects abordés durant le manuscrit est proposée dans le [chapitre 9](#).

Première partie

ETAT DE L'ART ET PRÉSENTATION DES PARCELLES

Cette première partie dresse dans le [chapitre 2](#) un panorama étendu sur les connaissances actuelles par rapport aux maladies du bois de la vigne (principalement l'esca) et sur les moyens de lutte mobilisés par la filière (traitement préventifs, prophylaxie, etc). Les caractéristiques particulières des MBV en font un ensemble de maladies difficile à appréhender. Ces difficultés sont à prendre en compte car elles conditionnent la nature des leviers d'action. Parmi ces leviers, l'imagerie (en considérant la chaîne allant du capteur au traitement de l'image) est une solution prometteuse pour la détection précoce ou non des MBV. Bien que peu d'applications de ce type existent dans le cas de l'esca, il est possible de s'inspirer de nombreuses autres applications dans le cadre de la viticulture ou de l'agriculture en général pour concevoir des applications spécifiques à l'esca. Le projet Advantage fournit ici comme terrain d'étude un ensemble de parcelles dans le vignoble bordelais. Une présentation rapide de ces parcelles et des notations sanitaires réalisées est décrite dans le [chapitre 3](#)

LES MALADIES DU BOIS DE LA VIGNE : ÉTAT DE L'ART ET MOYENS DE LUTTE

Sommaire

| | | |
|-------|--|----|
| 2.1 | Historique de la maladie | 6 |
| 2.2 | Mode d'action | 9 |
| 2.3 | Description des symptômes | 12 |
| 2.3.1 | Symptômes sur bois | 12 |
| 2.3.2 | Symptômes sur fruits | 12 |
| 2.3.3 | Symptômes sur les feuilles | 12 |
| 2.4 | Facteurs de variabilité et impact de la maladie | 17 |
| 2.4.1 | Atteinte géographique de la maladie et influence du cépage | 17 |
| 2.4.2 | Influence de l'environnement et de la parcelle | 18 |
| 2.4.3 | Conséquences liées à l'esca | 18 |
| 2.5 | Résumé des propriétés de la maladie | 18 |
| 2.6 | Inventaire des leviers d'actions | 19 |
| 2.6.1 | Prévention | 19 |
| 2.6.2 | Intervention | 21 |
| 2.6.3 | Détection classique | 21 |
| 2.6.4 | Utilisation de la télédétection et de la proxidétection | 22 |
| 2.6.5 | Résumé | 32 |
| 2.7 | Motivation des choix méthodologiques et expérimentaux | 33 |
| 2.7.1 | Le choix de l'approche terrain | 34 |

2.1 HISTORIQUE DE LA MALADIE

Chez les agronomes de jadis, on trouve de nombreuses mentions aux Maladies du Bois de la Vigne (MBV). Leur première description, comme celle de nombreux autres troubles de la vigne, est difficilement retraçable avec précision mais peut être attribuée à l'antiquité où une corrélation entre bois pourri et symptômes sur partie foliaire a été établie. On retrouve de façon plus documentée mention de la maladie dès le XIX^{ème} siècle, avec l'observation d'un trouble physiologique de la vigne lié à une différence importante entre absorption de l'eau par temps humide puis à une évapotranspiration soudaine lors d'un temps chaud et sec. Ce désordre appelé *folletage* entraîne sans délai la mort apoplectique d'un cep [156] qui ne peut reprendre sa croissance la saison suivante. Sa description incluait la présence de symptômes foliaires mais aussi l'existence de nécroses centrales et sectorielles dans le bois du pied, comme le montrent les dessins des figures 2.1 et 2.2. On différenciait aussi clairement les symptômes sur cépages blancs des symptômes sur cépages rouges.

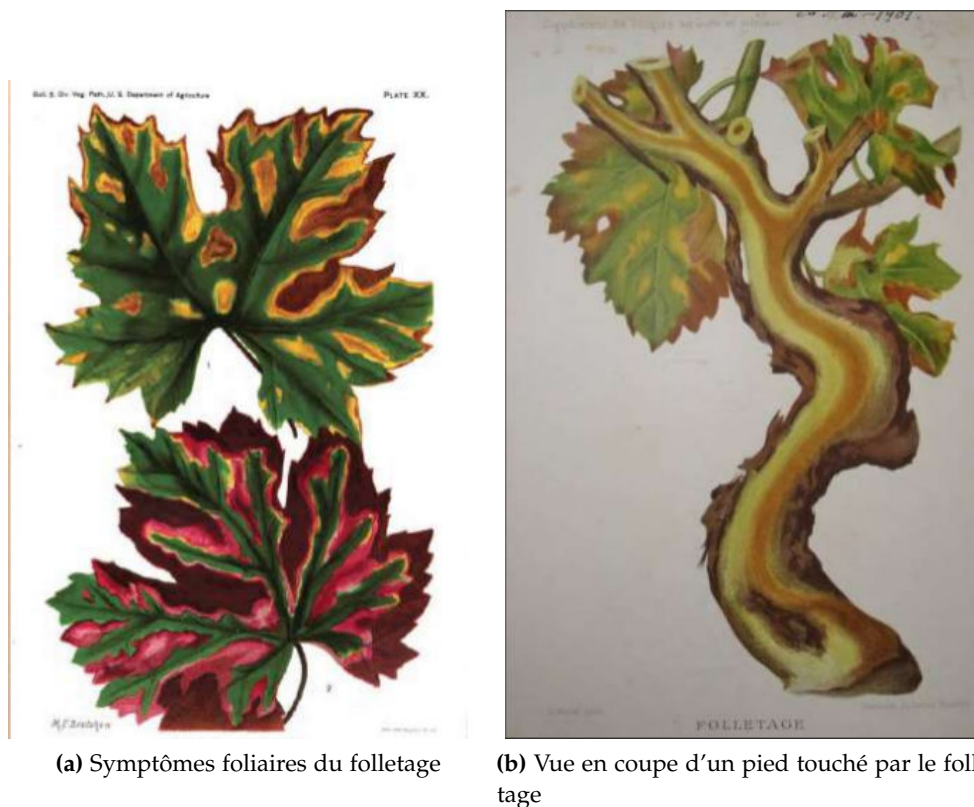


Figure 2.1 – Croquis d'observation du folletage dans les vignobles de la fin du XIX^{ème} siècle. (a) - Dessin de M.F. Bradshaw dans [143]. (b) - Dessin de J.L. Goffart dans [156]

La mise en évidence de pourriture blanche ou brune au sein du bois a permis rapidement de rapprocher ce trouble des maladies cryptogamiques, en le séparant nettement du folletage. On donna le nom d'*esca* à cette maladie, terme languedocien hérité du latin. D'autres maladies similaires ont également été séparées des observations de l'époque, notamment le virus d'enroulement de la vigne.



(a) Symptômes foliaires de l'esca

(b) Vue en coupe du bois et pourriture blanche

Figure 2.2 – Croquis d'observation de l'esca dans [195] par H. Boisgontier

Le XX^{ème} siècle vit l'élargissement des connaissances sur l'*esca*, mais aussi des incertitudes sur la nature et les formes de la maladie. On distingua d'abord la forme apoplectique conduisant à la mort subite du cep de la forme lente, en grande partie caractérisée par ses symptômes foliaires : des colorations internervaires donnant à la feuille un aspect "tigré". D'autres maladies connexes connues sous le nom de *Black Dead Arm* (BDA) [99] et *eutypiose* [198] furent alors aussi distinguées. La différence concrète entre esca et BDA est cependant peu évidente et les deux maladies sont souvent confondues de nos jours. Bien que l'*esca* touche principalement des pieds âgés de 10 ans et plus, des formes d'*esca* ont aussi pu être constatées sur des plants jeunes avec des symptômes similaires [52]. De nombreux auteurs ont ainsi tentés de proposer une définition claire des MBV mais les sources de confusion (nature des champignons impliqués, symptômes) restent nombreuses comme résumé dans [186].

Le problème de l'*esca* a trouvé à la fin du XX^{ème} siècle une solution simple sous la forme de l'arsénite de sodium, une solution toxique pour les champignons impliqués dans les MBV [100] qui était appliquée sur les bois viticoles. En 2001, le produit sera progressivement retiré du marché de tous les pays viticoles en raison de son danger évident pour l'homme et l'environnement [182]. L'impasse rencontrée depuis lors a justifié la mise en place de projets de recherche axés sur la prévention (prophylaxie) et la lutte

contre les maladies du bois de la vigne.

Pour plus d'informations un historique complet depuis l'antiquité est documenté par Philippe Larignon dans [98].

2.2 MODE D'ACTION

Les maladies du bois de la vigne, au sens général, sont des maladies cryptogamiques attribuées à plusieurs groupes complexes de champignons. Parmi ceux-là on citera non exhaustivement *Phaeomoniella chlamydospora*, *Phaeocremonium aleophilum*, *Eutypa lata* et *Fomitiporia*. La détermination précise des complexes impliqués dans les différentes maladies du bois peut être floue et dépend en grande partie de paramètres géographiques. La question de l'incidence réelle des champignons semble de même sujette à controverse [74]

Dans le cas de *Phaeomoniella chlamydospora*, un ascomycète présent dans la plupart des vignobles, la colonisation du bois se fait en pénétrant dans les plaies de taille, les zones fellées du bois ou les greffons de pépinières (source d'inoculum critique pour la fourniture de plants sains). La dissémination est aérienne et peut donc être facilitée par temps de pluie. Le développement du champignon peut alors se faire grâce aux pycnides qui assurent la multiplication du champignon dans un environnement humide propice. Le champignon peut être retrouvé dans les sarments mais son origine reste débattue, l'hypothèse principale étant que les spores sont transportés par la sève montante. Le champignon peut aussi subsister longuement dans le sol et être présent dans les racines.

La colonisation du bois est accompagnée de la production d'enzymes et de métabolites, certains ayant un pouvoir toxique sur la plante et sa vigueur. La production de cal peut de même être inhibée par ces composés. *Phaeomoniella chlamydospora* n'est pas un champignon provoquant la formation de cavités dans les parois secondaires, contrairement à *Phaeocremonium aleophilum* qui appartient à la famille des champignons de la pourriture molle. *Eutypa lata* est quand-à lui typiquement associé à l'eutypiose mais fait aussi partie du complexe esca général. Cette colonisation du bois par un complexe de champignons aura à terme pour effet de provoquer des nécroses à l'intérieur des vaisseaux.

La présence de vaisseaux dégradés semble souvent corrélée à la présence de symptômes foliaires, le transport de ces toxines jusqu'aux organes foliaires reste cependant débattu, l'hypothèse principale étant que le transport est réalisé par le flux de transpiration [128]. Certaines études ont tenté de reproduire les symptômes foliaires caractéristiques en inoculant certaines combinaisons de champignon [181] [55]. La reproduction exacte des symptômes de l'esca reste cependant difficile et imprévisible.

A plus ou moins long terme les maladies du bois peuvent provoquer l'affaiblissement ou le dépérissement du cep, on nommera ces deux formes : forme foudroyante (ou apoplectique [128]) et forme lente. Dans le cas le plus sévère (forme foudroyante), la dégradation du bois et de ses vaisseaux empêche l'afflux en eau, qui risque dans certains cas de stress hydrique de ne pas compenser l'évapotranspiration demandée. Toutes les feuilles

et grappes du rameau se dessèchent alors et l'appareil foliaire perd toute capacité de photosynthèse et de production, comme illustré dans la figure 2.3. L'apoplexie pourrait aussi être due à une concentration en toxines élevées dans les feuilles avec un fort taux d'évapotranspiration. Ces changements se font très rapidement, souvent en l'espace de quelques jours, et rendent quasi impossible tout retour de croissance sur la plante, ce qui nécessite un remplacement du pied à terme. D'autres troubles peuvent cependant ressembler à la forme apoplectique de l'esca, tels qu'un fort épisode de sécheresse ou les dégâts causés par un engin agricole.



Figure 2.3 – Apoplexie d'un pied de vigne - Dessèchement total des grappes et des feuilles

Dans l'autre cas (forme lente), la contamination par les Maladies du Bois de la Vigne (MBV) semble avoir un rôle modéré sur le métabolisme de la plante et sur son utilisation des réserves hydriques. D'après [131], les symptômes foliaires sont liés à une baisse de la photosynthèse, elle même corrélée à la diminution de la concentration des pigments chlorophylliens. Le constat peut varier à l'échelle de la plante : certaines zones ou rameaux entiers sont moins touchés par la décoloration et montrent donc des activités photo-synthétiques différentes. Les pieds atteints sont fragilisés et susceptibles de développer moins de réserves pour les années suivantes, ce qui pourrait déboucher à terme sur un épisode apoplectique. Dans [43], l'auteur s'attache à montrer que cette baisse de photosynthèse peut être détectée dans certains cas de façon précoce par mesure de la fluorescence. Il montre aussi que ce signal précoce peut être différencié de celui lié à un stress hydrique classique.

Globalement les étés modérés et pluvieux semblent corrélés à la forme lente (illustrée dans la figure 2.4) tandis que les étés chauds et secs (stress hydrique prononcé) favoriseraient la forme apoplectique. Dans la réalité les deux types peuvent coexister la même année sur une même parcelle. L'apoplexie est cependant dans la plupart des cas plus rare que la forme lente. La mortalité due à la forme apoplectique de l'esca semble cepen-

dant d'après [68] liée à l'expression de symptômes l'année précédente. Cette observation est en accord avec le constat sur les réserves limitées constituées par la plante en cas de forme lente.




Figure 2.4 – Photographies de pieds atteints par une forme lente de l'esca.

L'âge de la plante est un facteur critique dans le développement de la maladie. L'esca touche principalement les plants âgés de 10 ans et plus bien qu'il soit possible de repérer des symptômes d'esca sur des plants de quelques années seulement. Deux hypothèses ont été avancées pour expliquer ce constat. La plus simple est de considérer que le développement de la maladie s'étale sur plusieurs années dans un processus lent et qu'il semble par conséquent moins probable de constater les effets foliaires sur le court et moyen terme. Les pieds jeunes sont donc potentiellement affectés et présentent des nécroses du bois mais ne montrent pas de symptômes foliaires ni de troubles métaboliques. L'autre hypothèse plus exploratoire avancée dans [195] consiste à corréliser le phénomène avec les niveaux de tanins dans la plante qui augmentent typiquement dans un pied de vigne de 12 à 30 ans environ. Il n'a cependant pas été prouvé que cette corrélation était reliée à un véritable lien de cause à effet.

Le plant de vigne développe en réaction à la contamination fongique de nombreux mécanismes de défense destinés en partie à bloquer la progression du champignon. Les mécanismes généraux de défense [144] ou le rôle spécifique des stilbènes dans la protection de plante [97] ont entre autres été étudiés en détail, dans l'espoir que cette connaissance puisse mener à des méthodes de protection des pieds infectés.

L'étude des communautés fongiques impliqués dans les MBV et dans d'autres maladies fongiques est un domaine de recherche complexe dont toutes les clés de compréhension ne sont pas encore acquises [27]. Plus de détails sur le mode d'action des champignons liés aux MBV peuvent être trouvés dans [101].

2.3 DESCRIPTION DES SYMPTÔMES

Avant toute chose, les symptômes de l'esca peuvent être séparés en 3 organes principaux : le bois, les feuilles et les grappes. Le premier ne peut être constaté sans réaliser une coupe du bois (destructif) tandis que les autres peuvent être directement visibles sur le cep. On ne mentionnera ici que les symptômes de la famille esca/BDA, on ne citera donc pas le rabougrissement des sarments qui est un des symptômes connus de l'eutypiose, maladie du bois moins fréquente.

2.3.1 *Symptômes sur bois*

Les symptômes sur le bois sont la conséquence la plus évidente de l'infection mais aussi la moins visible, les dégâts étant internes aux tissus. D'après [95] on peut séparer les nécroses en 8 catégories complexes selon la combinaison de micro-organismes impliqués. Les plus courantes sont une coloration blanche et molle et une coloration brune et dure. Ces colorations peuvent être centrales ou sectorielles dans le bois et accompagnées de ponctuations dans la partie saine du bois. L'intensité des symptômes peut être variable selon la hauteur de coupe dans le bois.



Figure 2.5 – Exemples de coupes de la partie inférieure du bois d'un pied de vigne de 25 ans atteint par les MBV. Source : [128]

2.3.2 *Symptômes sur fruits*

Les symptômes sur les grappes ne sont pas systématiques. Lorsque présents, ils se traduisent par des baies flétries ou par un retard général dans la maturation. Ces symptômes ne sont cependant pas spécifiques à l'esca et peuvent être liés à de nombreux troubles de la vigne. Des taches de couleur marron ou violette peuvent se former sur les grappes sous forme de points voire de bandes [128].

2.3.3 *Symptômes sur les feuilles*

Les symptômes sur feuille sont la manifestation la plus spectaculaire des maladies du bois. Ceux-ci ont été très généralement décrits comme des colorations internervaires tigrées sur une partie des feuilles du pied.

Il est possible de réaliser une nomenclature simple des symptômes esca/BDA typiques. Celle-ci tourne autour de 4 zones de couleur différentes observées sur les feuilles autour des nervures :

- **Dessèchement** => Marron clair ●, orange ● ou gris ●
- **Rougisement** => , rouge vif ●, rouge violet ●
- **Chlorose (Jaunissement)** => jaune vif ● ou pale ●
- **Zone verte** => vert foncé ● ou clair ●

La façon d'assembler ces zones dans un faciès tigré le long des 5 nervures principales et secondaires de la feuille définit le motif esca. Le motif classique comprend souvent la transition ● ↔ ● ↔ ● ↔ ● internervaire (figure 2.6). Les motifs réels sont cependant bien plus subtils et variés que cette description. Le liseré jaune peut par exemple être d'épaisseur variable, tandis que la partie rouge (de couleur vive ou vineuse) peut exister sous forme d'une fine bande ou recouvrir toute la partie externe du limbe (partie pouvant aussi être desséchée dans certains cas).




Figure 2.6 – Exemples de motifs esca aux palettes de couleurs variées. (a)(b) - cépage rouge. (b)(c) - cépage blanc.

Le type de motif dépend d'un grand nombre de paramètres, le plus important étant le type de cépage. Les cépages blancs présentent des symptômes souvent bien distinguables des rouges. Chez les cépages rouges, les symptômes sont souvent décrits comme une décoloration rouge voire violette entourée de tissu nécrotique clair ou marron, avec la présence possible d'un très léger liseré jaune de transition entre la partie verte et la partie rouge. Quant aux cépages blancs, les symptômes sont décrits comme une décoloration principale jaune qui entoure des tissus rougeâtres à nécrotiques. Le liseré jaune y est typiquement plus prononcé que pour les cépages rouges. Par simplification on peut dire que les symptômes en rouge tendent vers des couleurs violet/marron tandis que les cépages blancs tendent vers le jaune/rouge. Ce constat ne se vérifie cependant pas forcément et peut varier selon les cépages.

A cela, on peut ajouter l'hétérogénéité de présence sur la feuille, certaines feuilles étant partiellement touchées ou au contraire partiellement desséchées (figure 2.7).




Figure 2.7 – Feuilles partiellement touchées par symptômes MBV.

L'intensité des symptômes est de même variable, atténuant la structure à 5 branches du symptôme typique jusqu'à aboutir dans certains cas à des motifs circulaires isolés (figure 2.8).




Figure 2.8 – Feuilles faiblement touchées par l'esca

Il est important de mentionner qu'une bonne partie des feuilles esca rencontrées en conditions réelles sont des feuilles partiellement atteintes, parfois avec des symptômes très peu prononcés, s'éloignant alors de la signature caractéristique de la maladie.

L'aspect tigré peut de même s'effacer sur des symptômes BDA précoces (figure 2.9).




Figure 2.9 – Symptômes BDA précoces sans motif tigré. Source des images : [104]

Ce type de symptôme est surtout rencontré en juin et juillet où les symptômes esca sont encore peu présents sur la parcelle et montre que le faciès tigré n'est pas la seule condition permettant de diagnostiquer les maladies du bois. Ici par exemple les symptômes sur cépage rouge commencent à apparaître sous forme de décolorations rouges ou brunes. L'esca n'est cependant pas la seule maladie à présenter des motifs internervaires, ce qui peut rendre la différenciation des symptômes parfois difficiles. De nombreuses formes de carences présentent des symptômes internervaires similaires (figure 2.10), ou simplement le résultat d'un stress hydrique prononcé (rencontré durant l'année 2016 par exemple). Les colorations jaunes internervaires peuvent par exemple provenir d'une carence en magnésium sur cépage blanc. D'autres troubles comme la flavescence dorée, le mildiou, le black rot ou les dégâts d'insecte sont par contre plus facilement différenciables des symptômes esca. La plupart de ces maladies provoquent cependant des symptômes de couleur similaire, à savoir des plages de jaunissement, de rougissement et de tissus nécrosés bruns. La différence réside dans le motif, par exemple la coloration quasi intégrale du limbe (accompagnée d'un enroulement des feuilles) dans le cas de la flavescence dorée.

Plus d'informations et d'exemples d'autres maladies de la vigne provoquant des symptômes foliaires peuvent être trouvés sur le site de l'Institut Français de la Vigne et du Vin (IFV) [80] ou sur l'application Ephytia de l'INRA ¹.



Figure 2.10 – Exemples de carences aux motifs internervaires similaires aux symptômes esca

Il est à noter que les vignes mères de porte-greffe n'ont pas de symptômes connus sur la partie herbacée. Les nécroses du bois sont cependant bien sûr possibles. Enfin les symptômes ne présentent pas de différence notable de teinte entre la face ventrale et la face dorsale des feuilles, l'intensité des couleurs est cependant moins prononcée sur la face dorsale.

2.3.3.1 Evolution des symptômes durant l'été

L'autre paramètre régissant l'expression des symptômes est le moment dans la saison. Les symptômes évoluent avec le temps et la palette de couleurs ou le motif peuvent drastiquement changer. La période de juin à août est ainsi cruciale pour l'expression des

1. <http://ephytia.inra.fr/>

symptômes MBV. Bien que de nombreux cas soient documentés, ces changements ne sont cependant pas prévisibles et il n’y a pas de règle sur l’évolution des symptômes durant l’été, d’autant plus que cela dépend de leur sévérité. Entre autres, il est impossible de prévoir un épisode apoplectique, les symptômes pouvant apparaître puis entraîner la mort du cep de façon soudaine (de l’ordre de quelques jours). Les symptômes ont tendance à s’exprimer avec force durant le mois d’août (pouvant être corrélé à une période de sécheresse) mais de nombreux pieds malades restent sans symptômes visibles durant cette période.

D’après [95] et [104], l’expression des symptômes MBV durant l’été peut être mise en relief par l’expression combinée des symptômes esca et Black Dead Arm (BDA). Une phase transitoire en juillet/août où les symptômes de BDA deviennent progressivement assimilables à des symptômes esca est ainsi mis en évidence.




Figure 2.11 – Exemple d’évolution de la répartition en symptômes MBV dans une parcelle du bordelais de début juin à mi-septembre. Barres noires : Symptômes BDA, Barres blanches : Symptômes Esca, Barres grises : Symptômes doubles, Barres hachurées (au sommet) : Apoplexie. Source : [104] page 9

Bien que de portée limitée (quelques parcelles d’échantillonnage), ces données apportent un regard intéressant sur l’évolution estivale complexe de la maladie et sur la différenciation que l’on fait entre esca et BDA. De cette étude, on peut tirer deux autres interprétations :

- Le nombre de pieds symptomatiques augmente de façon régulière, sans rupture de pente violente, l’évolution de la maladie n’est cependant pas prévisible (profils différents entre parcelles).
- Le nombre de pieds apoplectiques est négligeable sur cette figure mais leur nombre et leur première apparition est variable selon la parcelle (de début juillet à début août environ pour les premiers cas).

On fera le choix dans toutes les expérimentations de ce manuscrit de ne pas distinguer esca et BDA en raison du caractère similaire de ces maladies. On se référera à celles-ci sous le terme MBV (bien que nous n’ayons pas rencontré de symptômes d’eutypiose sur les parcelles) ou esca par abus de langage. Pour d’autres applications, il pourrait cependant être nécessaire de faire la distinction.

Cette incertitude rend le travail de l’expérimentateur mais aussi de l’expert terrain difficile quand il s’agit de réaliser la notation d’une parcelle. Celui-ci a le choix de différencier les symptômes esca des symptômes BDA (la différence n’étant pas forcément évidente),

de différencier la forme lente de la forme apoplectique et de quantifier l'atteinte du pied selon l'intensité des symptômes et la proportion du pied atteinte (par exemple un seul bras ou les deux).

2.4 FACTEURS DE VARIABILITÉ ET IMPACT DE LA MALADIE

2.4.1 Atteinte géographique de la maladie et influence du cépage

Les maladies du bois de la vigne ont été constatées dans tous les pays viticoles du monde où leur incidence est cependant variable [21]. Malgré la variabilité des profils, les recherches locales font unanimement état d'une augmentation de la prévalence aux maladies du bois depuis le début de ce siècle. Dans certains cas extrêmes comme en Autriche, une étude fait état d'une augmentation annuelle du nombre de pieds symptomatiques de 2.7% [160]. En Italie, Surico *et al.* montrent d'importantes différences géographiques mais aussi temporelle dans l'expression des symptômes [187]. Les symptômes de la forme lente semblent aussi être de plus en plus remarqués sur des pieds de moins de 10 ans, par exemple dans les vignobles australiens [52].

En France, un état de l'art historique important existe et les maladies du bois sont particulièrement surveillées depuis l'interdiction de l'arsénite de sodium. Cette volonté de surveillance prend principalement la forme de l'*Observatoire National des Maladies du Bois de la Vigne* consistant en le suivi d'un échantillon de parcelles représentatives de la diversité des vignobles français. Le dispositif a d'abord été appliqué de 2003 à 2008 sur un ensemble de 27 cépages. D'après [67] et [61], environ 10% des pieds suivis sur une période de 5 ans ont présenté au moins une fois des symptômes Maladies du Bois de la Vigne (MBV) et peuvent être considérés comme atteints. L'étude indique de même que 70 à 80% des parcelles sont touchées par le complexe esca-BDA. On notera aussi une forte variabilité inter-régionale voire intra-régionale. Ainsi le Jura présente la plus forte prévalence en France et le Languedoc semble présenter le plus d'intra-variabilité. La région du bordelais y est décrite avec une prévalence environ égale à 2.5%. De façon générale, les symptômes chroniques concernent typiquement environ 5% des pieds qui risquent donc d'être remplacés à moyen terme. Les formes apoplectiques représentent quand-à elles souvent moins de 2% des pieds du vignoble, ceux-ci ont cependant un caractère d'urgence et doivent être remplacés à court terme.

Les mêmes données de l'Observatoire National des Maladies du Bois de la Vigne auront permis de dresser un portrait de la prévalence des symptômes par cépage au début du XXème siècle [67]. On y apprend entre autres que les cépages Cabernet Sauvignon et Sauvignon Blanc (presque 10% de prévalence) sont particulièrement touchés par les MBV. A coté d'autres cépages tels que le Pinot Noir ou le Merlot (moins de 2% de prévalence) semblent relativement plus résistants. Comme mentionné précédemment, il est aussi noté que la prévalence des symptômes peut être trompeuse : si le nombre de pieds exprimant des symptômes reste relativement stable chaque année, la proportion de pieds malades ayant au moins une fois exprimé des symptômes est quand à elle à la hausse. Il est intéressant de noter qu'il ne semble pas exister de cépage totalement résistant aux MBV [186].

2.4.2 *Influence de l'environnement et de la parcelle*

Les différences géographiques d'expression peuvent être expliquées par de nombreux facteurs dont le plus probable semble être le climat. De nombreux climats cohabitent en France (océanique, continental, méditerranéen) et il paraît logique de penser que ces climats sont une des clés expliquant les différences entre régions. Cette hypothèse est à relier avec celle affirmant que que les étés modérés et pluvieux conduisent à l'extériorisation des symptômes foliaires tandis que les étés chauds sont plus aptes à favoriser la forme apoplectique [185]. L'influence de la pluie est étudiée plus en détail dans [119] qui établit une corrélation entre le nombre de pieds symptomatiques et l'intensité des précipitations en début d'été. L'influence du sol et des conditions climatiques est abordée dans [8], cette étude ne met cependant pas en évidence une relation claire entre l'apparition de la forme lente et les paramètres pédoclimatiques de la parcelle. L'influence du réchauffement climatique a aussi été logiquement conjecturée [187]. Il serait aussi intéressant de connaître le comportement de la maladie par rapport à d'autres épisodes climatiques destructeurs comme les périodes de gel ou de grêle pouvant fragiliser les vignes et faciliter l'installation des groupes de champignons associés à la maladie.

Le rôle précis du climat lors de la période estivale reste cependant difficile à déterminer. Il est délicat d'établir des relations entre les facteurs parcellaires ou environnementaux et la prévalence de l'esca. Comme indiqué dans [67], les facteurs cépages et âge de la parcelle semblent les plus significatifs et rendent l'analyse statistique basée sur d'autres paramètres délicate. Il est de même difficile d'obtenir assez de données terrain sur des parcelles suffisamment variées pour pouvoir tirer des conclusions robustes.

2.4.3 *Conséquences liées à l'esca*

La présence de pieds atteints par l'esca n'est pas sans conséquences pour la parcelle. Le dépérissement annuel de pieds malades provoque l'évolution des vignobles vers un peuplement à la fois jeune mais aussi extrêmement hétérogène. Les conséquences en terme de rendement et de qualité du vin peuvent être désastreuses. C'est plus généralement la pérennité du patrimoine viticole qui est mise en danger par la progression des MBV. L'impact économique de ces maladies est cependant difficile à estimer avec précision. Les estimations prennent en compte le coût de remplacement des ceps et les coûts liés à la baisse de rendement mais les problèmes liés au rajeunissement des parcelles et à la baisse de typicité du vin sont beaucoup plus difficiles à prendre en compte dans l'équation. On peut cependant estimer ce coût à environ 1 milliard d'euros par année en France si on utilise les chiffres de superficie viticole indiqués dans [82] et que l'on considère 1% de remplacement par an. Au coût de maintien de l'appareil de production, il faut bien sûr ajouter le coût lié à la recherche et au développement de nouvelles solutions.

2.5 RÉSUMÉ DES PROPRIÉTÉS DE LA MALADIE

D'après cet état de l'art, on peut résumer la maladie en 7 points clé :

- Contamination fongique par les plaies (taille, point de greffe),
- Complexe esca/Black Dead Arm (BDA) difficile à différencier,

- Incubation lente (expression sur pieds > 10 ans) ,
- Inoculation artificielle complexe et sans résultats viables,
- Attaque irréversible des organes pérennes de la vigne,
- Symptômes tigrés plus ou moins caractéristiques sur les feuilles,
- Expression erratique des symptômes chaque année,
- De nombreux facteurs de variabilité (cépages, météo, etc),
- Rajeunissement progressif des parcelles.

Ces points d'importance conditionnent la nature des leviers d'actions mobilisables contre la maladie.

2.6 INVENTAIRE DES LEVIERS D' ACTIONS

On dressera ici une liste des applications possibles pour la lutte ou la prévention des maladies du bois de la vigne. Cette liste nous mènera ensuite à établir le plan d'expérimentation de ce manuscrit en considérant les domaines où le laboratoire IMS peut apporter ses compétences. La façon la plus simple de présenter les leviers d'action est de les classer selon le moment chronologique d'intervention. On distinguera ici 3 objectifs, couvrant la durée de vie entière d'un pied de vigne, de la pépinière à la parcelle. :

- La **prévention** visant à empêcher la contamination des pieds, principalement lors de la production en pépinière.
- La **détection** visant à diagnostiquer la maladie le plus tôt possible.
- L'**intervention** visant à gérer la maladie après son diagnostic. Elle peut aussi inclure le remplacement du cep en question en cas d'apoplexie ou de dégradation des capacités de production trop importante.

2.6.1 Prévention

Le volet de prévention s'applique à la fois en pépinière et à la parcelle. Le rôle difficile du pépiniériste est de fournir en continu des plants sains dont le potentiel d'atteinte aux maladies du bois (et à de nombreuses autres maladies) est idéalement nul. Le seul moyen pratique d'éliminer les mauvaises boutures est de les vérifier une par une en inspectant le point de greffe. Ce tri manuel assure un taux d'échec quasi nul. Un test complet et sûr lié aux maladies du bois demanderait cependant d'examiner l'intérieur des tissus pour y déceler d'éventuelles nécroses et problèmes de greffe qui à terme pourraient mener à une infection des champignons Maladies du Bois de la Vigne (MBV). L'application d'un traitement à l'eau chaude à 50° permet notamment de réduire la présence de certains champignons au sein des tissus jeunes.

Après l'interdiction de l'arsénite de sodium, il a été nécessaire de trouver d'autres solutions préventives au champ pour empêcher la colonisation des champignons dans le bois. Les deux grands axes développés sont les fongicides chimiques (substitut direct à l'arsénite de soude) et les agents biologiques antagonistes du complexe de champignons. Dans les vignobles d'Afrique du sud, Groenewald *et al* étudient l'inhibition de

la croissance du mycelium de *Phaeoconiella chlamydospora* par l'action de 12 fongicides différents et montrent l'efficacité de certains sur une application en faible concentration. Du côté des agents biologiques, on citera entre autres la piste des *trichoderma* [120] dont l'action antagoniste semble inhiber une partie des champignons liés au MBV et améliorer le développement de la masse racinaire. On citera aussi *Pythium oligandrum* [205] un oomycète qui semble induire une baisse du niveau d'expression de gènes associés avec l'infection à *Phaeoconiella chlamydospora*. Leur application peut se faire de manière classique par pulvérisation ou par badigeonnage dans le cas d'un traitement plus spécifique. Il est aussi possible d'injecter le traitement dans la souche. D'autres solutions commerciales telles que le produit Esquive WP existent notamment le commerce, et permettent de diminuer la prévalence de la maladie dans certains cas. A l'heure actuelle de nombreuses pistes sont abordées mais aucune solution commerciale parfaitement viable n'a encore été trouvée.

Les applications d'imagerie pénétrante non destructive ont un potentiel intéressant pour la filière viticole, que l'on parle d'imagerie Imagerie par Résonance Magnétique (IRM), par rayons X ou de TeraHertz. Ces applications constituent une science à part entière et présentent en réalité d'énormes difficultés à surmonter (coût, débit, conditions contrôlées). Au delà de la pépinière et de la sélection de plants, ces technologies innovantes peuvent aussi trouver leur place dans l'étude de l'interaction complexe entre la plante et les pathogènes, comme visé dans le projet VITIMAGE porté par l'Institut Français de la Vigne et du Vin (IFV)². L'enjeu à moyen terme est de savoir si ces technologies en évolution constante peuvent répondre aux besoins particuliers de la filière.

L'autre volet de prévention se range dans la famille des méthodes prophylactiques. Ces méthodes sont un recours naturel pour les vigneron en absence de solution au champ efficace. Reléguées au second rang avant l'interdiction de l'arsénite de soude, celles-ci reviennent naturellement sur le devant de la scène. La mesure la plus évidente couvre l'élimination de tout bois mort (souche ou sarment) au sein de la parcelle, ces matériaux étant bien évidemment un vecteur pour l'installation de l'inoculum près de ceps vivant. La taille de la vigne est aussi pointée du doigt dans l'inoculation des ceps, les plaies de taille sont des portes d'entrée privilégiées. Les plaies près de la souche semblent particulièrement à risque tandis que les plaies de rognage ne le semblent pas. Une taille adaptée doit donc éviter les grosses plaies, ce qui dépendra du matériel, du type de taille et de la vigueur de la vigne. Les périodes de pluie sont aussi à éviter car elles entraînent une propagation plus facile des champignons à cause des chocs mécaniques. De même d'autres opérations de coupe comme l'épamprage provoquent aussi des plaies et doivent être réalisées proprement avec une coupe nette. Parmi les autres idées développées on mentionnera le badigeonnage des plaies (type escudo) pour les protéger ou l'utilisation de sécateurs traitants mais ces traitements ont aussi un coût pour le viticulteur.

La recherche de solutions de prévention face aux maladies du bois a de même motivé des initiatives de *crowd-sourcing* telles que [22] où le génome des pathogènes impliqué

2. <https://www.plan-deperissement-vigne.fr/travaux-de-recherche/programmes-de-recherche/vitimage>

dans les MBV a été rendu public afin de motiver l'effort de recherche autour de la problématique.

2.6.2 Intervention

Les méthodes d'intervention sur un pied atteint tiennent en réalité plus d'une prévention permettant d'éviter le pire, à savoir l'apoplexie et la mort du cep. Il est possible de recéper à condition de sectionner la charpente au dessus du porte greffe et de vérifier l'absence de nécroses. Cette opération peut être réalisée pour n'importe quel pied ayant présenté des symptômes, sa réussite modérée (risque de "rechute", non apparition des gourmands) et son coût en temps la rend cependant rédhitoire. Une autre méthode plus extrême, si aucun tissu au dessus du porte greffe n'est épargné, est de regreffer tout simplement sur le porte greffe. Dans le cas où le recépage n'est envisagé, les pieds apoplectiques ou trop peu productifs seront remplacés par de nouveaux complants qui ne seront pas productifs avant plusieurs années. Le remplacement des pieds doit donc être progressif si on veut éviter le rajeunissement de la parcelle et une diminution drastique des moyens de production.

2.6.3 Détection classique

Le volet détection s'attache à déterminer la présence de la maladie dans une parcelle. La détection peut se faire ainsi sur des pieds symptomatiques (cartographie des symptômes visibles à l'échelle de la parcelle) ou sur des pieds atteints mais sans symptômes foliaires (détection dite précoce). Habituellement la détection se fait soit à l'œil nul (passage dans les parcelles pour notation sanitaire) soit en réalisant une coupe du bois afin de vérifier la présence de dégâts liés aux MBV dans le bois. Ces méthodes ont leur limite, notamment quand il s'agit de cartographier de grandes étendues de vigne ou quand on souhaite détecter la maladie avant l'apparition de symptômes visibles.

Ce questionnement est de manière général très courant en agriculture et l'émergence des nouvelles technologies a conduit les chercheurs et les professions du domaine à considérer de nouvelles applications tirant partie de ces technologies innovantes, bien qu'elles n'aient souvent pas été pensées de base pour l'agriculture (applications militaires, automobile, prospection etc). La question des technologies employées pour la détection des maladies des plantes en général est creusée en détail dans [122] où les auteurs dressent un portrait des applications existantes. Ces techniques ont pour objectif d'être plus rapides que l'homme, non destructives et surtout non subjectives (ce qui est difficile car la machine apprend ses règles selon des données d'apprentissage qui sont apportées par l'homme et donc déjà subjectives).

La détection de pathogènes, bactéries et agents fongiques est historiquement réalisée par des techniques telles que ELISA ou *western blots*. Ces techniques ont principalement servi dans le cas de l'esca à partir des années 80 et ont permis d'isoler les champignons liés à l'esca puis de les relier aux nécroses observées dans le bois. Certaines méthodes sont quant-à elles basées sur l'ADN telles que les variantes de l'Amplification en Chaîne par Polymérase (PCR). Ces méthodes sont toujours employées dans les travaux de re-

cherche mais ne pourront jamais permettre de cartographier rapidement une parcelle. Elles peuvent être cependant cruciales dans certains cas particuliers comme le cas de la maladie d'enroulement des feuilles de tomate où différents agents viraux provoquent les mêmes symptômes foliaires mais provoquent des baisses de rendement radicalement différentes [47].

Afin de contourner les difficultés à identifier directement les pathogènes, d'autres méthodes de mesure indirectes ont été imaginées. Celles-ci s'attachent à mesurer les conséquences de l'action des pathogènes afin de réaliser le diagnostic. Par exemple certains capteurs tels que les capteurs de mesure de flux de sève sont étudiés pour la recherche sur le stress hydrique [36] et par extension pour la détection précoce des symptômes MBV [137]. Ceux-ci ont permis de dégager des différences de flux de sève sur les pieds atteints MBV symptomatiques. Le caractère précoce de ces signaux semble cependant beaucoup moins évident.

2.6.4 Utilisation de la télédétection et de la proxidétéction

Afin de tirer partie de l'interaction complexe entre la lumière et la plante et ses organes, d'autres techniques innovantes ont été adaptées au monde du végétal. On s'intéressera ici tout particulièrement à l'utilisation de capteurs mesurant l'énergie émise ou réfléchi par une surface dans une longueur d'onde donnée, le plus souvent dans le domaine du visible et de l'infrarouge.




Figure 2.12 – Schématisation des domaines du spectre de la lumière dans le Visible et l'InfraRouge (IR) en fonction de la longueur d'onde (λ). Le trou entre le visible et le PIR correspond à la zone de Red-Edge de transition

L'utilisation de ces capteurs est historiquement motivée par la connaissance de la signature spectrale de la végétation [63] [41]. Celle-ci dépend de la structure particulière des surfaces foliaires et donne à la végétation des propriétés remarquables qui la distinguent d'autres surfaces. La lumière incidente interagit avec la structure de la feuille, une partie étant absorbée, une étant réfléchi et le reste étant transmis. L'énergie absorbée à certaines longueurs d'onde par la chlorophylle sera soit convertie en fluorescence, soit utilisée par le processus photo-synthétique lui-même. La réflectance (proportion de lumière réfléchi par rapport à la lumière incidente) d'une feuille est universellement connue pour avoir une forme particulière, marquée par un important saut de réflectance entre la fin du domaine visible et le début du proche-infra-rouge. Cet écart communément appelé red-edge sert de signature aux végétaux, la pente entre les deux estimée par le (Normalized Difference Vegetation Index (NDVI)) a ainsi été historiquement utilisée

pour différencier la végétation d'autres objets verts (applications militaires, cartographie des zones de végétation etc).

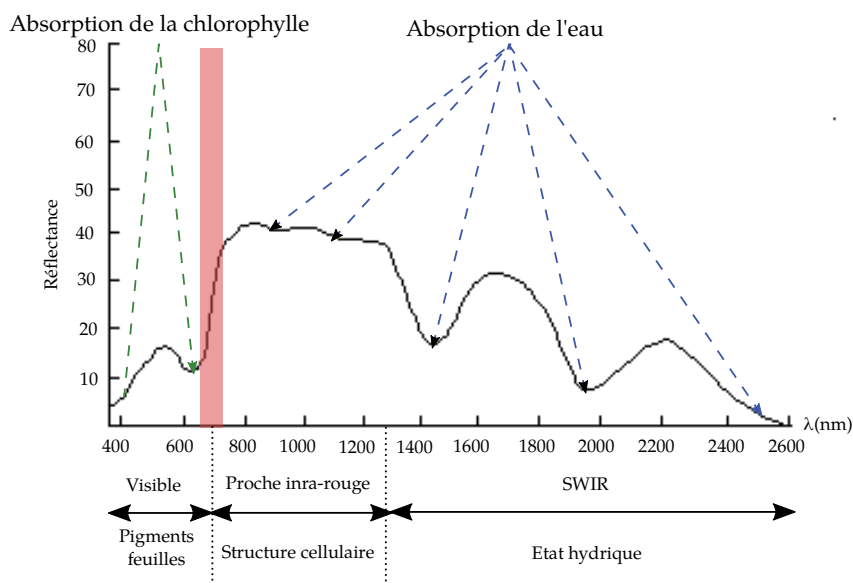


Figure 2.13 – Courbe de réflectance typique d'une feuille dans le visible et le proche Infra-Rouge. La région du Red-edge est indiquée par une bande rouge

Les zones intéressantes du spectre étant intrinsèquement reliées à la présence de composés particuliers au sein de la feuille, il est logique de considérer que les maladies peuvent avoir un effet sur ces composés et donc le spectre, voire que l'on peut détecter en avance l'effet de maladie sans que celle-ci ne soit encore visible à l'œil nu. De manière générale, tout stress chez la plante a potentiellement un effet sur les propriétés optiques des feuilles. Souvent la réaction aux pathogènes s'accompagne d'une baisse de l'activité photo-synthétique qui peut entraîner une augmentation de la fluorescence et de l'émission de chaleur, deux variables mesurables indirectement avec le capteur adapté [201]. Les capteurs en question permettent ainsi de mesurer les paramètres de composition de la feuille (pigments, teneur en eau) et dans certains cas une quantification de processus physiologiques comme la photosynthèse.

Les capteurs utilisant les propriétés de la lumière sont distingués en capteurs actifs et passifs, les premiers émettant leur propre source et les seconds étant simplement dépendants de la lumière naturelle. Les applications agricoles utilisent le plus souvent des capteurs passifs et la lumière naturelle du soleil à la parcelle. Ces capteurs varient principalement selon la longueur d'onde mesurée et le type de mesure effectuée, c'est à dire une mesure ponctuelle ou un ensemble de mesures spatiales sous forme d'une image. Dans le cas d'une image, la géométrie des pixels peut être utilisée en plus de la dimension spectrale (forme des objets d'intérêt).

Afin de passer en revue les différentes technologies et applications liées aux capteurs ponctuels et imagerie sur les feuilles de la vigne, nous allons considérer plusieurs

niveaux de spécificité par rapport à notre sujet d'étude : les MBV. Le premier niveau concerne les applications directement liées aux MBV, ce sont les plus intéressantes mais aussi les plus rares et de nombreuses technologies n'ont pas été testées dans le cas des MBV. Le deuxième niveau concerne les applications liées aux maladies de la vigne en général, celles-ci fournissent une littérature moins lacunaire qui reste cependant spécifique au monde viticole et à ses particularités. Enfin nous considérerons le cas le plus général : la détection des maladies sur les feuilles pour une quelconque culture agricole. Ce cas nous permet de considérer un nombre abondant de références qui ne sont cependant pas forcément pertinentes pour notre application.

Enfin d'autres applications connexes peuvent nous intéresser telles que la mesure du stress hydrique, du stress azoté, la mesure de la vigueur ou la mesure du Leaf Area Index (LAI) [49]. Bien que détachées de l'étude des maladies des plantes, ces applications utilisent le plus souvent des méthodes et mesures similaires.




Figure 2.14 – Classement des applications rencontrées dans l'état de l'art selon leur spécificité au problème agronomique des MBV

2.6.4.1 Capteur ponctuel et imagerie

Les capteurs ponctuels prennent une mesure en un point isolé seulement (par exemple un point sur la feuille) et n'intègrent donc pas les mesures sur la totalité d'une plante ou d'une feuille. Ces capteurs peuvent être utilisés au laboratoire ou au champ si l'appareil est portable. Dans les deux cas, ces capteurs sont actifs et disposent de leur propre source d'émission afin de se placer en conditions contrôlées et d'obtenir une mesure rigoureuse de la grandeur souhaitée. Les deux principaux types de capteurs utilisables sur la feuille mesurent sa réflectance ou sa fluorescence localement.

L'imagerie est liée à deux ambitions pour la détection des maladies des plantes. La première est de pouvoir cartographier exhaustivement la maladie sur une ou plusieurs parcelles de surfaces conséquentes, et ainsi de répondre à la contrainte posée par la notation sanitaire des parcelles de vigne. Ce procédé long et coûteux nécessite la présence d'un expert notant pour chaque pied la présence ou non de symptômes MBV ainsi que leur sévérité. Afin de faciliter ce travail de cartographie et le rendre plus automatisé, l'imagerie est un candidat idéal, pouvant être facilement embarqué sur une machine (engin agricole, drone, ULM etc). La deuxième est de pouvoir visualiser facilement les

hétérogénéités dans la réponse de la plante à un stress biotique.

2.6.4.2 *Imagerie en conditions contrôlées et conditions réelles*

Historiquement les expérimentations sur les capteurs matriciels (imagerie) ont suivi une approche ascendante, en partant d'expérimentations en laboratoire dans des conditions très contrôlées pour ensuite élargir sur les expérimentations en conditions réelles. Les conditions réelles couvrent toute la gamme d'applications dépendantes des paramètres rencontrés dans la parcelle et pouvant avoir une influence sur les mesures. On citera par exemple l'heure de la journée (angle solaire), la couverture nuageuse, l'existence d'ombres, la géométrie du couvert et le vent. L'acquisition d'images en conditions réelles peut alors se faire à 3 échelles selon le but recherché.

L'acquisition au sol (ou proxidtection) impose de réaliser une ou plusieurs mesures par pied de vigne mais permet d'obtenir une information plus riche (résolution élevée). Le capteur peut ensuite prendre de la hauteur en étant embarqué sur un drone (très basse altitude) ou un ULM (au dessus de 150m), augmentant ainsi le nombre de pieds inclus dans une mesure mais diminuant la résolution des images. Le troisième pallier est le vecteur satellite qui sera peu mentionné ici. Il existe des capteurs et applications tirant partie du satellite pour couvrir de très grandes surfaces mais celles-ci sont peu intéressantes dans le cas de la détection des maladies en raison de la faible résolution des images fournies (compensées par la fauchée importante pouvant couvrir un parcellaire entier). Une image multispectrale Pléiades a par exemple une résolution spatiale de 2m en mode multispectral (RVB + PIR). Il est possible de réaliser une opération de fusion avec le canal panchromatique résolu à 50cm mais la résolution spatiale originale sur les bandes d'intérêt reste trop faible pour envisager une application vigne (mélange de spectres de canopée et de sol peu informatif). Ce genre d'image peut cependant être utile dans d'autres applications viticoles comme la classification de parcelles de vigne [159].

En omettant l'imagerie "pénétrante" de type TeraHertz mentionnée précédemment, les cinq types principaux d'imagerie sont l'imagerie visible, multispectrale, hyperspectrale, thermique et de fluorescence.

2.6.4.3 *Imagerie visible*

L'imagerie visible ou Rouge Vert Bleu (RVB) consiste à mesurer les objets tels que perçus par notre œil. Un capteur RVB mesure donc la lumière réfléchi par un objet dans trois gammes de longueurs d'onde du domaine visible correspondant au rouge, au vert et au bleu. Cela implique que ce type de capteur ne peut être utilisé que pour détecter des symptômes visibles, correspondant souvent sur une feuille à des plages de couleurs jaune ou rouge différenciables du vert des feuilles. Ainsi, la donnée obtenue peut être utilisée pour détecter des plages de couleur anormales ou des formes caractéristiques liées à la maladie. Les traitements peuvent donc aller de méthodes très simples comme des filtres couleur ou des filtres de bord à des méthodes de détection plus sophistiquées couvrant entre autres l'analyse de textures, l'utilisation de descripteurs locaux ou de ré-

seaux convolutifs issus du *deep learning*. Dans tous les cas, l'information spectrale et/ou spatiale sera encodée dans un attribut représentatif de l'état d'une plante ou d'une feuille.

En laboratoire, des expériences très simples peuvent être réalisées comme dans [133] où les attributs couleur sont utilisés pour la détection des maladies de la betterave. Des applications au champ sont aussi possibles comme dans [154] où des méthodes plus complexes issues du *deep learning* sont évaluées dans le cas du manioc. Ici, les méthodes plus avancées servent à prendre en compte la variabilité rencontrée dans les conditions réelles et à rendre les algorithmes de détection plus robustes face aux éléments perturbateurs (sol, angles de vue différents, enchevêtrement complexe de feuilles, etc). Dans le cas des maladies provoquant des symptômes foliaires sous formes de chloroses ou de nécroses allant du jaune au brun, la composante de teinte (nature de la couleur sans considérer son mélange avec du noir ou du blanc) apporte une information précieuse sur la composition du feuillage. On notera par exemple [204] où les auteurs réalisent une analyse texturale sur des images dans l'espace Teinte Saturation Valeur (TSV) pour détecter l'alternariose de l'aubergine. L'imagerie visible seule est dans les faits peu utilisée (bien qu'il existe des exemples [189]) avec un vecteur aérien pour la raison simple que des capteurs multispectraux hyperspectraux de taille similaires existent et apportent une information plus riche que la simple information couleur. Elle peut cependant être utilisée pour des applications en viticulture de précision différentes telles que la recherche de pieds manquants [152] ou la reconstitution 3D du couvert [34].

L'imagerie visible a été utilisée pour l'étude de l'esca de la vigne à l'aide d'indices texturaux [4]. Les feuilles y sont posées à plat en conditions de laboratoire. Il existe des applications en laboratoire et en proxidtection [123] dans le cas de la vigne au sens général, les plus intéressantes étant les méthodes au champ [2]. Ces applications ont l'avantage de nécessiter un matériel peu coûteux fournissant des images haute-résolution mais sont aussi potentiellement compatibles avec des applications mobiles en tirant parti de la généralisation des smartphones équipés d'une caméra RVB. Elles semblent moins attractives de prime abord car elles ne permettent pas la détection précoce mais sont aussi les méthodes les mieux maîtrisées, que ce soit pour le protocole expérimental en amont ou la méthodologie de traitement en aval.

2.6.4.4 Imagerie multispectrale

Face aux limitations de l'information couleur de l'imagerie visible, l'imagerie multispectrale permet de sortir du domaine visible et d'apporter des informations sur des longueurs d'onde du proche-infrarouge liées aux paramètres biophysiques de la feuille (structure des cellules, composition en eau). L'imagerie multispectrale prend concrètement la forme de caméras avec des canaux ajoutés aux 3 canaux RVB. Les capteurs les plus simples incluent en plus une seule bande dans le proche infra-rouge tandis que d'autres capteurs incluent une dizaine de bandes dans le proche-infrarouge, parfois dédiées à des applications spécifiques comme la correction atmosphérique. Certains capteurs mettront ainsi en évidence les différents pics d'absorption de l'eau que l'on retrouve dans la zone du PIR. L'existence des capteurs multispectraux a ouvert la voie aux Indices de végétation (IV) permettant de résumer l'information de plusieurs bandes en un seul attribut comme le NDVI mentionné précédemment. Certains indices de végétation

sont parfois corrélés à des variables d'intérêt telles que la vigueur ou la teneur azotée. De nombreux travaux de recherche ont ainsi été dédiés à la conception de nouveaux indices permettant d'estimer d'autres variables biophysiques.

Les applications multispectrales ciblées sur la vigne sont nombreuses. En laboratoire, on citera [136] qui réalise l'identification du mildiou dans des conditions contrôlées en étudiant l'effet de variations de l'angle foliaire. Bien que motivée par le phénotypage de la couverture du couvert de la vigne, la thèse de Marie-Aure Bourgeon [25] présente des protocoles et méthodes en proxidtection multispectrale qui pourraient être appliqués à la détection de symptômes foliaires. D'autres efforts de recherche ont été réalisés pour la détection aérienne avec l'étude conjointe des symptômes de flavescence dorée et d'esca à l'aide d'un vecteur aérien [6]. Ce travail illustre l'ambition de plus en plus présente de ne pas seulement pouvoir différencier un pied malade d'un pied sain mais de pouvoir distinguer plusieurs maladies entre elles. Cette étude montre cependant que la différence entre les deux maladies est peu prononcée dans les bandes étudiées, des plages de jaunissement et de rougissement ayant le même comportement spectral selon qu'elles appartiennent à un pied atteint de l'esca ou de la flavescence dorée. Elle met aussi en évidence une variabilité inter-cépage et inter-annuelle extrêmement importante, les symptômes de ces deux maladies pouvant être très différents d'une année à une autre. Les caméras multispectrales montées sur drone peuvent de même être utilisée pour d'autres types d'application connexes comme la détection de mauvaises herbes [191]. L'imagerie multispectrale par satellite peut aussi être dans de rares cas utilisée pour la détection de maladies comme dans [124] sur le virus de la mosaïque des stries en fuseaux du blé.

2.6.4.5 Spectroradiométrie et imagerie hyperspectrale

Les capteurs décrits précédemment permettent d'obtenir les valeurs de réflectance sur quelques plages de longueurs d'onde étalées. Le canal vert d'un capteur RVB provient par exemple de l'intégration de la lumière reçue sur une vaste gamme de longueurs d'onde (*broadband*). Dans la réalité le spectre d'un matériau quelconque est continu et c'est sa forme qui détermine sa signature. Cette information spectrale continue (*narrow-band*) peut être obtenue à l'aide d'un spectroradiomètre, capteur actif permettant de réaliser des mesures ponctuelles et continues de réflectance dans le visible et le proche-infrarouge. Les conditions sont contrôlées et la réflectance exacte peut être récupérée si le matériel est calibré avec une cible de comportement radiométrique connu (le plus souvent présentant une réflectance égale à 95% dans les domaines de longueur d'onde mesurés). Le nombre de valeurs (et donc la dimensionnalité de la donnée obtenue) se dénombre en plusieurs centaines voire milliers, chaque valeur étant associée à une longueur d'onde précise. Historiquement ces capteurs ont été utiles dans le domaine de la minéralogie où l'identification d'un minéral particulier nécessitait une résolution spectrale fine (pics localisés de réflectance). Dans le cas des végétaux, on espère pouvoir comparer la forme des spectres entre elles et mettre en évidence des longueurs d'onde discriminantes d'une maladie. En connaissant ces longueurs d'onde, on peut alors concevoir un capteur de détection (visible ou précoce) multispectral moins coûteux les contenant. Ce type de montage d'abord utilisé en laboratoire a pu s'exporter à la parcelle avec la conception de dispositifs portables par exemple sous forme de pince équipée de sa propre source de

lumière.

L'imagerie hyperspectrale accomplit quand à elle la fusion entre le capteur d'imagerie multispectrale et le spectroradiomètre, permettant ainsi d'obtenir un spectre quasi continu pour chaque pixel de l'image. La résolution spectrale importante de ces capteurs se fait cependant au détriment de la résolution spatiale. Aussi, le nombre de canaux obtenus est élevé mais reste souvent moins important que pour un spectroradiomètre. Le défi technologique que représentait la création d'un capteur spatial à forte résolution spectrale a conduit à concevoir des capteur dits "linéaires" : ceux-ci n'enregistrent qu'une ligne à la fois et la prise d'une image nécessite donc que l'appareil se déplace progressivement pour acquérir chaque ligne de pixels. En conditions réelles, les images obtenues présentent souvent beaucoup de défauts géométriques liés au mouvement du capteur (instabilité sur drone) ou au mouvement des éléments de la scène (déplacement des feuilles à cause du vent par exemple). Les traitements appliqués aux capteurs hyperspectraux sont totalement différents des autres et ont donné naissance à une branche entière du traitement d'image. L'aspect spatial y est souvent délaissé pour se concentrer sur l'information spectrale (donnée de haute dimensionnalité mais très corrélée) et la classification pixel à pixel des images.

Étant donné ces contraintes il est logique de voir d'abord des applications en laboratoire émerger. Bergsträsser *et al* décrivent la conception d'un dispositif hyperspectral de 400 à 2500nm utilisé pour la détection des symptômes provoqués par *cercospora* sur la betterave sucrière [20]. Toujours sur la betterave sucrière, des applications en proxidtection existent tel que [96] où l'imagerie hyperspectrale est mêlée avec une modélisation 3D de la plante. Cette fusion permet ainsi de déterminer l'angle foliaire nécessaire entre autres pour corriger les mesures hyperspectrales en réflectance (les valeurs mesurées varient avec l'angle foliaire). Le capteur hyperspectral peut aussi être embarqué sur drone ou ULM bien que les contraintes de prise de vue le rendent moins attractif qu'un capteur multispectral. On citera [77] où la rouille jaune du blé est cartographiée avec une revisite temporelle.

La spectroradiométrie a été utilisée pour de nombreuses applications en viticulture depuis l'émergence de capteurs portables, on citera par exemple [132] à propos du virus d'enroulement de la vigne où le pouvoir discriminant de nombreux indices de végétation est étudié. Ce même virus d'enroulement de la vigne est cartographié depuis un vecteur aérien dans [116] puis comparé aux notations terrain géoréférencées disponibles. Les auteurs insistent sur la difficulté manifeste de définir une zone tampon autour de chaque point de la notation terrain afin de récupérer les pixels appartenant à chaque pied. En complément de l'imagerie visible [4] ou multispectrale [6], des études liées à l'esca se basent sur des spectres continus issus d'un spectroradiomètre de terrain afin d'obtenir une mesure exacte de la réflectance sur des feuilles symptomatiques d'esca et de flavescence dorée échantillonnées. Ces études concernent seulement les symptômes foliaires, mais il existe aussi des études étudiant le comportement spectral du bois abîmé par les maladies du bois [106]. Il n'existe cependant pas à notre connaissance d'application utilisant l'imagerie hyperspectrale pour la détection (précoce ou non) des maladies du bois de la vigne, que ce soit en proxidtection ou en télédétection, ce qui est l'un des

objectifs de cette thèse.

2.6.4.6 *Imagerie thermique*

Les applications précédentes étaient basées sur la mesure de la réflectance dans des domaines proches de la lumière visible comme le proche infra-rouge. Les propriétés du spectre deviennent cependant très différentes à mesure que l'on s'éloigne dans le domaine du moyen infra-rouge. Tout corps avec une température non nulle émet une radiation dans l'infrarouge thermique et cette radiation est corrélée à la température. Ainsi, les caméras thermiques permettent d'obtenir une estimation de la température à la surface d'un matériau en mesurant la lumière reçue dans l'infrarouge moyen, souvent autour de $10\mu\text{m}$, la plage dépendant principalement de l'appareil utilisé ainsi que la sensibilité thermique exprimée en degrés Celsius. Les appareils utilisés peuvent autant être ponctuels que imageurs.

Le stress induit par les pathogènes peut être corrélé à des changements de température dans les tissus de la plante. Ainsi par exemple, il existe une anti-corrélation entre le taux de transpiration de la feuille et sa température [109]. L'acide salicylique produit par les plantes provoque de même une hausse du métabolisme et de la température. Les pathogènes provoquant la fermeture de stomates sont ainsi indirectement responsables d'une augmentation de la température foliaire. Cet effet peut être potentiellement constaté à des stades précoces et constitue donc une piste intéressante pour l'étude et la détection des MBV. La variable d'intérêt pour la détection de stress biotiques est donc ici la différence de température entre un échantillon infecté et un non infecté. Cette différence est souvent inférieure au degré Celsius et met en évidence le rôle critique des facteurs extérieurs pouvant influencer la température mesurée en conditions réelles. La technologie implique ainsi d'important défis méthodologiques lorsque utilisée en conditions réelles. La circulation naturelle de l'air au sein d'un vignoble entraîne par exemple des zones de température différentes qui varient avec le temps [39]. La récupération des variables d'intérêt à la parcelle est aussi, au même titre que la réflectance, un problème d'inversion [85].

L'application principale est donc la surveillance de l'ouverture des stomates comme dans [40] où la méthode est appliquée au café. A l'aide de l'imagerie thermique, des auteurs mettent en évidence chez le tabac une hausse avant l'arrivée des symptômes visibles de la teneur en acide salicylique sur certaines zones des feuilles infectées [35], une détection précoce du mildiou sur le blé est aussi rapportée chez dans d'autres publications [3]. L'étude se déroule en conditions réelles et donc l'influence des paramètres environnementaux est discutée. L'étude met en évidence des résultats plus reproductibles dans le cas des mesures au soleil que dans celui des mesures à l'ombre.

L'imagerie thermique est une méthode connue en viticulture, particulièrement pour la mesure du stress hydrique lié à l'irrigation [38]. *Jones et al* s'intéressent à la mesure du stress hydrique par imagerie thermique en conditions réelles et considère deux expériences sur le riz et la vigne respectivement [88]. La première utilise la caméra en mode proxidétection tandis que la deuxième utilise un ballon comme vecteur afin de réaliser des clichés aériens. Les auteurs corrélaient la température mesurée du couvert de la vigne

avec la conduite de différents modes d'irrigation mais mentionnent aussi l'existence de paramètres naturels pouvant biaiser les résultats. On citera par exemple une étude qui montre que les mesures de température effectuée dépendent grandement de la géométrie des objets [92]. Ainsi le gradient d'angle rencontré naturellement dans les images aériennes à basse altitude peut avoir une répercussion très importante sur les résultats. Dans [60], l'imagerie thermique est utilisée en proxidtection, toujours dans le but de quantifier le stress hydrique. Les auteurs utilisent une feuille sèche et une feuille humide afin de calibrer les mesures de température en conditions réelles. L'efficacité de cette approche de calibration est cependant relativisée dans [66] où il est montré qu'il existe en réalité une grande variabilité dans les mesures de référence selon la situation. La fusion entre imagerie multispectrale et thermographie avec vecteur drone est aussi décrite dans une étude [10].

Dans [170], les auteurs explorent les possibilités de détection précoce des effets de *Plasmopara Viticola* sur la vigne. Toutes les expériences y sont réalisées sous serre avec des conditions contrôlées afin de pouvoir enregistrer avec précision la température des feuilles. Les effets de l'irrigation y sont de même explorés en montrant que celle-ci a un rôle dans la température des feuilles. Il n'existe cependant pas d'application similaire en imagerie thermique axée sur les MBV.

Notons qu'à l'échelle du satellite, l'imagerie thermique peut être utilisée pour la mesure de l'humidité et la salinité du sol de la parcelle [84].

2.6.4.7 Imagerie par fluorescence

La chlorophylle A et d'autres pigments foliaires sont fluorescents, c'est à dire qu'ils réagissent à une stimulation lumineuse dans l'Ultra-Violet (UV) par l'émission de fluorescence dans le visible à plusieurs longueurs d'onde. Cette énergie perdue par la plante est cependant négligeable, de l'ordre de quelques pourcents au maximum [63]. Ce rayonnement est de nature différente de la réflectance et ne peut pas être naturellement mesuré avec un capteur passif. On utilise donc un capteur actif permettant d'éclairer le sujet d'étude avec une lumière dans l'UV. Comparé à la thermographie principalement liée à la transpiration, la fluorescence est liée à l'activité photo-synthétique, deux phénomènes complémentaires et souvent rencontrés simultanément dans le cas d'un stress biotique chez la plante. La dissipation thermique et l'émission de fluorescence étant tous les deux une forme perdue d'énergie de la photosynthèse, une augmentation de l'un provoquera en théorie la diminution de l'autre.

La fluorescence peut être mesurée sous forme ponctuelle et sous forme d'image. Les feuilles illuminées par une lumière UV émettent à plusieurs longueurs d'onde (440, 520, 690 et 740nm), il est donc possible d'obtenir une image multi-canaux de fluorescence et de réaliser des cartes en fausses couleurs. L'opération peut être réalisée pour mesurer les intensités en elles mêmes ou pour calculer les ratios entre deux longueurs d'onde (ratio bleu/rouge par exemple) [29]. D'autres indices plus complexes peuvent être dérivés des mesures de fluorescence tel que le rendement quantique de la fluorescence qui représente l'efficacité d'émission des fluophores de la plante. La technologie a été dès les années 90 utilisée en laboratoire pour la détection précoce, par exemple 3 à 4 jours avant l'appari-

tion des symptômes de la rouille chez le haricot [142]. L'utilisation de capteurs portables équipés d'un laser a permis à la technologie de s'exporter au champ comme dans [89] où la détection du chancre bactérien des agrumes au Brésil est réalisée. L'imagerie par fluorescence peut notamment être utilisée comme un outil de phénotypage indicatif de la santé des plantes [163]. Les indices de rendement photosynthétique calculés peuvent ainsi être utilisés pour segmenter les feuilles en des zones de sévérité de la maladie différentes.

Du fait de leur complémentarité, on trouve aussi des exemples en laboratoire tirant partie à la fois de l'information thermique et de celle de fluorescence comme dans [28] où la combinaison des deux est utilisée pour la détection précoce des effets du virus de la mosaïque du tabac, dans [127] pour le tournesol. Une comparaison entre l'apport des deux types de capteurs est de même conduite au sujet de la tavelure du pommier [19]. On peut de même trouver des exemples de fusion avec l'hyperspectral. Des attributs issus de la fluorescence, la thermographie et des indices de végétation ont été utilisés pour la détection du stress biotique chez la laitue [166]. [15] utilise l'imagerie par fluorescence au champ pour la détection précoce des infections au fusarium sur le blé accompagnée d'imagerie hyperspectrale en laboratoire. D'après les auteurs, l'imagerie hyperspectrale permet ici de détecter les symptômes sur l'épi de blé selon sa signature tandis que la fluorescence permet de mettre en évidence des changements dans l'activité photo-synthétique de la plante. Ceux-ci mentionnent aussi les difficultés liées à l'utilisation de l'imagerie par fluorescence en conditions réelles. Les signaux de fluorescence mesurés à la lumière naturelle sont plus faibles que ceux mesurés avec une adaptation au préalable des feuilles dans le noir. Les auteurs indiquent aussi que l'exposition directe au soleil doit être évitée et que le vent est un facteur important à prendre en compte, même pour des temps de mesure courts. Dans [145], une étude de la variabilité des mesures de fluorescence en conditions réelles est réalisée en fusionnant les données de fluorescence avec l'angle obtenu grâce à une reconstruction stéréoscopique.

Les capteurs de fluorescence peuvent aussi être utilisés dans le monde viticole. Dans un effort de détection précoce du mildiou, des auteurs mettent en évidence un lien entre la présence de *Plasmopara viticola* sur les feuilles et la mesure de fluorescence [62]. Les plantes inoculées étaient, dans cette expérience, conservées dans des conditions de serre semi-contrôlées, en adaptant les feuilles dans le noir pendant une vingtaine de minutes. Les cartes d'un ratio de fluorescence sur les feuilles à plat ont alors permis une détection des symptômes 3 jours avant leur apparition visible. Des conclusions similaires sur la détection précoce du mildiou ont été établies dans [18]. Là encore, il ne semble pas exister d'études sur l'imagerie par fluorescence appliquée aux maladies du bois qui, bien qu'étant aussi une maladie fongique, est très différente du mildiou. La fluorescence in-situ ponctuelle a cependant été mesurée dans [43], permettant de mettre en évidence dans certains cas une altération de l'appareil photo-synthétique pouvant être détectée jusqu'à 2 mois avant apparition des symptômes foliaires. Une étude de la différenciation avec les troubles photo-synthétiques dus au stress hydrique a aussi été réalisée et montre que les deux sont différenciables sur la base des indices dérivés de la mesure de fluorescence.

2.6.5 Résumé

L'émergence de capteurs de plus en plus variés, miniaturisés mais aussi moins onéreux a ouvert la voie à de nombreuses applications agricoles, dont entre autres le diagnostic de stress biotique par la détection de symptômes visibles ou précoces. Ces capteurs ont trouvé leur voie allant du laboratoire avec des conditions contrôlées à la parcelle où toutes les composantes terrain sont à prendre en compte. La démocratisation des drones a de même permis de trouver un compromis intéressant entre la télédétection basse résolution et la proxidétection haute résolution, introduisant en même temps de nouveaux types de difficultés techniques. Les recherches sont jalonnées de nombreux résultats encourageants mais se heurtent toujours à des problèmes récurrents desservant de potentielles applications commerciales. Le premier problème est la difficulté à prendre en compte les paramètres du terrain et le danger de tirer de mauvaises interprétations (faux négatifs ou faux positifs) à cause de l'influence de ces variables. Ces contraintes sont d'autant plus vraies que l'information mesurée est fine.

Le pont entre recherches théoriques (modèles d'inversion, modélisation, analyse d'images, *machine learning*, statistiques) et l'applicatif reste encore difficile à construire. La conséquence de ces difficultés est qu'une méthodologie n'est pas forcément généralisable. Par exemple un algorithme de détection entraîné sur une parcelle de vigne en août ne sera pas forcément adapté à une parcelle d'un autre cépage observée deux mois auparavant à la première apparition des symptômes. L'autre problème inhérent aux recherches sur les maladies des plantes est qu'elles n'abordent souvent pas le cas de la différenciation avec d'autres troubles. C'est particulièrement vrai avec la vigne où de nombreux stress biotiques et abiotiques sont référencés et peuvent être confondus de par la similarité des symptômes résultants. Cependant, l'acquisition et l'étiquetage de données d'apprentissage reste coûteux et contraignante malgré des dispositifs opérationnels de plus en plus automatisés. On remarque que dans le cas des applications en hyperspectral, thermique et fluorescence, les conditions réelles posent toujours problème, principalement à cause de la variabilité de la lumière naturelle, de la géométrie de la plante et du vent. Les bonnes pratiques d'expérimentation et les méthodologies de correction diffèrent cependant entre les trois. D'autres projets tentent de fusionner les sources de données différentes mais cette fusion est méthodologiquement complexe et dégage des descripteurs qui sont très souvent partiellement ou totalement corrélés.

On compte à ce jour peu d'applications directement liées aux MBV bien que des efforts de recherche divers existent. Il est cependant possible de s'appuyer sur la grande diversité d'applications viticoles voire agricoles pour imaginer les applications qui pourraient faire l'objet d'un effort de recherche. Le tableau 2.1 résume l'existence ou non d'applications utilisant l'imagerie liées à la détection de maladies ou de stress abiotique aux 3 niveaux de spécificité définis auparavant.

Tableau 2.1 – Exemples d’applications existantes en imagerie concernant les MBV, la vigne et l’agriculture en général. Les références sont indiquées dans le cas des applications spécifiques aux MBV

| | | MBV | Vigne | Général |
|---|----------------------|------------------|-------|---------|
| Imagerie ● :Labo ● :Proxy ● :Aérien | Visible | ● - - [4] | ● ● - | ● ● ● |
| | Multispectral | - ● - [5] [6] | ● ● ● | ● ● ● |
| | Hyperspectral | - - - | ● - ● | ● ● ● |
| | Thermique | - - - | ● ● ● | ● ● ● |
| | Fluorescence | - - - | ● ● - | ● ● ● |

On remarque que les applications MBV imagerie se concentrent pour l’instant exclusivement sur l’imagerie multispectrale aérienne et sur l’imagerie visible en laboratoire. On peut ajouter à cette liste les travaux basés sur des mesures ponctuelles (et donc non présentes dans le tableau 2.1) de la fluorescence [43] et sur la spectroradiométrie [6] [4] (complémentaires aux mesures en imagerie dans le deux cas).

De nombreux articles existent pour passer en revue de manière plus exhaustive les méthodes de détection des maladies des plantes. La revue de Martinelli *et al* semble une des plus complète en la matière ([122]) mais on pourra aussi citer [167] et [54]. Les revues de littérature spécifiquement dédiées à l’imagerie appliquée à l’agriculture sont aussi nombreuses. On citera ici par exemple [12] et [130] qui s’intéressent à la détection des maladies des plantes par tout type d’imagerie, [165] qui se penche sur l’apport de l’imagerie hyperspectrale pour l’agriculture, [83] à propos de l’imagerie thermique ou même [151] qui s’intéresse spécifiquement à la détection des maladies fongiques.

2.7 MOTIVATION DES CHOIX MÉTHODOLOGIQUES ET EXPÉRIMENTAUX

Nous avons vu précédemment que les technologies potentiellement applicables à la détection des Maladies du Bois de la Vigne (MBV) étaient nombreuses et fournissent une information variée mais parfois redondante sur l’état physiologique de la feuille et de la plante entière. Il n’est cependant pas envisageable d’orienter ses efforts de recherche vers toutes les méthodes présentées, bien qu’une comparaison exhaustive serait intéressante. Un choix a donc été fait afin de retenir les plus intéressantes, du point de vue de l’application, mais aussi de la contribution méthodologique que l’on peut apporter. Le choix s’est ici porté sur une application de détection de symptômes visibles et une plus exploratoire de symptômes précoces. La première application utilisera ainsi une caméra RVB classique tandis que la seconde tirera parti de l’information fine d’une caméra hyperspectrale dans le visible et le proche infra-rouge.

La signature spatiale particulière des feuilles atteintes par l’esca nous motive à utiliser l’imagerie visible afin de les détecter et de les différencier d’autres troubles impliquant

aussi des jaunissements et des rougissements. La composante forme implique aussi qu'il est nécessaire de travailler à une échelle où la résolution des images est suffisante, d'où le choix de prendre des images en proxidtection au sol ou en laboratoire : la détection de forme serait plus complexe sur des images drone et impossible sur des images Ultra Léger Motorisé (ULM). Ce choix est de même motivé par les avancées méthodologiques importantes sur la détection d'objet et de forme ces 15 dernières années, nous menant aussi à considérer l'apport que pourrait constituer les méthodes de *deep learning* par rapport à des méthodes classiques. Ces méthodes souvent appliquées à des domaines totalement différents constitueraient aussi un apport méthodologique intéressant dans le domaine agricole.

Sur la base des résultats existants en détection précoce, l'imagerie hyperspectrale semble prometteuse mais plus expérimentale et incertaine. L'enjeu ici est en réalité double. Le premier concerne l'étude des propriétés spectrales des symptômes visibles et des méthodologies permettant de corriger ou modéliser les variations de spectre en conditions réelles. Le deuxième concerne la détection précoce et la recherche de pieds non symptomatiques au moment de la mesure qui sont connus comme étant atteints MBV. Dans les deux cas, on cherchera dans le spectre des longueurs d'onde stables et discriminantes dans le signal permettant si possible de répondre à ces questions. On envisagera de la même façon un passage près des feuilles car les caméras hyperspectrales possèdent une résolution spatiale moyenne et il est nécessaire dans notre cas de pouvoir distinguer, sans pixels de mélange, les différentes plages de couleur sur les feuilles symptomatiques.

L'imagerie par fluorescence et l'imagerie thermique ne seront pas abordées, par choix et pour des questions de matériel. Ces deux techniques sont cependant des pistes de choix pour se substituer à la détection précoce visée par l'imagerie hyperspectrale.

2.7.1 *Le choix de l'approche terrain*

Les deux applications présentées pourraient faire l'objet de mesures en conditions contrôlées (laboratoire) ou réelles (parcelle de vigne à la lumière du jour). Le choix entre les deux pourrait être résumé par analogie à l'adoption d'une approche ascendante (*bottom-up*) ou descendante (*top-down*). L'approche ascendante a pour objectif de partir de la théorie et de la consolider pour aboutir à la pratique tandis que l'approche descendante part de l'application et tente de faire émerger des théories adaptées. Les concepts sont parfaitement maîtrisés dans le premier (expériences en laboratoire) alors que ceux-ci sont élaborés dans les grandes lignes afin de répondre à un problème dans le cas du second (expériences au champ).

Le choix des conditions réelles et de l'approche descendante est ici en premier lieu motivé par le caractère pressant des enjeux liés aux MBV. L'ingénierie de solutions adaptées passe par des étapes de recherche mais celles-ci doivent autant que possible être proches d'une potentielle application commerciale. L'autre raison concerne le manque d'applications de ce type dans la littérature, que ce soit en visible ou en hyperspectral. Le travail en condition réelle peut déboucher sur une contribution intéressante sur le potentiel et les points bloquants qui entourent ce type d'applications dans le monde de la vigne et

de l'agriculture en général. Enfin, les compétences théoriques et méthodologiques du groupe Signal et Image du laboratoire de l'Intégration du Matériau au Système (IMS) en terme de traitement du signal et des images ont tendu à porter l'effort sur les aspects algorithmiques appliqués à l'analyse de scènes naturelles. Cela permet de valoriser ces compétences sur des domaines tel que l'agriculture et de favoriser les liens entre deux mondes a priori distincts.

Les avantages et inconvénients de la méthode descendante adoptée sont résumés dans le tableau 2.2 :

Tableau 2.2 – Avantages et inconvénients de la méthode descendante *Top/Down* adoptée

Avantages :

-
- Transposition en application réelle plus simple
 - Jeux de données conformes aux conditions réelles
 - Prise en compte naturelle des problèmes liés au terrain

Inconvénients :

-
- Conditions non contrôlées, paramètres d'incertitude
 - Effort méthodologique plus important
 - Pas de connaissance a priori des résultats en laboratoire (risque de passer à coté de résultats identifiables en conditions contrôlées)

Les deux expériences en visible et en hyperspectral seront donc réalisées au champ sur les mêmes parcelles d'étude. L'application au champ pose bien évidemment plus de problèmes méthodologiques dans le cas de l'imagerie hyperspectrale mais ouvre des perspectives méthodologiques intéressantes.

La suite de l'étude aura à cœur d'examiner les applications potentielles répondant aux deux question formulées plus tôt. Ces deux questions seront abordées sur la base de parcelles disponibles dans le cadre du projet, détaillées plus en détail dans le chapitre suivant. Une fois la présentation des parcelles et de leur prévalence esca, le manuscrit s'articulera en deux grands volets autour de l'étude des MBV, résumés dans le tableau 2.3.

Tableau 2.3 – Volets d'étude abordés dans le manuscrit

Volet 1 : Détection et différenciation des symptômes MBV par imagerie visible

- Etat de l'art sur l'utilisation de l'imagerie visible pour détection de symptômes visibles
 - Conception du dispositif d'acquisition et du protocole
 - Mise en place d'une méthodologie de classification et de détection des symptômes
-

Volet 2 : Etude expérimentale des applications en imagerie hyperspectrale

- Etat de l'art sur l'utilisation de l'imagerie hyperspectrale pour la détection précoce (stress biotique et abiotique)
- Conception du dispositif d'acquisition et du protocole expérimental
- Mise en place de la méthodologie d'analyse des données hyperspectrales permettant d'isoler les longueurs d'onde discriminantes

PRÉSENTATION DES PARCELLES DE L'ÉTUDE

Sommaire

| | | |
|-------|--|----|
| 3.1 | Description des parcelles et notations terrain | 37 |
| 3.2 | Prévalence des symptômes à la parcelle | 38 |
| 3.3 | Evolution temporelle | 39 |
| 3.3.1 | Evolution entre les années | 39 |
| 3.3.2 | Evolution au cours d'un été | 41 |
| 3.4 | Répartition des symptômes | 42 |
| 3.5 | Conclusions | 42 |

Le présent chapitre est dédié à la présentation des parcelles étudiées durant la thèse ainsi qu'à une rapide description de la prévalence des symptômes des maladies du bois de la vigne.

3.1 DESCRIPTION DES PARCELLES ET NOTATIONS TERRAIN

Plusieurs parcelles dans le bordelais sont mises à disposition pour le projet Advantage. Parmi celles-là, une parcelle en blanc et une en rouge ont été retenues pour les expérimentations. Ces deux parcelles sont situées respectivement dans le Médoc à Pauillac et dans les graves à Castre-Gironde. Les cépages respectifs sont le Cabernet-Sauvignon rouge et le Sauvignon-blanc blanc, cépages courants dans la région bordelaise. La parcelle en rouge est caractérisée par une conduite stricte et feuillage poreux tandis que la parcelle en blanc possède un feuillage plus dense.

Les parcelles sont notées chaque été depuis 2012 en considérant un sous-ensemble de la parcelle. La notation est une étape difficile dépendant de l'objectif et du degré de précision recherché. Dans notre cas, les notations, bien que légèrement différentes entre les deux parcelles, sont spécifiques dédiées à l'étude de l'esca. Certains autres symptômes liés à l'eutypiose pourraient être indiqués mais ce type de Maladies du Bois de la Vigne (MBV) est plus rare et n'était pas rencontré dans les parcelles du projet.

La classification des symptômes fournie est ainsi la suivante :

- Pieds sains
- Esca forme lente
- Esca forme apoplectique
- Complants (cep récemment planté, âge détaillé)
- Manquant
- Mort (pouvant être causé par un épisode apoplectique ou autre)

3.2 PRÉVALENCE DES SYMPTÔMES À LA PARCELLE

A l'aide des notations des pieds, il est d'abord possible de déterminer la prévalence de la maladie (et d'autres variables telles que le nombre de complants ou de pieds morts à la parcelle). Ces pourcentages sont indiqués avec un exemple dans le tableau 3.1. On y retrouve des atteintes similaires à celles constatées en moyenne dans les vignobles français pour la parcelle en rouge et des atteintes élevées pour la parcelle en blanc, avec un taux important de pieds apoplectiques.

Tableau 3.1 – Prévalence 2016 (en %) des pieds symptomatiques au sein des parcelles notées pour l'année 2016

| | Sain | Mort/Manquant | Complant | Esca | |
|-------|------|---------------|----------|------|--------------|
| | | | | Lent | Apoplectique |
| Blanc | 76.9 | 0.5 | 14.7 | 4.7 | 3.2 |
| Rouge | 81 | 4.6 | 10 | 2.9 | 1.5 |

Les données de notations ne sont pas accompagnées de mesures GPS mais sont spatialisées dans le repère rang/pied, il est donc possible de replacer les mesures sur une grille afin de visualiser l'état sanitaire de la partie de parcelle mesurée. Il est à noter qu'il peut subsister de légers décalages entre les rangs lorsque l'on adapte cette méthodologie. De plus, les pieds de la parcelle en cabernet sauvignon sont notés par alternance de 3 rangs. C'est ce que présente la figure 3.1 sur la même année que la figure précédente.

Parcelle 1: Sauvignon blanc



Parcelle 2: Cabernet Sauvignon

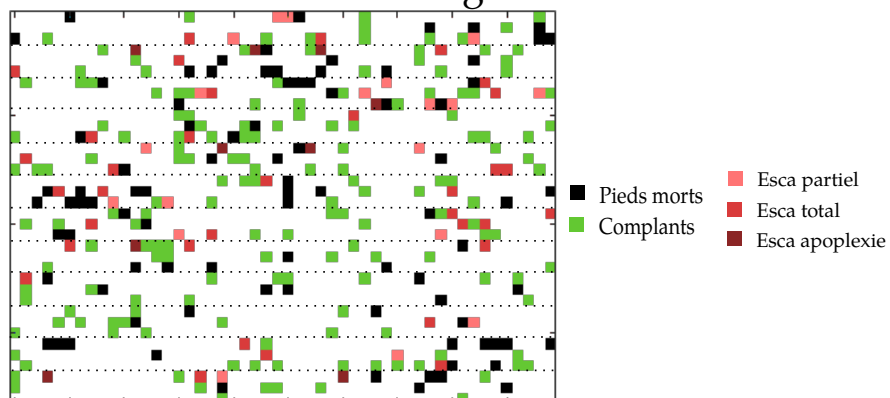


Figure 3.1 – Exemples de notations lors de l’année 2016 sur les deux parcelles d’étude. Les données sont présentées sous forme d’une grille de dimension arbitraire.

3.3 EVOLUTION TEMPORELLE

3.3.1 Evolution entre les années

Grace à la notation terrain répétée d’année en année, il est de même possible de décrire l’évolution des symptômes sur la période concernée. On prendra ici l’exemple de 5 années de mesures de 2012 à 2016. Cette évolution est illustrée dans la figure 3.2

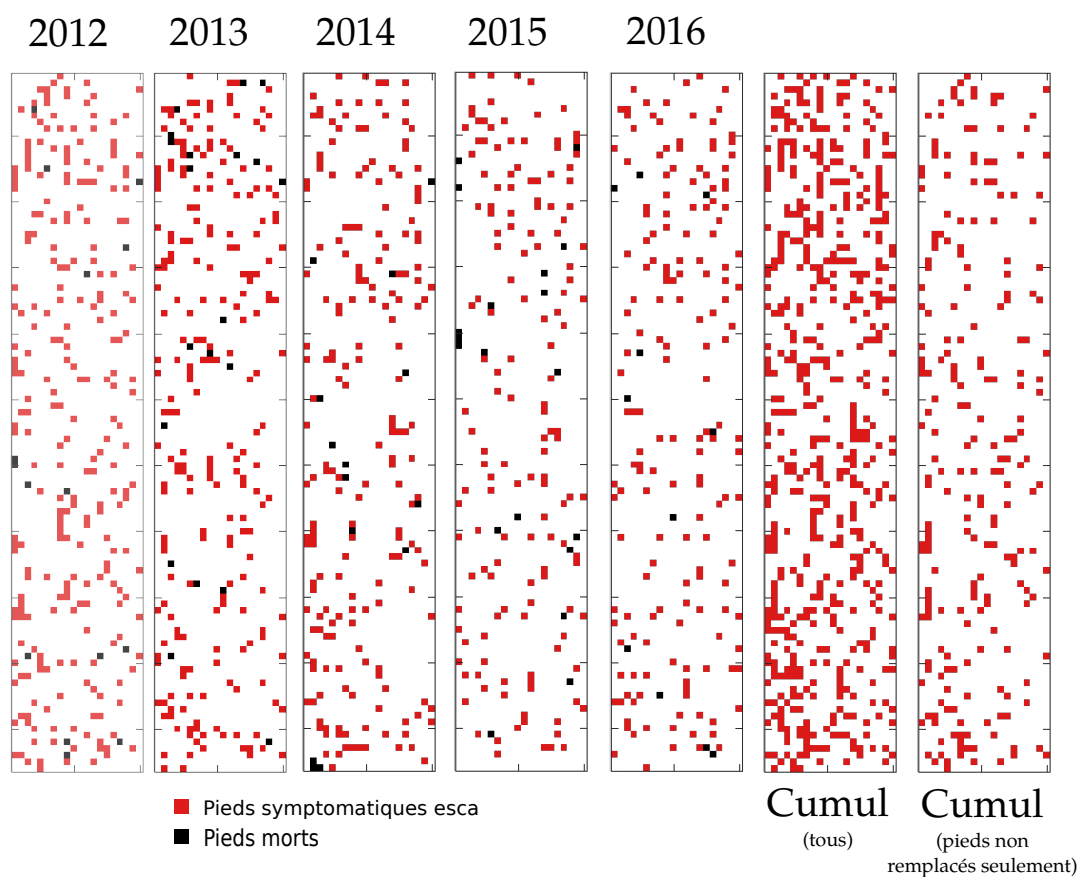


Figure 3.2 – Evolution sur 5 années de la position des pieds symptomatiques esca sur la parcelle sauvignon blanc.

Dans cette figure, les cinq premières colonnes indiquent la position des pieds symptomatiques et morts pour cinq années de mesure. De grandes différences sont constatées entre les années, il est difficile de trouver des similarités en dehors de certains pieds ayant tout le temps exprimé des symptômes. La multitude de pieds ayant exprimé des symptômes sur ces 5 ans se retrouve dans la 6ème colonne, où le cumul est réalisé. Le cumul n'est cependant pas forcément le plus adapté pour décrire la parcelle sur la dernière année de mesures car certains pieds ont pu être remplacés entre temps (pour une quelconque raison pas nécessairement liée à l'esca). Le cumul de la 7ème colonne permet de corriger ce problème et propose ainsi une carte des pieds que l'on peut considérer comme étant malades lors de la dernière année. Bien évidemment, cela ne prend pas en compte d'éventuels pieds malades ayant exprimé des symptômes seulement avant 2012.

Si on considère l'évolution de chaque pieds individuellement, il est possible de déterminer le nombre d'apparitions des symptômes sur les 5 années. Le tableau 3.2 indique cette fréquence d'apparition.

Tableau 3.2 – Fréquence d'apparition des symptômes en 5 ans pour les pieds de la parcelle sauvignon blanc. Le nombre entre parenthèse précise le nombre parmi eux ayant été remplacés

| Nombre d'apparitions de l'esca en 5 ans | 0 | 1 | 2 | 3 | 4 | 5 |
|---|------------|----------|---------|--------|--------|-------|
| Nombre de pieds | 1789 (220) | 206 (60) | 83 (11) | 29 (3) | 12 (0) | 4 (0) |

Environ la moitié des pieds symptomatiques recensés (206) ne l'ont été qu'une fois durant les 5 ans, en sachant que 60 d'entre eux ont dépéri. Au contraire, seuls 4 pieds ont présenté les 5 années d'affilée des symptômes.

3.3.2 Evolution au cours d'un été

L'évolution estivale des symptômes est difficile à décrire car elle nécessite des passages réguliers sur les parcelles. On retrouve dans certaines études une quantification globale par parcelle ([104]) mais l'évolution individuelle de chaque pied n'est pas forcément connue. On peut cependant utiliser dans ce cas la comparaison entre mesures au début de l'été et mesures à la fin de l'été et constater l'évolution entre ces deux dates. On prendra ici l'exemple de la parcelle sauvignon blanc, représentée dans la figure 3.3.

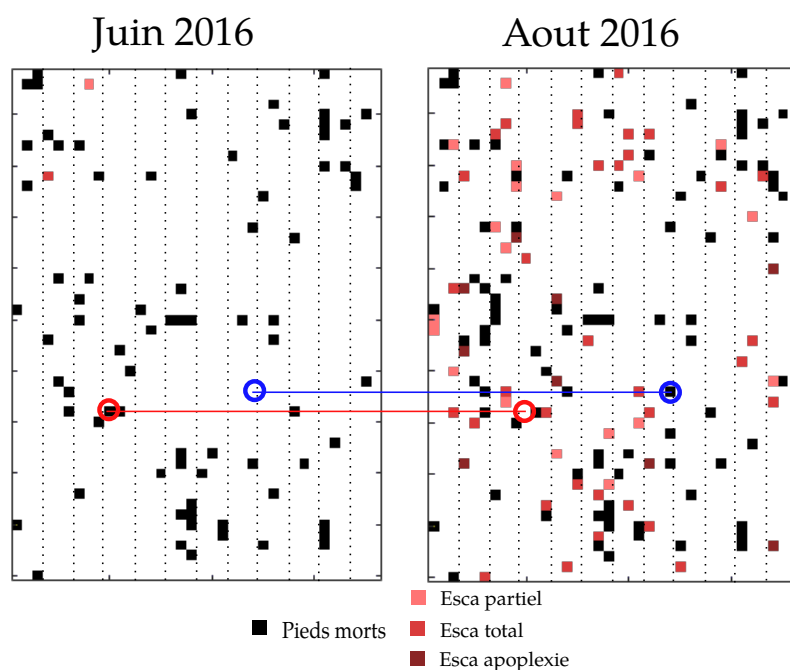


Figure 3.3 – Evolution sur un été de la position des pieds symptomatiques esca et des pieds morts

Ici le nombre de pieds symptomatiques augmente significativement entre fin juin et août, ce qui est logique et attendu. On dénombre ainsi seulement deux occurrences de symptômes en juin. Ici l'intensité de ces deux symptômes n'a pas évolué mais on aurait pu imaginer une aggravation voire un épisode apoplectique. D'autres observations peuvent être dégagées de ces cartes (en supposant que ces cas ne soient pas dus à une erreur de notation) :

- Un pied sans symptôme en juin peut être désigné mort en août (flèche bleue sur la figure)
- Des pieds morts peuvent être remplacés par un complant durant l'été (flèche rouge)

3.4 RÉPARTITION DES SYMPTÔMES

La répartition spatiale des symptômes est ici difficile à évaluer car tous les rangs ne sont pas échantillonnés pour la parcelle cabernet sauvignon et des décalages peuvent survenir avec la progression dans le rang pour la parcelle sauvignon blanc. Dans ce dernier cas, la répartition semble cependant aléatoire. Cela distingue l'esca de maladies comme la flavescence dorée au caractère épidémique (voir étude sur la répartition de la flavescence dorée en Annexe A). Peu de motifs d'agrégation non aléatoires sont ainsi constatés. Ces observations sont corroborées par certaines études sur la répartition de l'esca ([206], [180], [149]) ainsi que par les résultats d'une thèse sur la répartition spatio-temporelle de l'esca [174]. Cela signifie que l'on ne peut pas utiliser la position d'un pied pour déterminer son risque d'être malade et d'exprimer des symptômes.

3.5 CONCLUSIONS

Les deux parcelles étudiées fournissent un cadre d'étude de l'esca courant, dans lequel les occurrences de symptômes peuvent être rares et pour lesquelles la constitution d'une notation sanitaire spécifique est un processus long. Les améliorations possibles se heurtent aussi à ces contraintes. Par exemple, on pourrait imaginer une forme de notation avec détail des facteurs confondants ou un passage de chaque côté au pied pour rendre les mesures plus fiables mais cela se ferait au détriment du nombre de pieds évalués.

Les notations réalisées ne sont ici pas reliées à des mesures de la position géographique (par GPS ou méthode de mesure indirecte comme un ruban métrique déployé dans le rang) par choix. En effet, les applications en proxidétection envisagées ne nécessitent en théorie qu'un numéro de rang et de pied pour être géolocalisées.

Les positions des pieds symptomatiques au cours des années sont un outil précieux pour mettre en place l'échantillonnage sur les deux parties suivantes, particulièrement pour la partie hyperspectrale (validation de la détection précoce nécessitant un historique sur plusieurs années).

Deuxième partie

CLASSIFICATION ET DÉTECTION DES SYMPTÔMES FOLIAIRES DE L'ESCA PAR IMAGERIE RVB

Cette partie s'intéresse à l'apport de l'imagerie visible et de la vision assistée par ordinateur pour la détection de l'esca en conditions réelles au champ. Après avoir fait un tour d'horizon des applications et méthodologies de l'état de l'art, un protocole expérimental d'acquisition est proposé. Celui-ci sera appliqué durant l'été 2017 et aura conduit à la création d'une base de données étiquetée d'environ 2000 photographies/pieds de vigne et de 8000 imagerie (à l'échelle de la feuille) associés à une classe. Des approches SIFT et *deep learning* sont alors mobilisées pour la classification des feuilles d'esca et leur discrimination avec d'autres symptômes foliaires confondants. L'approche *deep learning* la plus performante est ensuite intégrée dans un réseau de détection (RetinaNet) permettant de déterminer la position des feuilles symptomatiques et, pour chaque pied, la surface symptomatique. Ce dispositif peut être monté sur tracteur et utilisé pour réaliser une cartographie automatique et exhaustive de la prévalence de l'esca sur une parcelle.

Sommaire

| | | |
|-------|---|----|
| 4.1 | Problématiques | 44 |
| 4.2 | Applications existantes en imagerie RVB | 45 |
| 4.2.1 | Définition du problème de classification | 45 |
| 4.2.2 | Exploitation simple de l'information couleur | 46 |
| 4.2.3 | Apport progressif de l'information spatiale : bords, formes et textures | 47 |
| 4.2.4 | Encodage et modélisation de descripteurs locaux : composition d'une image | 48 |
| 4.2.5 | Extraction de descripteurs profonds : la révolution du Deep Learning | 50 |
| 4.3 | Protocole expérimental | 53 |
| 4.3.1 | Dispositif d'acquisition | 53 |
| 4.3.2 | Échantillonnage | 55 |
| 4.3.3 | Observations sur la nature des données | 56 |
| 4.3.4 | Étiquetage des données | 57 |
| 4.4 | Détermination des classes | 59 |
| 4.5 | Détail des classes d'intérêt | 61 |
| 4.5.1 | Feuilles saines (témoin) | 61 |
| 4.5.2 | Esca | 62 |
| 4.5.3 | Facteurs confondants | 63 |
| 4.5.4 | Classes secondaires | 64 |
| 4.6 | Choix des approches méthodologiques abordées au chapitre 5 | 65 |

4.1 PROBLÉMATIQUES

La détection des symptômes foliaires à la parcelle recoupe deux problématiques successives :

- La première consiste à mettre en place un dispositif permettant d'acquérir des images automatiquement ou semi-automatiquement en proxidétection dans la parcelle.
- La deuxième consiste à créer la chaîne de traitement permettant d'aboutir à une détection des symptômes foliaires voulus en limitant selon les besoins le nombre de faux positifs (détections erronées) et/ou le nombre de faux négatifs (symptômes non détectés). Une méthodologie d'évaluation des résultats est de même construite pour quantifier les performances

La deuxième est ainsi construite sur la base des images fournies par la première. Afin de répondre aux deux problématiques, une connaissance de l'état de l'art actuel sur l'analyse d'image couleur et ses applications au végétal est nécessaire.

4.2 APPLICATIONS EXISTANTES EN IMAGERIE RVB

De la même façon que pour l'état de l'art initial sur les Maladies du Bois de la Vigne (MBV), on essaiera de considérer dans la mesure du possible des exemples présentant le plus de lien possible avec le sujet d'étude. D'autres applications utilisant des méthodologies différentes, seront toutefois présentées pour alimenter le panorama des techniques utilisées sur d'autres sujets d'étude. De façon générale, on peut distinguer 4 grandes familles d'applications où l'imagerie visible apporte une information intéressante et exploitable sur la plante.

- Caractérisation d'espèces et de sous-espèces (**diagnostic qualitatif**),
- Comptage d'organes (fleurs, fruits, bois) ou de la surface foliaire de la plante (**quantitatif**),
- Détection de plantes invasives autour de la culture (**qualitatif et quantitatif**),
- Détection de maladies et de stress abiotiques (**qualitatif et quantitatif**).

Les applications en détection de maladies sont à la fois qualitatives et quantitatives car l'objectif est dans un premier temps de détecter la maladie (état binaire) puis ensuite si possible d'apporter un diagnostic plus précis sur sa sévérité, en segmentant les zones atteintes et en mesurant leur surface. L'utilité d'un diagnostic quantitatif dépend cependant de l'application. Il serait aussi possible de réaliser plusieurs de ces opérations en même temps. Dans le cas de la vigne, on pourrait par exemple estimer le rendement en grappes dans une parcelle tout en cartographiant le niveau de sévérité lié à une ou plusieurs maladies. Ces différentes applications nécessitent cependant des méthodes d'analyse d'image différentes. La détermination d'une espèce peut par exemple être réalisée en analysant la forme des limbes foliaires tandis que la détection de maladies utilisera très certainement l'information couleur en priorité. Les approches détaillées par la suite peuvent s'apparenter à une évolution chronologique, des méthodes plus performantes apparaissant progressivement avec les progrès en vision par ordinateur et sont transférées vers le monde agricole. Il faut cependant garder à l'esprit que pour des applications spécifiques les méthodes à la pointe de l'état de l'art ne supplantent pas forcément des méthodes plus simples et anciennes basées sur des descripteurs simples.

4.2.1 Définition du problème de classification

La détermination de l'état sanitaire d'une feuille de vigne par un algorithme passe obligatoirement par la définition d'un problème de classification. Celui-ci consiste à apprendre des règles permettant de déterminer la classe d'un échantillon (ici une feuille) selon des descripteurs numériques. L'apprentissage des règles se fait à l'aide d'un classifieur, algorithme utilisant des échantillons d'apprentissage pour apprendre des règles

utilisables sur d'autres échantillons. Ces algorithmes appartiennent à la famille du *machine learning* et apprennent ainsi de façon semi autonome. Il existe de nombreux algorithmes de classification dans la littérature, tels que le *Support Vector Machine* (SVM) ou le *Random Forest*. Les descripteurs utilisés en entrée doivent alors permettre de discriminer au maximum les classes définies dans le problème. On détaillera par la suite diverses façons d'extraire des descripteurs informatifs dans une image ainsi que des exemples liés.

4.2.2 Exploitation simple de l'information couleur

L'information couleur est la première ressource simple utilisable dans une image Rouge Vert Bleu (RVB) classique à 3 canaux. Dans certains cas, un canal de l'image auquel on applique un seuil (arbitraire ou déterminé automatiquement par un algorithme dédié) peut suffire à résoudre un problème de classification. C'est le cas par exemple si l'on travaille en conditions contrôlées sur des feuilles isolées et que l'on cherche à segmenter les zones avec rougissements, ou si l'on cherche à masquer le sol nu sur une image de végétation. Ces méthodes, très nombreuses dans la littérature (exemple : détection de symptômes sur le blé [183]), peuvent alors être directement comparées au diagnostic humain. Dans le cas où l'on souhaite prendre en compte les 3 canaux de l'image, il est possible de considérer leurs valeurs ensemble (descripteurs à 3 attributs) en entrée d'un classifieur ou alors de considérer les canaux séparément et de fusionner les cartes de décision résultantes.

L'espace RVB n'est cependant pas forcément le plus adapté, il modélise la synthèse additive de 3 couleurs, ce qui signifie que l'information de teinte (couleur "pure") est dispersée entre les 3 canaux. Afin de remédier à ce défaut, des transformations vers un autre espace de type Teinte Saturation Valeur (TSV) ou L^*a^*b sont souvent introduites. L'espace TSV isole la teinte en un seul canal, sa pureté et son intensité étant contenus dans les deux autres canaux. L'espace teinte a cependant pour défaut majeur d'être cyclique, sa valeur maximale correspondant ainsi à la même teinte que sa valeur minimale, souvent fixée comme le rouge par convention. Il est important de préciser que ces espaces ne permettent pas de créer de l'information par rapport aux canaux RVB (une partie de l'information peut même dans certains cas être perdue lors de la transformation dans le nouvel espace) mais seulement de la réorganiser sous une forme différente. Il existe de même de nombreuses méthodes de transformation de l'information en un seul attribut. On citera par exemple les indices de végétations obtenus sur la base d'un calcul avec deux ou trois canaux (bien qu'ils soient majoritairement utilisés dans le domaine du multispectral et de l'hyperspectral comme développé dans le [chapitre 8](#)) ou les méthodes de type réduction de dimensionnalité telles que l'Analyse en Composantes Principales (ACP) ou l'Analyse Discriminante Linéaire (ADL).

Ces approches deviennent cependant assez vite limitées pour des symptômes plus complexes et des images en conditions réelles où l'éclairage n'est pas constant et où certains objets perturbateurs sont présents (sol, tiges, grappes, fils etc). Les voisinages entre pixels, la présence de formes, d'objets et leur disposition doivent alors être pris en compte.

4.2.3 Apport progressif de l'information spatiale : bords, formes et textures

L'information spatiale couvre toute information utilisant, d'une façon ou d'une autre, la disposition relative des pixels d'une image. L'information spatiale peut s'envisager à différentes échelles et à différents niveaux de complexité, la plus simple étant la différence relative entre pixels voisins, estimation du gradient local. Ce type d'information a donné lieu à la création de filtres appliqués sur l'image entière par convolution. Le filtre est appliqué localement à chaque pixel de l'image (et son voisinage) en calculant un produit de convolution. Ces filtres permettent par exemple d'obtenir une information sur les contours des objets (type filtre de Sobel) ou de lisser l'image à l'aide d'un noyau gaussien. Ces filtres d'apparence simples sont omniprésents en analyse d'image et peuvent servir de briques élémentaires pour des algorithmes plus complexes (tels que les réseaux de neurones convolutifs qui seront détaillés dans le paragraphe 4.2.4).

L'identification de plantes est une problématique ayant généré beaucoup d'études de reconnaissance de forme [199]. L'information de couleur seule n'y est pas suffisante car la plupart des végétaux ont des teintes de vert similaires. L'espèce peut cependant être retrouvée facilement en extrayant les caractéristique des bords de la feuille. Du côté des maladies, la détection du mildiou en conditions contrôlées est notamment abordée dans [203] à l'aide des transformées de Hough, dont la variante circulaire est dédiée à la détection robuste de cercles dans une image. Cette méthode a aussi logiquement été utilisée pour la détection de baies de raisins [129]. Combinées à l'information couleur (ou autre), l'information spatiale permet aussi par exemple de segmenter la végétation, c'est à dire la découper en zones homogènes [138].

L'analyse de texture s'attache entre autres à repérer des motifs locaux répétés dans une image de formes plus ou moins aléatoires. La principale difficulté de ce type d'analyse consiste à concevoir des descripteurs quantitatifs encodant la nature d'une texture, si possible en étant invariant à de nombreux paramètres tels que l'échelle, l'illumination ou la rotation. Ces méthodes ont un intérêt particulier pour la détection de maladies ou d'organes car les éléments rencontrés dans la vigne définissent parfois des textures locales, anisotropes ou isotropes, particulières [91]. Le calcul local de matrices de co-occurrence des niveaux de gris permet le calcul d'indices texturaux tels que les indices d'Haralick [72]. Ces indices sont souvent envisagés pour la détection de maladie en raison de leur simplicité d'utilisation. Grâce à leur complémentarité évidente à l'information couleur, une fusion couleur/texture peut alors être mise en œuvre [76] [90]. Dans le cas où la fusion entre descripteurs est réalisée avant la décision, on commence déjà à entrevoir des problèmes fondamentaux liés à la fusion de données de natures différentes.

La fusion entre attributs texturaux calculés sur des images visibles et sur des mesures ponctuelles de réflectance a été réalisée par Al-Saddik *et al.* [4]. Dans cette étude, une différenciation entre esca et flavescence dorée est réalisée à l'aide de la fusion de ces deux capteurs. Cette étude en condition de laboratoire montre le potentiel de deux types de capteurs et de descripteurs différents pour différencier plusieurs maladies entre elles. Dans ce type d'approche, les expériences en laboratoire servent de base pour de futures applications au champ en conditions réelles. La recherche sur l'analyse texturale a de

même fait émerger de nombreux descripteurs plus sophistiqués, tels que les ondelettes, les filtres de Gabor [150] ou les tenseurs de structure pouvant donner lieu à de multiples stratégies de modélisation des images. Les applications végétales vont de la détection de rang de vigne sur des images satellitaires [159] à la segmentation des organes de la vigne [2].

4.2.4 Encodage et modélisation de descripteurs locaux : composition d'une image

La principale difficulté rencontrée avec les tâches de classification et de détection d'une image est la complexité des images en conditions réelles. Celles-ci sont par nature extrêmement diverses et surtout l'information d'intérêt (une grappe, une feuille symptomatique) est entourée d'informations sans intérêt pour l'application (présence de tiges, sol, second plan). Ces dernières peuvent influencer les algorithmes si ceux-ci sont fondés sur des règles trop simples. Par exemple une tige lignifiée possède des teintes similaires à une feuille symptomatique et trompera vraisemblablement un algorithme basé sur un simple histogramme de teintes.

Au début des années 2000, de nouvelles méthodes encodant naturellement la composition des images ont été imaginées. Il en résulta d'énormes progrès pour des tâches de classification complexes telles que la reconnaissance de 1000 classes d'objets sur la base de données ImageNet. Ces méthodes reposent souvent sur l'utilisation de descripteurs locaux tels que les descripteurs SIFT [113]. De la même façon que les descripteurs texturaux, ces descripteurs résument une information locale par un attribut. Contrairement aux descripteurs texturaux, ces descripteurs ont cependant été pensés pour des images naturelles possédant de nombreuses formes différentes. L'intuition sur laquelle reposent les descripteurs SIFT est de mesurer des histogrammes de gradients orientés dans une grille dont les paramètres sont la position, l'échelle et l'angle (orientation dominante du gradient). Le descripteur ainsi obtenu possède des propriétés d'invariance intéressantes, notamment utilisées pour mettre en correspondance des photos prises depuis plusieurs points de vue.

Plus en détail, l'algorithme SIFT est en réalité décomposé en deux étapes indépendantes :

- La détection de points d'intérêt utilisant le plus souvent la méthode de différence de gaussienne (DoG) comme substitut rapide au laplacien de gaussiennes. Différentes valeurs d'écart-type σ sont utilisées pour le noyau gaussien afin de mettre en valeur les points d'intérêt à plusieurs échelles. Les extrema locaux sont alors détectés puis filtrés par leur intensité pour aboutir aux points d'intérêts de l'image. Une fenêtre est ensuite extraite autour de chaque point d'intérêt à son échelle correspondante puis la direction majoritaire du gradient est calculée sur la base d'un histogramme de magnitudes tous les 10° . Tous les pics à hauteur de 80% du plus grand pic sont aussi conservés pour créer d'autres descripteurs indépendants avec une orientation différente. Cette étape permet d'assurer l'invariance à la rotation des points d'intérêt. Deux tiges de taille et d'orientations différentes au dessus d'une feuille produiront donc théoriquement des descripteur similaires.

- Le calcul des descripteurs SIFT vient ensuite sur la base des points d'intérêt. Une grille de 4x4 cellules de taille variable est d'abord posée autour du point selon son échelle et son orientation. Pour chacun des sous blocs, un histogramme des gradients pour 8 directions est calculé, résultant en un vecteur de 128 valeurs agrégées. Diverses normalisations sont appliquées pour assurer l'invariance aux changements d'illumination.

Ces points d'intérêt décrivant les différents motifs locaux présents dans l'image peuvent alors être encodés à l'aide des approches dites "sacs de mots" [178], c'est à dire que l'on va classer les descripteurs locaux (mots) en un nombre fini de classes (le vocabulaire). On obtient alors en sortie un histogramme contenant le nombre d'occurrences de chaque élément du vocabulaire dans l'image. Les approches sacs de mots sont particulièrement adaptées aux images naturelles telles que les photographies. La combinaison entre descripteurs SIFT et encodage de type sacs de mots est schématisée dans la figure 4.1.




Figure 4.1 – Principe de la méthode d'encodage des descripteurs SIFT

Les approches basées sur l'encodage de descripteurs locaux sont depuis longtemps au centre de nombreuses applications de part leurs performances supérieures pour une vaste gamme de problèmes. L'application la plus importante de ces approches est la reconnaissance d'espèces végétales par analyse de leur feuille [202]. Dans ces études, les descripteurs locaux permettent d'encoder la forme des feuilles ainsi que la structure des nervures principales et secondaires. La mise en valeur fiable des nervures de la feuille demande cependant une très bonne résolution spatiale et des conditions d'éclairage contrôlées. D'autres études utilisent la fusion entre descripteurs SIFT et filtres de Gabor dans l'espace couleur TSV [90] ou font état de la création d'une application Android pour l'identification d'espèces [153]. Cette dernière utilise des descripteurs SURF, une variante rapide de SIFT. D'autres études plus originales utilisent les descripteurs SIFT pour l'identification des stades de floraison du riz en conditions réelles [69]. Dans ce cas, les descripteurs SIFT sont obtenus sur la base d'une grille de points régulièrement disposés sur l'image, sans passer par l'étape de détection de points d'intérêt. D'autres expérimentations plus poussées testent l'apport d'approches de fusions de couleurs ainsi que d'autres détecteurs de points d'intérêt pour la classification de fleurs sur plusieurs bases de données [171]. Des techniques texturales basées sur les *Local Binary Patterns* (LBP) [173] (pouvant être généralisés à la donnée couleur [105]) ou les histogrammes de gradients locaux (HoG) [125] sont aussi populaires dans la littérature et font appel à des descripteurs locaux de nature similaire.

La question de la détection de maladies a été abordée en conditions de laboratoire sur des feuilles scannées [146]. Dans cette étude, les meilleurs résultats ont été obtenus en utilisant une grille multi-échelles de points d'intérêt. Aucune étude n'existe dans le cas de l'esca mais l'encodage de descripteurs SIFT est une piste prometteuse pour prendre en compte la structure particulière des feuilles symptomatiques.

4.2.5 *Extraction de descripteurs profonds : la révolution du Deep Learning*

En 1998, les travaux de Yann LeCun [103] marquent précocement le début de l'ère de l'application des méthodes héritées des réseaux de neurones aux images. Appelé réseau de neurones convolutif (abrégé Convolutional Neural Network (CNN) dans la littérature), le dispositif fusionne les concepts de réseau de neurones classique (dont le principe est connu depuis les années 1960) et de filtres convolutifs simples (détecteurs de bords et de couleurs) communément utilisés en analyse d'image. Le réseau de neurones est un ensemble de couches contenant chacune un groupe de neurones, les couches étant reliées entre elles dans un grand réseau séquentiel interconnecté. Dans le cas des CNN, l'architecture embarque une partie convolutive qui extrait des descripteurs de l'image étudiée, suivie le plus souvent par un réseau neuronal classique (*Fully Connected*) qui procède à la prise de décision. Dans la partie convolutive, chaque neurone sera représenté par un filtre convolutif dont les coefficients du filtre ne sont pas choisis mais appris par la machine. L'activation en sortie du neurone est alors donnée après application d'une fonction d'activation le plus souvent non linéaire (par exemple la fonction ReLu avec une réponse linéaire pour les valeurs positives et nulle pour les valeurs négatives). Ainsi dans l'exemple de LeCun, le réseau simple LeNet a appris à reconnaître des chiffres sur de petites images de taille 32x32. Le réseau de filtres mis en place décompose l'information spatiale et l'activation sur les 10 derniers neurones (classes en sortie) donne le chiffre le plus probable. Les performances remarquables du réseau pour ce type de problème de classification ont poussé la communauté scientifique à développer de plus en plus les CNN, d'abord pour la classification d'images couleur [94], ensuite pour la détection d'objets et de parties d'objets dans les images [65] voire la description sémantique d'une scène. Malgré la simplicité des filtres, la profondeur de ces réseaux leur permet d'extraire des descripteurs très fins et de réaliser ces tâches de façon robuste et rapide. Cette profondeur complexifie l'interprétation des descripteurs obtenus, ce qui a été vivement critiqué malgré l'attrait des performances.




Figure 4.2 – Principe illustré de l’architecture d’un CNN (partie convolutive). Une image en entrée passe à travers un réseau de filtres pour obtenir une image finale de petite taille mais avec de nombreux canaux dans laquelle l’information est compacte. Cette image est alors mise à plat pour former le descripteur final de l’image

Les méthodes de *deep learning* se sont logiquement exportées dans le monde agricole, relançant l’intérêt pour des problèmes de vision par ordinateur jugés trop complexes auparavant. Le *deep learning* s’avère tout d’abord très efficace pour des tâches de classification impliquant de nombreuses classes, l’identification de maladies faisant partie des problèmes abordés [126]. Cette étude examine le potentiel d’un réseau de neurones convolutif pour la discrimination de 26 maladies sur 14 espèces différentes, en utilisant une base d’environ 50 000 images de feuilles acquises en conditions laboratoire contrôlées. L’utilisation du *deep learning* pour l’identification de feuilles est abordée dans [184] à l’aide d’un réseau convolutif de type ResNet [73]. Deux bases de données d’images y sont testées. La première base créée pour l’étude et non disponible au public contient des images en conditions réelles prises par un smartphone. La seconde est la base de données Flavia disponible publiquement contenant les feuilles (prises à plat en laboratoire) de 33 espèces.

Le rôle de la base de données d’entraînement a ainsi particulièrement évolué avec l’explosion des applications du *deep learning*. L’entraînement complet de réseaux convolutifs demande ainsi des bases de données conséquentes et variées afin d’estimer les paramètres du réseau (pouvant atteindre plusieurs dizaines de millions de paramètres). Sladojevic *et al* constituent une base de données d’imagettes couvrant plusieurs maladies en récupérant des images variées depuis internet [179]. Celles-ci sont donc de nature diverses et peuvent être autant des images acquises en laboratoire que des images acquises en conditions réelles. Des procédés de *data augmentation* sont ensuite utilisés afin de créer artificiellement de nouveaux échantillons. A chaque itération de l’apprentissage (appelée *epoch*), des modifications aléatoires sont appliquées aux images afin que le réseau ne "voit" pas en boucle les mêmes images. Les approches d’augmentation de données donnent la plupart du temps des résultats concluants pour limiter le surapprentissage des modèles de classification. Les auteurs mettent aussi en évidence le fait qu’une classe de fond contenant seulement des témoins négatifs (feuilles saines) est extrêmement bénéfique pour les performances. On peut supposer que cela permet au réseau d’éliminer l’information non pertinente pour la détection des maladies (grandes plages vertes sur le limbe, bord des feuilles etc).

Des bases de données standard utilisables par tous à des fins de recherche et parfois alimentées par les utilisateurs (*crowd-sourcing*) existent de même. La base PlantVillage [78] en est un exemple et contient une cinquantaine de classes présentant des couples espèce/maladie différents, celle-ci a pu être mobilisée pour des études impliquant le *deep learning* [56]. Il est à noter que la base contient des feuilles atteintes par l'esca acquises en laboratoire, bien que cela soit limité à un cépage. Afin de tirer partie de réseaux déjà entraînés, certaines études réalisent du *fine-tuning*, à savoir que les poids de ces réseaux sont légèrement modifiés pour être adaptés à un nouveau problème [190]. Seules les couches les plus profondes seront ainsi modifiées afin de conserver les propriétés générales des couches superficielles et d'apprendre de nouvelles règles spécifiques dans les couches profondes. Ces approches sont très populaires lorsqu'une base de données suffisamment importante n'est pas disponible. Le *fine-tuning* a de même été utilisé avec succès dans le cadre de l'identification de mauvaises herbes vues à la verticale [188].

Les performances sur des tâches de classification ont très rapidement incité à les généraliser pour réaliser des tâches plus complexes, la plus courante étant la détection de zones dans une grande image. Ce type de réseau utilise souvent un CNN classique utilisé comme extracteur de descripteurs et emboîté dans un autre réseau assurant les tâches de détection et de classification des zones. Ce type plus sophistiqué de réseau est utilisé dans [164] pour la détection de fruits divers en proxidtection. Les auteurs rapportent de bons résultats pour localiser par des boîtes englobantes la position des fruits, même en cas d'occlusions partielles de ces derniers. Les résultats sont cependant moins probants lorsque plusieurs types de fruits sont détectés en même temps sur les images. L'originalité de l'approche est aussi de fusionner la détection sur des images visibles et proches infra-rouges afin d'améliorer les performances. Ce type de fusion avec d'autres types d'images se retrouve dans certaines approches, son inconvénient étant qu'il sera alors impossible de profiter des modèles préentraînés sur des bases comportant uniquement des images RVB.

Fuentes *et al* différencient avec succès les symptômes de plusieurs maladies affectant les feuilles de tomate à l'aide d'un réseau convolutif de détection [59]. Les auteurs appliquent aussi des méthodes de visualisation des filtres convolutifs afin de mieux comprendre le fonctionnement du réseau. Cette volonté de contourner l'effet boîte noire est très marquée dans les applications construites sur la base du *deep learning* où le choix des descripteurs résulte d'un processus d'optimisation de la machine. Les auteurs notent que malgré les difficultés à comprendre les rouages du réseau, celui-ci a l'avantage d'être très flexible (détection naturelle d'objets de tailles différentes) et de nécessiter très peu de paramètres à régler manuellement. Des réseaux personnalisés peuvent de même être créés pour répondre à des problèmes spécifiques. Le réseau TasselNet est par exemple dédié au comptage des panicules du maïs en conditions réelles [114].

On peut remarquer plusieurs tendances fortes dans ces travaux modernes, tendant à devenir de plus en plus prononcées avec respectivement l'utilisation des descripteurs SIFT et du *deep learning* liés à un classifieur.

- Les **bases de données** tendent à devenir de plus en plus volumineuses, poussées par la volonté de prendre en compte la complexité des objets du réel dans leurs

conditions naturelles. Le nombre de classes augmente et l'étiquetage de la base devient de plus en plus complexe (détection, relation entre objets, description sémantique etc).

- L'étape d'**extraction de descripteurs** tend à être de moins en moins spécifique à un problème donné. La *transfer learning* consiste en l'utilisation d'extracteurs très généraux pour les appliquer à un problème différent, avec parfois de légères modifications apportées. Les grandes bases de données généralistes telles que ImageNet sont ainsi de plus en plus considérées pour le préentraînement du réseau.
- L'importance de l'étape de **classification** semble avoir été revue à la baisse au profit de l'étape d'extraction de descripteurs. Des classifieurs à la pointe de l'état de l'art tels que les SVM, les *Random Forest* (RF) ou les *Multi Layer Perceptron* (MLP) donnent le plus souvent des résultats satisfaisants. L'amélioration des performances passe ainsi beaucoup plus par les descripteurs utilisés et par les bases de données en amont.

La comparaison voire la complémentarité entre les approches SIFT et CNN reste encore d'actualité de nos jours. On trouve ainsi une étude comparant les deux pour la reconnaissance de plantes [139], résultant en des performances supérieures dans le cas du *deep learning*. Zheng *et al* présentent un ensemble complet de *benchmarks* des deux méthodes sur des bases généralistes, tout en mentionnant les possibilités d'utilisation conjointe [209]. Un exemple d'approche hybride est l'utilisation d'un réseau combinant les couches convolutives et l'encodage de celles-ci par les vecteurs de Fisher (variante de l'algorithme sacs de mots) [175].

Avant de faire le choix d'une ou plusieurs architectures à tester pour la classification et la détection de l'esca, nous fixerons dans un premier temps le protocole d'acquisition et d'étiquetage des images ainsi que les classes de feuilles à discriminer.

4.3 PROTOCOLE EXPÉRIMENTAL

4.3.1 Dispositif d'acquisition

Le dispositif d'acquisition se compose d'une caméra Rouge Vert Bleu (RVB) accompagnée d'un flash monté dans un boîtier avec vitre transparente (figure 4.3(a)). Le boîtier est alors monté à un montant lui même fixé sur le plancher d'une brouette ou d'un engin agricole. La caméra vise perpendiculairement à la direction de l'avancement, permettant ainsi de prendre les photos du palissage de la vigne dans son intégralité tout en avançant le long d'un rang (figure 4.3(b)).




Figure 4.3 – (a) - Détails du système d’acquisition monté dans le boîtier. (b) - Passage du dispositif dans une parcelle de vigne

La manipulation se fait à l’aide d’une application smartphone dédiée se connectant en wifi au boîtier d’acquisition et déclenchant de façon synchrone l’appareil photo et le flash. Le réglage du flash est primordial car il dépend des conditions de luminosité. En effet, une acquisition à l’aube aura besoin d’un flash important tandis que les acquisitions à la lumière directe du jour utiliseront un flash modéré (le risque étant de surexposer les feuilles et d’obtenir des pixels blancs saturés comme illustré dans la figure 4.4).



Figure 4.4 – Influence du flash sur les prises de vue. Gauche : éclairage naturel. Droite : utilisation du flash avec légère surexposition.

Deux modes de prise de vue sont alors possibles :

- **Manuel** : permet de réaliser une acquisition pied à pied sans avoir à avancer dans le rang à une vitesse définie constante. Le dispositif est alors fixé sur une brouette.
- **Automatique** : utilise un pas de temps réglé. Utile dans le cas où le dispositif est monté sur un engin agricole à vitesse constante

Le choix s’est porté pour nos expérimentations sur le mode manuel. Deux objectifs dont un grand angle ont été testés, l’objectif normal permet de couvrir intégralement un pied (sauf lorsqu’un rameau déborde sur un autre pied) et a donc été conservé. Les images obtenues sont de taille 2592 x 2048 pixels, permettant de conserver une résolution millimétrique pour les feuilles. Les prises de vue sont globalement nettes, même en cas

de vent ou d'avancée discontinue de la brouette dans les rangs à cause de la rugosité du sol. Des exemples de photographies de pieds sont présentés dans la figure 4.5.

Avancement dans le rang




Figure 4.5 – Exemple de photographies de 5 pieds consécutifs obtenus avec le dispositif d'acquisition

4.3.2 Échantillonnage

Comme montré dans le [chapitre 3](#), les pieds atteints par l'esca et exprimant des symptômes une année donnée sont assez rares (environ 5%). Leur expression est de même globalement spatialement homogène. Sur les parcelles en blanc et en rouge, les 50 premiers pieds ont été échantillonnés un rang sur deux afin d'obtenir une couverture homogène de la parcelle. Ensuite, les pieds atteints par l'esca seulement dans les autres rangs ont été visités afin de compléter la base de données. Les pieds sains n'ont ainsi pas été visités dans ces rangs, car le nombre de témoins négatifs était déjà très important en ne prenant en compte qu'un rangée sur deux. Une autre exploitation viticole, le château Luchey-Halde (Bordeaux Sciences-Agro) à Merignac a de même été visité avec le dispositif, sa particularité étant de fournir de nombreux exemples de facteurs confondants. La campagne Advantage de 2017 a ainsi permis l'acquisition d'environ 1100 pieds, dont presque 800 ont été étiquetés. Les autres pieds, en grande majorité des pieds sains, ne seront pas utilisés.

En plus de cela, des données complémentaires ont été collectées sur des parcelles provenant d'autres projets en utilisant le même dispositif d'acquisition. Des photographies issues du projet EARN (estimation du rendement de la vigne) prises en Gironde ont ainsi été mobilisées. En plus d'augmenter significativement le nombre de photographies dans la base, ces données annexes permettent de même d'enrichir une diversité de cépages et de conditions d'éclairage. Des dizaines de milliers de photographies étant disponibles sur l'année 2016, une sélection a été réalisée contenant principalement des pieds atteints de l'esca avec des motifs visibles sur les feuilles. Les données de la campagne 2017 portent aussi sur des données du projet EARN, cette fois ciblées sur un rang d'une parcelle en blanc et un rang en rouge. Certaines de ces données présentent aussi l'avantage d'avoir fait l'objet de revisites à plusieurs stades de l'été. Le [tableau 4.1](#) résume les données utilisées pour la détection des symptômes visibles qui s'étalent sur les étés 2016 et 2017.

Tableau 4.1 – Base de données d’images RVB utilisée pour la création des bases de données MBV. Les acquisitions Advantage de 2017 sont mélangées à de précédentes acquisitions.

| | | Date de prise de vue | Nombre d’images (étiquetées) |
|----------------|----------------------|--------------------------|------------------------------|
| ADVANTAGE 2017 | Sauvignon blanc | 17 août 2017 - 11h ~ 13h | 445 (284) |
| | Cabernet sauvignon | 19 août 2017 10h ~ 12h | 341 (282) |
| | Château Luchey-Halde | 24 août 2017 14h ~ 16h | 367 (235) |
| EARN 2017 | Merlot juillet | 28 juillet 2017 ~10h | 127 (36) |
| | Merlot | 31 août 2017 ~9h | 127 (59) |
| | Merlot | 14 septembre 2017 ~15h | 130 (26) |
| | Sauvignon | 28 juillet 2017 ~11h | 115 (31) |
| | Sauvignon | 31 août 2017 ~9h | 111 (88) |
| EARN 2016 | Merlot | 6 octobre 2016 ~8h | 85 (85) |
| | Sauvignon | 22 août 2016 ~12h | 88 (88) |
| | | | 1809 (1214) |

4.3.3 Observations sur la nature des données

Le protocole d’acquisition produit une image par pied de vigne (figure 4.5) mais certains défauts d’acquisition peuvent subsister. Les images ne sont ainsi pas parfaitement bien centrées sur les ceps. Le tronc est considéré comme le repère permettant de centrer l’objectif à chaque photographie. Cependant il ne correspond pas forcément au "centre" de la partie foliaire de la plante, certains bras étant parfois plus développés. De même, le pied de vigne n’est pas non plus pris dans toute sa verticalité. La zone en dessous des feuilles les plus basses est bien sûr hors champ mais une partie de la zone supérieure peut aussi être coupée. Cela n’est pas gênant car la présence de symptômes dans la partie supérieure est très sûrement accompagnée de symptômes dans la partie centrale. La proportion du pied apparaissant dans l’image dépend principalement de la parcelle, certaines parcelles avec un palissage très haut étant quasi impossibles à photographier en entier, d’autres étant plus compactes. Étant donné que la mise au point est faite sur le plan de la vigne, les rangs situés au second plan apparaîtront flous mais certains de ses éléments peuvent quand même être distingués.

La résolution des organes de la vigne est variable lorsque l’on travaille en proxidtection. Le premier élément qui conditionne la résolution est bien sûr le placement du capteur : lorsque l’on avance dans le rang, celui-ci peut devenir légèrement plus proche ou plus éloigné de la cible. Elle dépendra aussi du type de parcelle et de l’inter-rang utilisé : certaines parcelles très étroites obligent à se placer très près du palissage (ce qui peut pousser à utiliser un objectif grand angle dans ce cas). La source la plus importante de modification de la résolution est en réalité la géométrie de la vigne. La croissance des

vignes est contrainte par le palissage mais il existe des cas où des tiges et feuilles vont s'en éloigner. La résolution de ces objets sera donc plus élevée car ils sont plus proches du capteur. Habituellement une feuille est globalement contenue dans un carré de 250 pixels de côté, il arrive cependant que certaines prennent plus de place. Ces feuilles peuvent aussi être floues et/ou surexposées et alimenter des bases d'échantillons aberrants mais fréquents qu'il convient de prendre en compte. Le stade phénologique influe de même sur les clichés des organes, particulièrement pour les grappes de raisin dont la couleur et la taille sont variables.

4.3.4 Étiquetage des données

L'étiquetage des données consiste à définir des zones dans les images de base et leur donner des classes. Ces données seront utilisées plus tard pour l'apprentissage, à savoir dans notre cas apprendre à reconnaître les symptômes de l'esca.

L'étiquetage est cependant complexe car les éléments d'intérêt d'un pied de vigne n'ont pas tous la même taille et la même forme. La délimitation du tronc ne se fait par exemple pas à la même échelle qu'une feuille ou qu'une tige. La délimitation de ces éléments peut de même être plus ou moins grossière :

- *délimitation par des boîtes englobantes* : l'objet d'intérêt est délimité par un rectangle de coordonnées connues. L'opération est simple et facile mais le rectangle ne contiendra pas seulement l'objet d'intérêt.
- *délimitation précise* : l'objet est délimité par une forme couvrant au pixel près la zone d'intérêt. L'opération est beaucoup plus longue que pour les boîtes englobantes mais la zone ne contient que l'objet d'intérêt. Il est de même possible de convertir la zone en rectangle englobant si besoin, l'inverse n'étant pas possible automatiquement.

Dans cette étude, la délimitation par boîtes englobantes est retenue. Les algorithmes de classification courants utilisent cependant souvent en entrée des images carrées de taille fixe. Il sera donc nécessaire d'adapter ensuite ces boîtes englobantes pour l'extraction d'images au format standard, comme indiqué dans la figure 4.6. On choisit une taille fixe de 224x224 pixels pour deux raisons : il s'agit d'une taille standard très utilisée pour la classification d'images (par les Convolutional Neural Network (CNN) par exemple) et cette taille correspond naturellement dans nos images à l'emprise moyenne des feuilles.




Figure 4.6 – Création d’imagettes carrées à partir d’une annotation rectangulaire (en blanc)
Rouge : Conservation de la surface du rectangle d’origine
Bleu : Patch de taille fixe (ici 224 x 224)

L’étiquetage des feuilles pose cependant un autre problème : il n’est pas toujours pertinent d’annoter les feuilles une par une. Une feuille isolée est très facile à annoter mais un amas de feuilles superposées ne l’est pas. Or cette situation est en réalité plus fréquemment rencontrée que celles de feuilles parfaitement isolées (plus proches d’une acquisition en laboratoire). Afin de prendre en compte cette source de variabilité importante, on décidera d’annoter de façon variable les échantillons. Dans le cas des amas de feuilles difficiles à distinguer, certaines annotations ne couvriront qu’une feuille tandis que d’autres seront à cheval sur plusieurs feuilles. On ne considère pas ainsi les feuilles en tant qu’unités distinguables mais plutôt comme des zones très variables dont on veut connaître l’état sanitaire. Bien qu’arbitraire et difficile à formaliser, ce choix permet d’introduire une grande diversité de situations dans la base.

Du point de vue pratique, le choix s’est porté sur le programme LabelImg écrit en Python/QT et utilisable sur n’importe quelle version récente de Windows ou distribution Linux¹ (figure 4.7). Le programme propose une interface graphique dans laquelle, pour une liste d’images, l’utilisateur peut créer des rectangles associés à une classe (les classes sont définies au préalable dans un fichier de configuration éditable). Les résultats peuvent ensuite être exportés sous forme de fichiers .xml facilement exploitables.

1. <https://github.com/tzutalin/labelImg>



Figure 4.7 – Interface du programme de labelisation LabelImg (Python, QT)

4.4 DÉTERMINATION DES CLASSES

La détermination des classes est liée au problème de classification que l'on souhaite résoudre. Dans notre cas, le problème le plus simple consiste à séparer les feuilles saines des feuilles atteintes par l'esca. L'enjeu est ici de rechercher des descripteurs permettant de séparer facilement ces deux classes entre elles. La figure 4.8 schématise ce problème pour une classification binaire en considérant que les descripteurs de chaque classe sont répartis à l'intérieur d'un cercle englobant. La qualité de la classification dépendra ainsi de la superposition entre ces ensembles, la classification parfaite étant possible si les cercles ne se rencontrent jamais. On dit alors qu'une séparation parfaite entre les classes est possible dans l'espace des descripteurs. Cette séparation est apprise par le classifieur sur la base des images d'apprentissage. Il est aussi possible d'évaluer la qualité de la séparation en mesurant la proportion de Vrais Positifs, Faux Positifs, Vrais Négatifs et Faux négatifs engendrés par la séparation. Par exemple, vouloir bien classer tous les échantillons atteints de l'esca pourra entraîner des échantillons de feuilles saines mal classés (faux positifs)




Figure 4.8 – Schématisation d'une classification binaire avec deux ensembles plus ou moins séparables - Gauche : Séparation parfaite, Milieu : Séparation satisfaisante mais avec compromis, Droite : Séparation médiocre. Flèche : Séparation optimale entre les ensembles

Si l'on souhaite prendre en compte également les autres symptômes rencontrés dans la vigne, cela nécessite au minimum une troisième classe. L'introduction des facteurs confondants change ainsi le problème de classification, comme illustré dans la figure 4.8. Celui-ci devient plus complexe car il faut séparer les classes 2 à 2 et prédire la bonne classe parmi les 3. Séparer l'esca des feuilles saines ne sera pas forcément suffisant si celles-ci se superposent aux facteurs confondants. Le jeu de règles apprises est donc plus complexe et les descripteurs choisis devront être pertinents pour chaque classe.




Figure 4.9 – Schématisation d'une classification multi-classes avec 3 ensembles. Flèche : Séparation optimale entre l'ensemble MBV et les autres ensembles

Cependant ce schéma est une vision théorique, les données réelles s'en éloignent fortement. Ici le nombre d'échantillons pour la classe de contrôle (feuilles saines) excède largement celui des classes d'intérêt. Les échantillons liés aux autres symptômes devraient cependant être fractionnés en plusieurs sous-classes (flavescence, carences, mildiou, desèchements etc), plus ou moins faciles à distinguer de l'esca. De même, la classe esca pourrait aussi être sub-divisée en sous-classes selon la sévérité des symptômes rencontrés. On s'attend alors à ce que les symptômes prononcés soient bien séparés des autres classes tandis que les symptômes moins évidents puissent être confondus dans l'espace des descripteurs. Cette situation réelle est schématisée dans la figure 4.10.




Figure 4.10 – Schématisation d’une classification multi-classes en conditions réelles avec la classe des autres symptômes découpée en 7 autres classes et des déséquilibres entre classes

Plusieurs stratégies sont envisageables pour gérer le problème :

- Considérer la discrimination binaire feuille saine/esca seulement et tester le modèle sur les autres symptômes ensuite.
- Considérer une classe par type de symptômes quitte à avoir de nombreuses classes avec très peu d’échantillons (parfois moins de 10).
- Considérer l’ensemble des autres symptômes comme une classe de facteurs confondants.

On fera le choix dans cette étude de considérer tous les facteurs confondants dans une seule classe plus vaste. La deuxième option aurait cependant été la plus pertinente dans le cas où la base de données aurait été plus représentative.

4.5 DÉTAIL DES CLASSES D’INTÉRÊT

Le trio principal de classes se compose ainsi d’une classe de témoins négatifs (feuilles saines), d’une classe d’intérêt (la classe esca) et d’une classe de facteurs confondants (autres troubles de la vigne). A ces 3 classes principales s’ajoutent des classes secondaires décrivant le reste du pied de vigne.

4.5.1 Feuilles saines (témoin)

Les feuilles saines englobent toutes les feuilles sans symptômes visibles ou alors dont les symptômes sont imperceptibles à l’œil. Comme indiqué plus tôt, les imgettes peuvent être composées d’une unique feuille ou d’un ensemble de feuilles superposées. L’exposition des feuilles est de même variable et des parties de tige, grappes ou fils peuvent parfois apparaître en premier plan.



Figure 4.11 – Exemple d’imagettes de végétation saine

Le nombre d’imagettes étiquetées par pied de vigne est variable. Étant donné que la classe feuille saine peut être vue comme un témoin négatif majoritairement présent dans le palissage, toutes les parties foliaires d’une photographie ne sont pas étiquetées. On cherchera surtout à délimiter des échantillons autant variés que possible.

4.5.2 *Esca*

Afin de prendre en compte la sévérité des symptômes, les feuilles symptomatiques esca ont été divisées en 3 sous catégories, servant ainsi de sous-classes, aussi résumées dans la figure 4.12 :

- $Esca_3$: Symptômes très bien définis sur l’imagette, limbe en grande partie affecté, pas de zones d’occlusions,
- $Esca_2$: Symptômes moins prononcés, feuille en partie affectée avec possibles occlusions,
- $Esca_1$: Symptômes faibles et/ou avec une forte occlusions. Imagettes difficiles pouvant être confondues avec d’autres troubles.



Figure 4.12 – Exemple d’imagettes de feuilles présentant des symptômes de l’esca.

Première ligne : Symptômes prononcés (Esca3)

Seconde ligne : Symptômes modérés (Esca2)

Troisième ligne : Symptômes faibles (Esca1)

Cette délimitation est en partie arbitraire, la visibilité d’un symptôme est parfois difficile à déterminer. La classe esca sera utilisée dans sa globalité pour l’apprentissage. Les sous-classes ne serviront qu’à déterminer la sensibilité de nos algorithmes à la sévérité des symptômes.

4.5.3 Facteurs confondants



Figure 4.13 – Exemple d’imagettes d’autres troubles de la vigne

Les autres troubles de la vigne sont un mélange de tous les autres symptômes rencontrés sur les vignes échantillonnées. Ces symptômes peuvent être dus à des carences, des dégâts d'insectes, des maladies type mildiou/black rot ou de la flavescence (non rencontrée dans les parcelles du projet Advantage).

4.5.4 Classes secondaires

D'autres classes sont naturellement présentes dans la vigne mais sont secondaires pour notre application. Elles ne seront pas utilisées pour la classification mais auront un rôle potentiel pour la détection afin d'éviter l'apparition de faux positifs esca sur ces parties de l'image. L'approche consistera ainsi à prendre en compte comme des classes à part entière les organes de la vigne. Une autre approche consisterait à réaliser au préalable une pré-segmentation des images afin de ne conserver que la partie foliaire. Cette étape est cependant difficile car elle ne doit pas rejeter les feuilles symptomatiques. Ces classes, au nombre de 5 (grappes, tiges, bois, sol, ciel) sont détaillées dans la figure 4.14.




Figure 4.14 – Exemple d'images appartenant aux classes secondaires rencontrées dans la vigne (ligne par ligne : grappes, tiges, bois, sol, ciel)

Le tableau 4.2 résume le nombre d'échantillons pour les 3 classes principales. Les échantillons y sont séparés selon le cépage de provenance, en raison de quelques différences entre les symptômes esca sur cépage blanc et ceux sur cépages rouges.

Tableau 4.2 – Détail du nombre d’imagettes par classe dans les deux bases de données

| | Témoin | Esca | | | | Total Esca | Confondants | Total |
|--------------|-------------|------------|------------|------------|-------------|-------------|-------------|-------|
| | | Esca1 | Esca2 | Esca3 | | | | |
| Cépage blanc | 1554 | 326 | 165 | 43 | 534 | 630 | 2718 | |
| Cépage rouge | 2045 | 259 | 218 | 60 | 537 | 953 | 3535 | |
| Total | 3599 | 585 | 383 | 103 | 1071 | 1583 | 6253 | |

4.6 CHOIX DES APPROCHES MÉTHODOLOGIQUES ABORDÉES AU CHAPITRE 5

Parmi les méthodes présentées, plusieurs pourraient être utilisées pour la détection des Maladies du Bois de la Vigne (MBV). Afin de choisir, il est d’abord nécessaire de traduire en terme d’analyse d’image numérique la description des symptômes faite au [chapitre 2](#). Il y est indiqué que les symptômes esca se traduisent par des transitions de couleur le long des nervures principales et secondaires de la feuille. En plus de la richesse en teintes de l’image de la feuille, cela signifie aussi que de nombreux gradients doux de teintes y sont présents, et ce avec des orientations variées. Certains gradients sont aussi symétriques : la transition vert - jaune - rouge sera suivie par la transition inverse de l’autre coté d’une nervure. D’autres motifs seront aussi circulaires, une tache rouge étant entourée par un rebord jaune. Des exemples de motifs variés rencontrés sur les faciès esca sont énumérés dans la figure [4.15](#). En plus de cela de nombreux éléments extérieurs sont présents sur les imagettes de feuilles. Il est difficile d’isoler des feuilles seules, celles-ci sont la plupart du temps accompagnées de tiges ou de grappes, recouvertes par d’autres feuilles et plus généralement ne sont pas devant un fond uniforme. Cette composition complexe appelle à considérer des algorithmes prenant en compte tous les éléments d’une image et retenant l’information essentielle sous forme de descripteurs.




Figure 4.15 – Exemples de motifs locaux 48x48 rencontrés sur des feuilles avec faciès esca. Première ligne : Cépage rouge. Deuxième ligne : Cépage blanc

Des méthodes simples basées sur la répartition des couleurs dans l'image seront d'abord considérées. On se concentra ensuite sur les deux grandes familles d'approches détaillées plus tôt, à savoir l'encodage de descripteurs SIFT et les réseaux de neurones convolutifs. Les enjeux sont cependant différents pour les deux méthodes et la comparaison entre les deux est d'un intérêt particulier car le *deep learning* peut être vu comme une forme automatisée de la démarche de conception des descripteurs complexes comme les SIFT. On s'intéressera tout particulièrement à la technique du *transfer learning* conduisant à utiliser des réseaux de neurones convolutifs appris pour des problèmes d'analyse d'image très généraux pour les appliquer à un problème spécifique. Comme on l'a remarqué dans l'état de l'art, ceux-ci sont très intéressants lorsque la base de données pour l'apprentissage n'est pas de taille suffisante. C'est le cas de notre étude au vu de la rareté relative des symptômes d'esca par rapports aux feuilles non symptomatiques.

CLASSIFICATION DES SYMPTOMES VISIBLES DE L'ESCA :
COMPARAISON DES MÉTHODES D'ENCODAGE SIFT ET DES
MÉTHODES DEEP LEARNING

Sommaire

| | | |
|--------|---|-----|
| 5.1 | Méthodologie de comparaison | 67 |
| 5.1.1 | Choix du classifieur | 68 |
| 5.1.2 | Partitionnement des échantillons | 68 |
| 5.1.3 | Indicateurs pour l'évaluation des résultats | 69 |
| 5.1.4 | Visualisation des descripteurs | 70 |
| 5.2 | Expérimentations descripteurs SIFT | 70 |
| 5.2.1 | Espaces de représentation | 70 |
| 5.2.2 | Information couleur simple | 72 |
| 5.2.3 | Information couleur locale | 75 |
| 5.2.4 | Approches SIFT et dérivées | 81 |
| 5.2.5 | Stratégies de fusion de l'information | 85 |
| 5.2.6 | Fusion des canaux pour une image couleur | 85 |
| 5.2.7 | Fusion des descripteurs SIFT avec des histogrammes couleur simples | 86 |
| 5.2.8 | Taille des dictionnaires d'encodage | 87 |
| 5.2.9 | Performances de classification | 87 |
| 5.2.10 | Résumé des expérimentations SIFT | 91 |
| 5.3 | Approches Transfer Learning | 92 |
| 5.3.1 | Motivations au deep learning | 92 |
| 5.3.2 | Modèles envisagés | 92 |
| 5.3.3 | Implémentation des algorithmes et modèles | 94 |
| 5.3.4 | Stratégie d'entraînement du réseau | 94 |
| 5.3.5 | Espaces de représentation | 97 |
| 5.3.6 | Expérimentation transfer learning | 97 |
| 5.3.7 | Résultats | 98 |
| 5.3.8 | Visualisation du fonctionnement du réseau | 102 |
| 5.4 | Résumé : Comparaison entre les deux approches | 104 |

Ce chapitre décrit la méthodologie et les résultats obtenus pour la classification des images de feuilles de la base de données créée au [chapitre 4](#). L'objectif est de différencier les feuilles symptomatiques esca des feuilles saines mais aussi des autres troubles de la vigne. Après avoir défini le protocole d'expérimentation et les métriques de comparaison envisagées, les deux méthodes seront successivement comparées.

5.1 MÉTHODOLOGIE DE COMPARAISON

L'étape d'extraction de descripteurs est une étape dite de "goulot d'étranglement" (*bottleneck*), dans le sens où les descripteurs sont une représentation compacte et standardisée

de l'image que l'on espère informative. Ces descripteurs peuvent ensuite être utilisés la classification. Les images en entrée sont standardisées (image carrées de taille 224x224 pixels) mais la taille des descripteurs varie selon la méthode utilisée. Il n'est pas possible en soit de quantifier l'efficacité des descripteurs dans leur forme brute. La performance de la tâche de classification en aval utilisant ces descripteurs peut cependant être facilement quantifiée car elle dépend du nombre d'échantillons bien classés sur une base de test. Il est de même possible de visualiser les descripteurs dans un espace à 2 dimensions à l'aide de méthodes de réduction de la dimensionnalité.

5.1.1 *Choix du classifieur*

Dans cette étude, on fera le choix du classifieur Support Vector Machine (SVM) [37]. Le classifieur SVM est couramment utilisé pour une vaste gamme de problèmes. Ses performances sur des applications concrètes et variées en ont fait une méthode de référence. En termes simples, l'algorithme SVM dans sa forme linéaire cherche un hyperplan permettant de séparer au mieux les données. Afin de prendre en compte la structure non linéaire de certains types de données, un noyau peut être utilisé comme par exemple le noyau gaussien Radial Basis Function (RBF).

Il est possible aussi d'utiliser des métriques différentes lorsque l'on calcule la matrice de distances entre échantillons en entrée du SVM. La plupart des implémentations du SVM considèrent par défaut une distance euclidienne et calculent donc la matrice selon cette métrique. Dans la réalité on peut avoir besoin d'autres métriques, comme par exemple la métrique du χ^2 lorsque l'on souhaite comparer deux histogrammes (approches sacs de mots par exemple).

En résumé les paramètres de l'algorithme SVM pour la classification sont :

- Noyau RBF
- Distance du χ^2 ou euclidienne selon la situation
- Détermination automatique de σ (50 valeurs en échelle logarithmique de 2^{-8} à 2^5) par Validation Croisée avec 20% d'échantillons de validation et 5 répétitions. Sur les tests effectués, peu de différences ont été constatées entre 5, 10 et 20 répétitions, le paramètre σ obtenu reste similaire.

5.1.2 *Partitionnement des échantillons*

Le partitionnement consiste à choisir les échantillons qui seront utilisés pour l'apprentissage et ceux qui seront utilisés pour le test (on y applique les métriques d'évaluation). La proportion d'échantillons d'apprentissage et de test peut être variable, le plus simple étant de considérer 50% de chaque, valeur qui sera utilisée par défaut dans les expérimentations. Le déséquilibre entre classes est problématique pour la séparation car une classe sur-représentée aura plus d'influence lors de l'évaluation des performances. Afin de parer à cela, on considère des classes avec le même nombre d'échantillons pour le jeu d'apprentissage et de test (400 échantillons par classe pour une séparation 50/50).

Les performances peuvent fluctuer selon les sous-ensembles d'apprentissage et de test générés. Afin de comparer les résultats, on utilisera une approche classique consistant à tester plusieurs ensembles apprentissage/test puis à moyenner les performances. On considérera un ensemble de 10 séparations pour les échantillons de la base cépage blanc et autant pour ceux de la base cépage rouge. Ces ensembles seront générés au préalable de façon aléatoire puis utilisés de la même façon pour toutes les expérimentations de ce chapitre, que ce soit pour les descripteurs issus de SIFT ou des couches d'un Convolutional Neural Network (CNN).

5.1.3 Indicateurs pour l'évaluation des résultats

La précision globale (*Overall Accuracy*) pour toutes les classes (C classes au total) peut être vue comme la moyenne pondérée par le nombre d'échantillons des précisions par classe, ou tout simplement comme la proportion de bonnes classifications V (quelle que soit la classe) parmi le nombre total d'échantillons N .

Évaluer les sous-classes est un peu plus difficile. On ne s'intéresse pas à la prédiction en sous-classes, mais simplement au détail de la prédiction dans une classe en considérant le niveau de sévérité de l'esca. La précision pour les sous-classes esca est calculée en considérant la proportion d'échantillons dans la sous-classe prédits dans la bonne classe. La moyenne pondérée de ces précisions par sous-classes permet ainsi de retrouver la précision pour la classe.

Les prédictions sont d'une certaine manière limitées car on considère seulement la classe attribuée "en dur", sans considérer le degré de confiance associé à la prédiction. Le classifieur SVM de base ne permet pas d'obtenir un indice de confiance sur les prédictions mais certaines extensions le permettent. Parmi les approches présentes dans littérature, celle de Platt [148] présente l'avantage d'estimer directement depuis le jeu de données d'apprentissage une correspondance entre les scores du SVM et une distribution de probabilités en sortie. L'intuition derrière l'approche de Platt est d'avoir constaté que les scores des échantillons d'apprentissage suivent la distribution d'une fonction sigmoïde, avec une rupture plus ou moins marquée dans la zone de transition entre deux classes. Les échantillons dans la zone définie par les vecteurs de support seront ainsi assignés des probabilités proches de 0.5, signifiant que la confiance liée à la décision est très faible. Au contraire les échantillons loin de l'hyperplan se verront assignés une probabilité proche de 1, ce qui implique une bonne confiance dans la décision. Les paramètres de la sigmoïde sont appris lors de l'apprentissage du SVM.

L'estimation des paramètres passe par une maximisation de leur log-vraisemblance. Il est alors possible d'appliquer la fonction de transfert sur des données de test afin d'obtenir leur probabilité postérieure d'appartenir à une classe. La démarche est applicable dans le cas multi classes en considérant les classes 2 à 2. Pour l'étude de l'esca on considérera ainsi la probabilité liée à la classe esca contre toutes les autres classes du jeu de données de test. Dans le cas idéal, les échantillons d'esca devraient déclencher des probabilités supérieures à 0.5 et les autres classes des probabilités inférieures à 0.5.

5.1.4 Visualisation des descripteurs

Les descripteurs ne peuvent pas être visualisés directement à cause de leur haute dimensionnalité (parfois de l'ordre de plusieurs dizaines de milliers). On peut donc utiliser une étape dite de réduction de la dimension pour y remédier. Les descripteurs sont projetés dans un espace à 2 dimensions résumant au mieux l'information de l'espace d'origine. La plupart des méthodes de réduction n'utilisent pas les classes des échantillons (approche non supervisée). Certaines méthodes utilisent cependant les classes pour maximiser la séparation entre classes dans le nouvel espace formé. On retiendra 2 méthodes de réduction de la dimension :

- L'Analyse Discriminante Linéaire (LDA) peut être vue comme le pendant supervisé de l'Analyse en Composantes Principales (ACP). Là où l'ACP cherche à produire des axes maximisant la variance des données, la LDA cherche des axes maximisant l'inertie inter-classes et minimisant l'inertie intra-classes. La méthode produit aussi une matrice de transformation entre les deux espaces.
- La méthode t-SNE (t-distributed stochastic neighbor embedding) non supervisée utilise les fondements de la théorie de l'information pour déterminer le nouvel espace des données [115]. Elle cherche à minimiser la divergence de Kullback-Leibler entre la distribution des similarités point-à-point de l'espace d'origine et de l'espace réduit. Contrairement aux deux précédentes, la méthode t-SNE n'utilise pas une matrice de passage entre les deux espaces. C'est une méthode non linéaire qui ne peut pas être utilisée pour réduire la dimension de données autres que celles utilisées.

Ces méthodes simples et puissantes peuvent être utilisées pour de nombreux types de jeux de données tels que les spectres en imagerie hyperspectrale [chapitre 8](#).

5.2 EXPÉRIMENTATIONS DESCRIPTEURS SIFT

5.2.1 Espaces de représentation

Comme nous l'avons vu au chapitre précédent, les descripteurs SIFT opèrent sur un seul canal, il est donc nécessaire de réfléchir la décomposition en canaux de l'image Rouge Vert Bleu (RVB) de base. On peut retenir quatre espaces colorimétriques candidats :

- RVB mesurant le mélange entre rouge, vert et bleu.
- Cyan Yellow Magenta (CYM) mesurant le mélange entre cyan, jaune, magenta et noir.
- Teinte Saturation Valeur (TSV) mesurant en un seul canal la teinte, accompagnée d'un canal de saturation et d'un canal de valeur (intensité).
- *Lab* où L exprime la clarté et où la couleur est exprimée par les canaux a et b.

Des exemples de décompositions pour une image esca sont présentés dans la figure [5.1](#).




Figure 5.1 – Visualisation en niveau de gris d’une imagerie dans les espaces RVB, TSV, Lab et CYM

En plus de l’espace initial RVB on retiendra aussi l’espace TSV pour les expérimentations de part le fort pouvoir discriminant théorique du canal de teinte. Ce canal particulier pose cependant un problème. Il est théoriquement impossible d’encoder l’information teinte complète sans coupure, l’espace de teinte étant circulaire. Son origine est universellement fixée au rouge, ce qui signifie que les teintes autour du rouge sont situées à la fois autour de 0 et de 1. Dans le cas de la vigne, la teinte la moins représentée (et la teinte n’intervenant pas dans les symptômes de l’esca) est la teinte bleue violette. On peut donc décaler l’origine du cercle vers cette teinte afin d’encoder au mieux de façon continue les cartes de teinte et calculer des gradient. Il reste cependant dans certains cas des zones de transition brutale entre 0 et 1 comme indiqué dans la figure 5.2. Ces valeurs se retrouvent particulièrement dans les zones très sombres de l’image où il y a beaucoup d’incertitude sur la valeur exacte de la teinte. D’autres méthodes basées sur ces espaces colorimétriques pourraient de même être mobilisées, telle que la méthode de sélection d’un espace hybride utilisée notamment pour des tâches de segmentation [193].

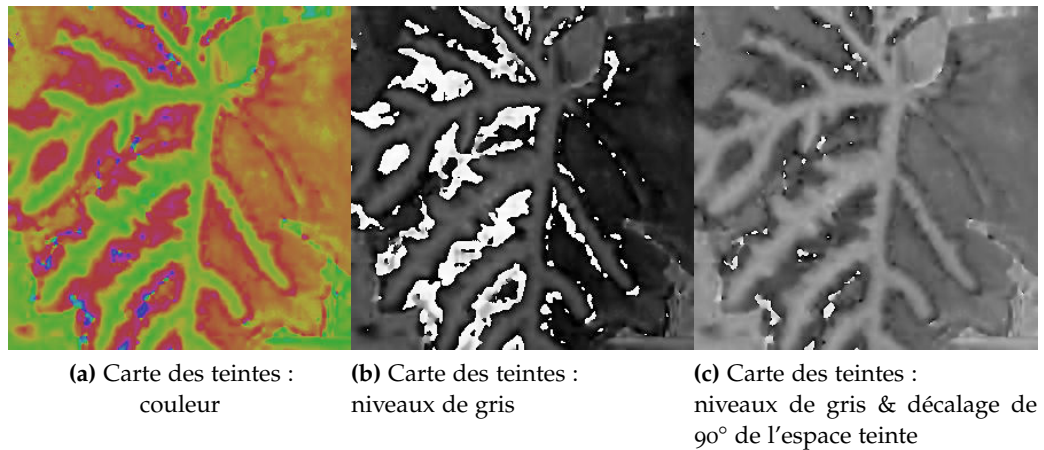


Figure 5.2 – Changement des valeurs de teinte par décalage de l'origine

5.2.2 Information couleur simple

L'information couleur peut être extraite facilement en considérant un seuil (fixe ou adaptatif) ou en considérant l'histogramme entier des valeurs dans l'image entière pour un canal donné. La figure 5.3 présente des exemples d'histogrammes de teinte sur des images de difficulté variables. Dans cette figure, on considère la couleur rouge comme l'origine de la teinte. La dimension du descripteur final dépend du nombre de compartiments utilisés dans l'histogramme. Cette quantité est cependant de l'ordre de la dizaine seulement, ce qui signifie que les descripteurs résultants sont très compacts mais aussi facilement interprétables.

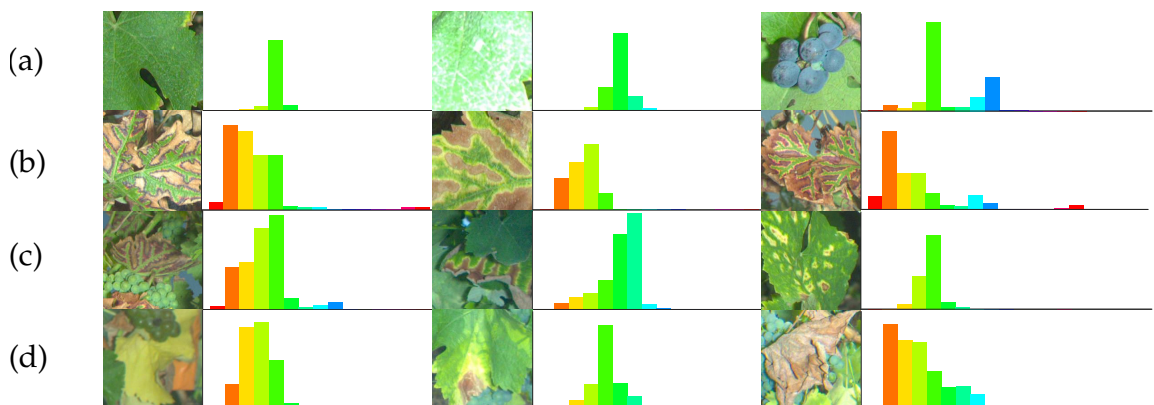


Figure 5.3 – Histogrammes de teinte pour 12 images de la base de données

- (a) - Feuilles saines
- (b) - Esca échantillons simples (esca3)
- (c) - Esca échantillons plus complexes (esca2 ou esca1)
- (d) - Autres symptômes

On remarque que, en dehors des feuilles saines uniformément vertes, il est très compliqué de délimiter des règles permettant de distinguer les 3 classes. La présence de multiples éléments superposés tels que les grappes, les tiges, le ciel ou même d'autres éléments plus rares (morceau de ruban adhésif dans la première colonne de la figure 5.3.(d)) donne des histogrammes de mélange peu informatifs sur la composition réelle de l'image. Même les échantillons d'esca prononcés ne semblent pas fournir une population homogène. La variabilité intra-classes est très importante au regard de la variabilité inter-classes. On remarque également que les teintes allant du jaune à orange sont communes, que ce soit pour l'esca, les facteurs confondants ou même sur les tiges lignifiées.

Il est possible de réaliser une première expérimentation simple à l'aide d'un histogramme. On considérera ici la précision de classification pour les 3 classes, moyennée sur 10 répétitions. On teste d'abord les performances en considérant les canaux séparés puis, en fusionnant les histogrammes sur les canaux de l'espace RVB ou TSV. La fusion se fait simplement en concaténant les vecteurs, ce qui signifie que la dimensionnalité du vecteur résultant est triplée. En plus de cela, quatre modalités sur la taille des histogrammes sont testées : de 5 à 20 valeurs. Les résultats sont synthétisés dans la figure 5.4.

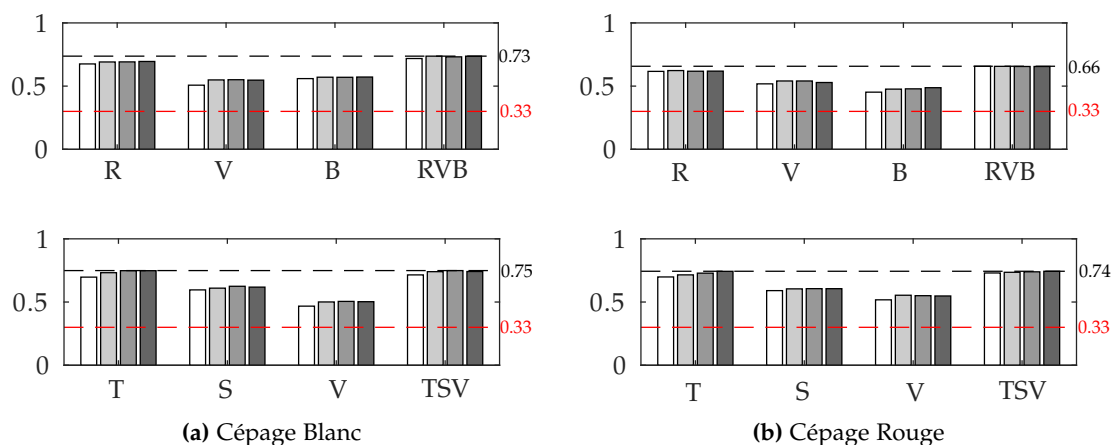


Figure 5.4 – Performances de classification (Overall Accuracy) en utilisant l'histogramme couleur comme descripteur pour les bases de données Cépage Blanc (a) et Cépage Rouge (b) dans les espaces RVB et TSV. Légende des barres du blanc au gris : 5 10 15 et 20 compartiments. Les histogrammes sont concaténés lorsque l'on utilise les 3 canaux à la fois.

Les histogrammes simples permettent d'emblée d'obtenir des performances correctes, avec environ 75% de bonnes classifications sur les deux cépages. Les 25% de mauvaises classifications restants sont cependant les plus difficiles et intéressants à classer. Les résultats sont logiquement dominés par les approches de fusion couleur, avec des performances similaires entre l'espace RVB et TSV. Lorsque les canaux sont considérés individuellement, la teinte se démarque avec des performances comparables aux approches de fusion, suivie par le canal rouge. Les autres canaux permettent une distinction beaucoup moins précise, les plus mauvais résultats étant obtenus avec le canal de valeur et 50% de bonnes classifications (un choix aléatoire correspondrait à environ 33% de bonnes classi-

fications).

On remarque enfin que la taille de l'histogramme ne semble pas être un paramètre critique bien qu'une légère augmentation est constatée dans certains cas (exemple : canal de teinte seul). Dans le cas de la teinte cela signifie qu'une "résolution spectrale" importante n'est pas indispensable bien qu'elle permette de nuancer plus finement les teintes entre le vert et le rouge les plus rencontrées dans les images. Dans le cas d'un espace colorimétrique à 3 couches, il serait de même possible de réaliser un "histogramme 3D" des valeurs conjointes [64]. Cette approche prometteuse se heurterait cependant au problème du choix du nombre de compartiment dans ses histogrammes.

A l'aide la méthode de Platt, il est possible de représenter les probabilités postérieures des échantillons d'appartenir à la classe esca. Les résultats, disponibles dans la figure 5.5, sont séparés en classes (et sous-classes esca) puis représentés dans l'ordre croissant afin de visualiser la distribution des probabilités esca de tous les échantillons. Les zones grisées correspondent ainsi aux échantillons mal classés, si la probabilité est inférieure à 0.5 pour la classe esca ou si celle-ci est supérieure à 0.5 pour les deux autres classes.

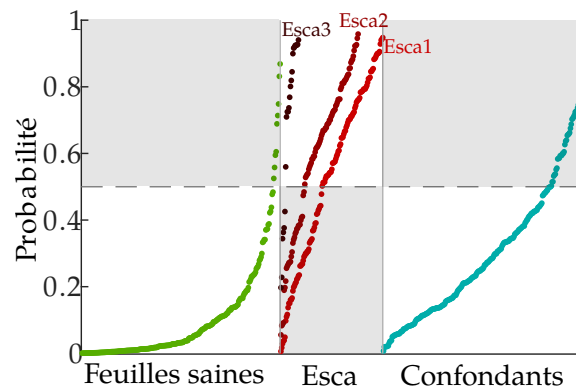


Figure 5.5 – Probabilités esca postérieures du SVM séparées par classe et sous classe puis ordonnées

La classe la mieux discriminée ici est la classe des feuilles saines, beaucoup d'échantillons ayant de très faibles probabilités pour la classe d'esca. Les autres symptômes semblent plus difficiles, avec une répartition plus homogène et un nombre non négligeable d'échantillons reconnus comme de l'esca. Les performances pour la classe esca dépendent logiquement des sous-classes, on remarque moins de faux-négatifs dans les échantillons très atteints par l'esca. Les échantillons les plus simples (esca3 sous forme de points noirs) sont pour la plupart bien retenus tandis que les nombreux échantillons de symptômes d'esca moins sévères (esca1 sous forme de points rouge vif) sont souvent mal reconnus.

Au vu des performances obtenues sur les canaux individuels on considérera seulement par la suite :

- Les images dans l'espace RVB
- Les images dans l'espace TSV

- Les images avec le canal teinte T seul

5.2.3 Information couleur locale

Les histogrammes par canaux donnent une information utile sur la répartition des valeurs pour un canal dans une image. Elles ne prennent cependant pas en compte la répartition spatiale de ces couleurs. Différentes valeurs cohabitent différemment selon l'endroit dans l'image. L'histogramme des teintes au niveau d'une tige sera par exemple différent de celui au niveau d'une grappe ou d'une feuille. Afin de prendre en compte cette diversité spatiale, on superpose une grille spatiale sur les images afin de délimiter un nombre fini de cellules et d'extraire les histogrammes dans chaque cellule. La figure 5.6 présente les 5 grilles utilisées dans cette étude. La grille 2x2 sépare l'image en seulement 4 cellules. Les histogrammes sont ainsi calculés sur des cellules de taille 112x112. Plus le nombre de cellules augmente, plus la taille de ces dernières diminue. Pour une grille 32x32 les histogrammes sont alors calculés sur 49 valeurs par cellule seulement. Le compromis idéal pour une application est difficile à estimer, c'est pourquoi il est nécessaire de tester plusieurs valeurs de ce paramètre dans l'expérimentation.




Figure 5.6 – Types de grilles utilisées pour les expérimentations. Si les descripteurs sont concaténés, la dimensionnalité du descripteur final augmente d'un facteur 4 à chaque fois que le pas de la grille est divisé par 2

Bien que cette approche apporte une information plus riche, elle ne permet pas de calculer un descripteur global uniformisé de l'image mais au contraire un ensemble de descripteurs locaux séparés. Plusieurs stratégies pour passer de l'un à l'autre sont décrites.

5.2.3.1 Concaténation des histogrammes : prise en compte de la composition

La concaténation agrège tous les descripteurs locaux en un seul descripteur. Cela signifie que la dimensionnalité des descripteurs est multipliée par leur nombre. Cette approche n'est donc pas idéale pour des grilles avec beaucoup de cellules. Dans le cas de la grille 32x32, le descripteur final sera de dimension $1024 * p$ où p est le nombre de compartiments dans l'histogramme. L'inconvénient majeur de la méthode vient cependant du fait qu'il y a une notion d'ordre dans la façon de concaténer les vecteurs. La concaténation implique par définition que l'on comparera toujours une cellule d'une image avec la même cellule d'une autre image. Or, un détecteur qui indique des phénomènes à des

endroits fixes de l'image n'est pas souhaitable. Un motif n'est pas forcément intéressant qu'à l'intérieur des cellules du centre ou des cellules du bord. Les limites de la méthode sont donc particulièrement apparentes pour des grilles denses, là où une grille 2x2 en souffrira moins. On souhaite construire à la place un détecteur prenant en compte des motifs intéressants quelque soit leur position dans l'image.

5.2.3.2 Encodage des descripteurs locaux par la méthode des sacs de mots

Une information de composition appropriée s'avère plus riche. Elle permet de connaître la composition en types de cellules dans l'image sans se soucier de leur position. Une image avec des grappes et des feuilles serait par exemple composée de 40% de cellules de feuilles, 50% de cellules de grappe et 10% de tiges. Ce cas idéal est illustré dans la figure 5.7.

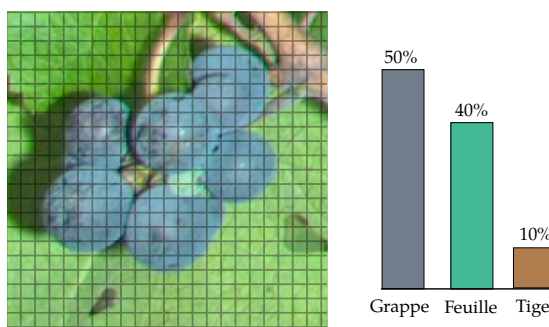


Figure 5.7 – Description idéale d'une image de la base étiquetée avec la classe grappes.

Dans les faits on ne déterminera cependant pas si une cellule est "feuille" ou "grappe", ces classes étant abstraites et difficiles à définir. Elles contiennent aussi un grand nombre de motifs locaux par nature. On considérera plus simplement un dictionnaire de cellules que l'on définira à l'aide des données d'apprentissage. Chaque mot du dictionnaire se réfère à un type de cellule aux propriétés remarquables, pouvant être caractéristiques d'une ou plusieurs classes. Ce nombre de mots est cependant bien plus important que le nombre de classes. Le nombre d'occurrences de chaque mot dans la grille nous fournit un histogramme décrivant la composition de l'image (figure 5.8). Ce descripteur peut alors être simplement injecté dans un classifieur afin d'apprendre des règles et de prédire la classe d'une image sur la base de son histogramme de composition.

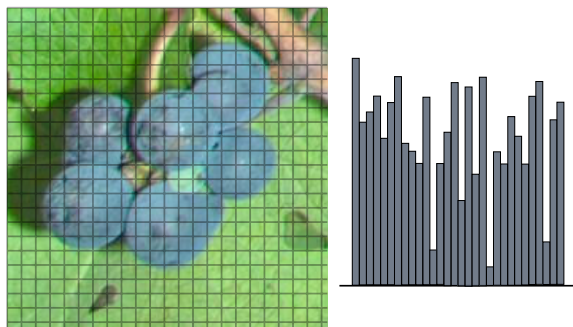


Figure 5.8 – Description réelle d'une image par histogramme de descripteurs locaux. Le nombre d'occurrence de chaque "mot" dans l'image nous permet indirectement d'estimer la classe la plus probable en connaissant les histogrammes des données d'apprentissage.

Bien que d'apparence moins simple et plus difficile à interpréter cette méthode permet beaucoup plus de souplesse et de considérer les cas hybrides entre deux classes souvent présentes dans la vigne (feuille à moitié symptomatique, feuille cachée par des grappes, présence de tiges au premier plan). Ainsi si une image contient un nombre important de descripteurs locaux, l'encodage permet de répondre à la question : *Quels types de descripteurs locaux sont présents dans l'image ?* Plus précisément, il apporte une estimation quantitative de la composition en un nombre fini de descripteurs locaux "type" qu'on appellera le dictionnaire. Le dictionnaire résume en un nombre de descripteurs réduit toute la variabilité de descripteurs locaux que l'on rencontre dans la base d'apprentissage. Cette dernière facilite aussi la création du dictionnaire étant donné qu'il n'y a pas à labeliser les descripteurs locaux, les mots du dictionnaires seront générés de façon non supervisée.

La méthode décrite a été nommée "sacs de mots" ou "sacs de mots visuels" (BoW) [178]. L'intuition derrière l'encodage a permis de générer plusieurs algorithmes dédiés de complexité croissante, deux autres algorithmes seront présentés dans les sections suivantes puis testés durant les expérimentations : les descripteurs VLAD et les vecteurs de Fisher.

En termes plus concrets, le dictionnaire est appris en réunissant les descripteurs de toutes les images de la base d'apprentissage pour un total de n échantillons de dimension J puis en appliquant l'algorithme de classification non supervisée k -means. Il repose sur une idée intuitive selon laquelle des objets proches ont plus de chance d'appartenir au même groupe que deux objets éloignés. L'algorithme k -means regroupe les descripteurs en k classes (mots) en partant de centroïdes initialisés aléatoirement puis en associant itérativement les échantillons au centroïde le plus proche (selon la distance euclidienne). La fonction à minimiser itérativement dans l'algorithme k -means est ainsi définie par :

$$\arg \min_s \sum_{k=1}^K \sum_{x \in S_k} \|x - \mu_k\|^2 \quad (1)$$

où x est un objet appartenant au groupe S_k et μ_k le centroïde associé de ce groupe. A chaque itération, les centroïdes mis à jour en tenant compte des nouvelles associations.

L'algorithme prend fin au bout d'un nombre fixe d'itérations ou lorsqu'il n'y a plus de changements dans l'association des descripteurs aux K classes. Afin d'accélérer les calculs lors de cette phase de *clustering*, une borne maximale est souvent fixée pour le nombre d'échantillons (ici un maximum de 10^5). On obtient alors un dictionnaire de mots équitablement répartis dans l'espace des descripteurs. Plus le dictionnaire contient de mots, plus la dimension du vecteur histogramme en sortie de l'algorithme sacs de mots sera grande. Le choix du nombre de mots k est fixé par l'utilisateur et dépendra de l'application, bien que généralement plusieurs centaines de mots sont nécessaires pour une bonne représentation.

Une fois le k -means réalisé, on peut associer n'importe quel nouveau descripteur dans le même espace à un groupe, c'est à dire à un mot visuel. Il suffit pour cela de trouver le centroïde le plus proche. Pour chaque nouvelle image, on calculera ses descripteurs locaux puis le nombre d'occurrences de chacun des mots visuels dans cette image. Le nombre de descripteurs (sur un total de N descripteurs dans l'image) associé à un groupe k est ainsi donné par :

$$v_k = \sum_{i=1}^N q_{ik} \quad (2)$$

Dans le cas de l'algorithme k -means $q_{ik} = 0$ ou $q_{ik} = 1$. On aura $q_{ik} = 1$ seulement pour les descripteurs i associés au groupe k et 0 pour les autres (association "en dur"). La concaténation des valeurs pour chaque groupe donne alors l'histogramme $\hat{\Phi}(I)$ décrivant l'image I .

$$\hat{\Phi}(I) = \begin{bmatrix} \vdots \\ v_k \\ \vdots \end{bmatrix} \quad (3)$$

$\hat{\Phi}(I)$ est enfin normalisé par sa norme L_2 (soit $\hat{\Phi}(I) = \frac{\hat{\Phi}(I)}{\|\hat{\Phi}(I)\|_2}$) pour obtenir un vecteur que l'on peut injecter dans un algorithme de classification. Ce type de normalisation est le plus souvent utilisé pour les descripteurs encodés afin de faciliter l'utilisation d'un noyau SVM.

5.2.3.3 Encodage de moment d'ordre 1 par la méthode VLAD

Comme nous l'avons vu dans la section précédente, les sacs de mots s'attachent simplement à compter le nombre d'occurrences de mots visuels dans une image afin d'aboutir à un vecteur compact. L'association d'un descripteur à un mot est binaire : soit il appartient à un groupe, soit il n'y appartient pas. Dans la réalité on observe au sein d'un groupe des échantillons très proches du centroïde et d'autres au contraire plus éloignés voire à la limite d'être assignés à un autre groupe. Cela veut dire que lorsque l'on compte le nombre d'associations par groupe, certaines sont beaucoup plus fortes que d'autres. L'algorithme VLAD ([87]) essaie simplement de généraliser l'approche BoW en considérant ces différences. Ici on considérera le résidu, c'est à dire la différence entre le vecteur

descripteur et le vecteur centroïde (moyenne de tous les échantillons du groupe). L'encodage pour un groupe est ainsi défini comme la somme pondérée des résidus pour tous les échantillons (au lieu du seul nombre d'échantillon), c'est à dire :

$$v_{jk} = \sum_{i=1}^N q_{ik}(X_{ij} - \mu_k) \quad (4)$$

où i est le numéro du descripteur dans l'image (N descripteurs au total), X_i est le descripteur i , μ_k les coordonnées du centroïde k et j une dimension du descripteur local (de 1 à J soit de 1 à 128 pour le descripteur SIFT classique).

Les valeurs encodées des K groupes pour les J dimensions sont alors concaténées ensemble dans un grand vecteur :

$$\hat{\Phi}(I) = \begin{bmatrix} \vdots \\ v_{pk} \\ \vdots \end{bmatrix} \quad (5)$$

En plus de prendre en compte l'éloignement au centre du groupe, la méthode VLAD diffère aussi par la dimensionnalité après encodage, le nombre de mots K est multiplié par la dimension du descripteur d'origine J .

5.2.3.4 Encodage des moments d'ordre 1 et 2 par la méthode vecteurs de Fisher

Il est possible d'aller encore plus loin dans la généralisation des approches sacs de mots [140]. La grande différence réside ici dans la modélisation des données sous forme d'un modèle de mélanges de gaussiennes là où VLAD et BoW utilisent l'algorithme k-means pour segmenter l'espace. Le modèle de mélange de gaussiennes (GMM) consiste en un regroupement de K distributions gaussiennes. Chaque distribution représente un groupe, au même sens que pour le k-means. Cela veut dire qu'il faut estimer les paramètres de chaque gaussienne, à savoir le vecteur de moyennes μ , la matrice de covariance et les poids w . L'algorithme d'Expectation Maximization (EM) est utilisé pour estimer ces paramètres. Soit un échantillon i , la probabilité d'appartenir à chacun des groupes k de la mixture sera ainsi définie comme :

$$q_{ik} = \frac{w_k p_k(x_i|\lambda)}{\sum_{j=1}^J w_k p_k(x_j|\lambda)} \quad (6)$$

où λ est l'ensemble des paramètres. Il est important de préciser ici que la matrice de covariance est supposée diagonale. L'initialisation de l'algorithme EM est cruciale, par conséquent on utilisera l'algorithme des k-means comme prétraitement pour l'initialisation des paramètres, les poids sont quant-à-eux pris égaux (leur somme est de même égale à 1). Le modèle de mélange de gaussiennes peut alors être utilisé en entrée de l'encodage *Fisher Vector* (FV). On considère le gradient de la log vraisemblance pour le mélange :

$$F_{\lambda}^{-1/2} \nabla_{\lambda} \log p(X|\lambda) \quad (7)$$

où F_{λ} est la matrice d'information de Fisher. Une vision simple est de considérer le gradient de la log-vraisemblance comme la direction dans laquelle les paramètres doivent être modifiés pour mieux correspondre aux données. Le noyau de Fisher transforme ainsi l'ensemble des observations X (descripteurs SIFT) en un vecteur de taille fixe. Ce gradient peut être dérivé partiellement par rapport aux paramètres du modèle. Ici on s'intéressera seulement aux paramètres μ et σ pour prendre en compte les moments d'ordre 1 et 2.

$$u_{jk} = \frac{1}{N\sqrt{w_k}} \sum_{i=1}^N q_{ik} \frac{x_{ji} - \mu_{jk}}{\sigma_{jk}} \quad (8)$$

$$v_{jk} = \frac{1}{N\sqrt{w_k}} \sum_{i=1}^N q_{ik} \left[\left(\frac{x_{ji} - \mu_{jk}}{\sigma_{jk}} \right)^2 - 1 \right] \quad (9)$$

Ces deux expressions pour chaque groupe sont alors concaténées dans un vecteur unique pour obtenir le vecteur de Fisher :

$$\hat{\Phi}(I) = \begin{bmatrix} \vdots \\ u_{jk} \\ \vdots \\ v_{jk} \\ \vdots \end{bmatrix} \quad (10)$$

La dimension du vecteur de Fisher pour une image sera donc de $2 \times K \times J$. Il est à noter que les vecteurs de Fisher par rapport à μ ou σ seuls pourraient être utilisés. On décide ici de n'utiliser que la combinaison des deux, c'est à dire le vecteur de Fisher complet. Les performances des vecteurs de Fisher sont aussi affectées par le type de normalisation effectué [141]. Pour les 3 algorithmes d'encodage, nous utiliseront une normalisation L2 classique.

Les expérimentations se concentreront sur ces 3 méthodes d'encodage car elles représentent plusieurs niveaux de généralisation distincts (mais aussi de complexité) et car elles peuvent être facilement mobilisées via la librairie *VLFeat* de Matlab¹.

5.2.3.5 Performances de classification

Les modalités de l'expérimentation portent ainsi sur la méthode utilisée (concaténation, sacs de mots, VLAD, Fisher Vectors) ainsi que sur la taille de la grille utilisée (détail en figure 5.6). Les résultats sont présentés dans la figure 5.9 pour les deux cépages.

1. <http://www.vlfeat.org/install-matlab.html>

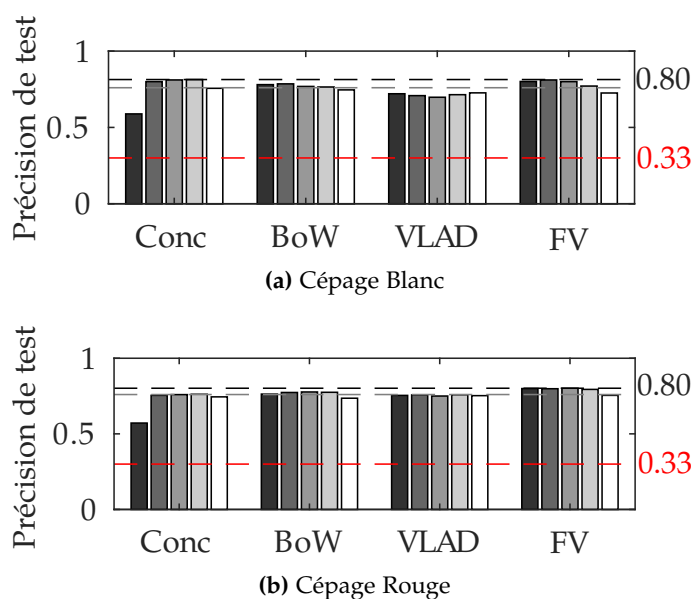


Figure 5.9 – Performances de classification (Overall Accuracy) par méthode grille sur cartes de teintes. *Conc.* : Concaténation des histogrammes. *BoW* : Encodage sac de mots, *VLAD* : Encodage VLAD, *Fisher* : Encodage vecteurs de Fisher. Barres du noir au blanc : cellules de 112, 56, 48, 28, 14 et 7 pixels de côté. Trait horizontal rouge : Performances si choix aléatoire

Le gain de performances à l’aide de ces descripteurs locaux par rapport aux histogrammes simples (environ 5%) est réel mais la classification est encore loin d’être parfaite. La composition permet de raffiner les descripteurs mais les histogrammes encodés restent basiques. Tout particulièrement ils ne prennent pas en compte la nature des gradients présents dans l’image. Ici, les Fisher vectors semblent particulièrement tirer leur épingle du jeu avec des performances intéressantes même avec un grand nombre de cellules (indiquées en noir dans la figure 5.9). Comme attendu les approches d’encodage permettent de maintenir de bonnes performances voire même de les améliorer en augmentant le nombre de cellules dans la grille.

5.2.4 Approches SIFT et dérivées

La limitation inhérente des histogrammes simples, malgré des approches d’encodage sophistiquées, nous a alors poussé à considérer des descripteurs plus fins, prenant en compte de façon invariante la dynamique des gradients autour de points d’intérêt. Comme nous l’avons vu précédemment, les descripteurs SIFT sont calculés sur la base d’une liste de points possédant une échelle et un angle. Ces points peuvent être générés par l’utilisateur ou provenir d’un algorithme de détection de points d’intérêt. On testera ici 3 façons de générer la liste des points.

5.2.4.1 Détection des descripteurs par approche DoG

L'approche *Difference of Gaussians* (DoG) décrite dans la figure 4.1 détecte pour chaque image des points d'intérêt à des positions différentes comme illustré dans la figure 5.10(a). Ces descripteurs sont d'échelles et d'angle variés (5.10(a)(c)) et sont majoritairement creux (vue de l'ensemble des descripteurs sous forme d'image dans la figure 5.10(b)).

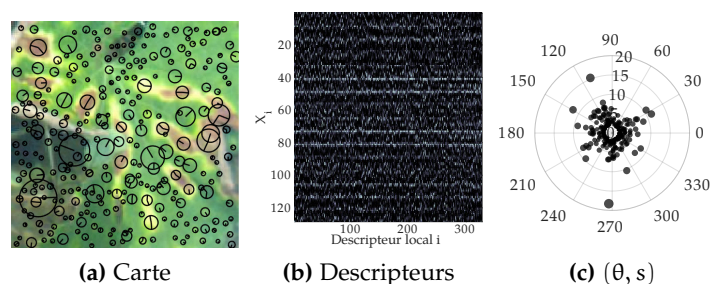


Figure 5.10 – Descripteurs locaux sur une image à l'aide de la méthode DoG

Il existe ainsi de nombreux types de descripteurs locaux, selon l'échelle et le motif représenté. La figure 5.11 présente 10 exemples de descripteurs variés sur des feuilles symptomatiques esca et sur d'autres feuilles. Ainsi, à l'intérieur de chaque cellule de la grille 4x4, des histogrammes d'orientation du gradient sont calculés. Les descripteurs semblent notamment attirés par le point de regroupement des nervures de la feuille ou par les bords entre les baies dans une grappe. Certains motifs sont cependant assez similaires au sens du descripteur SIFT, comme par exemple la transition entre feuille saine et tige lignifiée qui est similaire à la transition entre feuille saine et partie desséchée (la différence étant ici la présence d'un liseré violet).




Figure 5.11 – Exemples de descripteurs locaux variés avec grille 4x4 d'histogrammes orientés affichée

Première ligne : Motifs esca. Seconde ligne : Autre motifs

Il est possible de calculer le nombre moyen de descripteurs par image pour chaque classe (figure 5.12). Dans cette figure, on représente le nombre moyen de descripteurs par image en fonction du paramètre de bord de l'algorithme SIFT (permettant d'éliminer

des points d'intérêts peu saillants). Une séparation nette entre feuilles symptomatiques et saine semble se faire sur la seule base du nombre de descripteurs par images. Le résultat n'est pas étonnant car les feuilles symptomatiques déclenchent la détection de points d'intérêt supplémentaires par rapport aux feuilles saines du fait des motifs colorés qui y sont présents. Il n'y a cependant que très peu de différences entre le nombre de descripteurs esca et celui d'autres maladies.

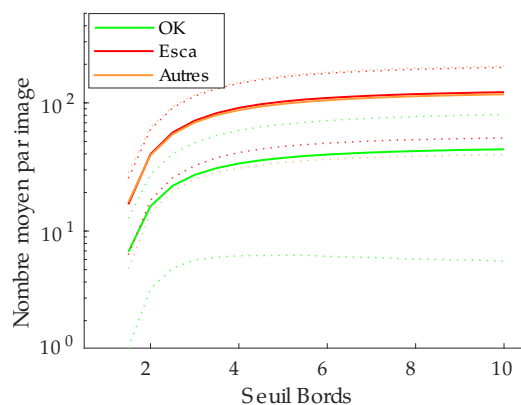


Figure 5.12 – Sensibilité de l'étape de détection SIFT au paramètre "Seuil de bord" ("Seuil de pic" fixé à 10^{-2}) pour les échantillons des 3 classes. Courbes en pointillés : écart type pour chaque classe

5.2.4.2 Descripteurs sur grille

Une façon d'encoder de façon hybride les descripteurs est de ne pas considérer l'étape de détection de points clés et de la remplacer par une grille de points où l'échelle sera fixe. Le gradient dominant sera ensuite considéré pour déterminer l'orientation du descripteur. La différence vient donc du fait que tous les centres de descripteurs, ainsi que leur échelle, sont connus à l'avance. Cela veut dire aussi que toutes les images ont le même nombre de descripteurs. La figure 5.13 présente un exemple de descripteurs alignés sur une grille.

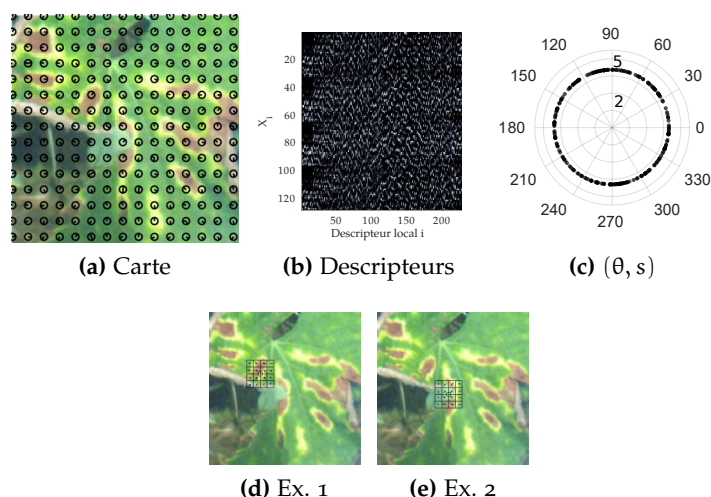


Figure 5.13 – Exemples de descripteurs locaux SIFT sur grille pour une échelle de 5

Le pas de la grille ainsi que l'échelle de ces points s'ajoute ainsi aux autres paramètres. Afin de les fixer, on réalise une expérience préliminaire consistant à mesurer les performances globales en fonction de ces deux paramètres et de la méthode d'encodage. Les résultats sont présentés dans la figure 5.14. Le nombre de mots est fixé à 250 pour l'approche sacs de mots et à 30 pour les approches VLAD et Vecteurs de Fisher.




Figure 5.14 – Étalonage des paramètres optimaux pour la méthode Dense SIFT établie sur la base cépage blanc. La meilleure performance pour chaque approche est indiquée par un chiffre rouge

Trait vert : Meilleur résultat pour l'approche histogramme (figure 5.4)

Trait bleu : Meilleur résultat pour l'approche grille d'histogrammes (figure 5.9)

Cette expérience préliminaire permet de battre les meilleurs résultats de l'approche grille d'histogrammes d'environ 5% (section 5.2.3.5). On remarque plusieurs tendances intéressantes :

- Les performances décroissent globalement avec l'augmentation du pas de la grille. Les meilleures performances sont ainsi obtenues avec un très petit pas (en blanc dans la figure 5.14)

- Les performances sont très instables pour des descripteurs à petite échelle (échelle 2 par exemple).
- Les performances sont plus stables pour des descripteurs à grande échelle (20) mais les meilleures performances sont rencontrées pour des descripteurs à moyenne échelle (5 et 10).

Dans la suite on considérera un pas de 8. Les performances sont similaires à celles avec un pas de 4 à l'échelle 5 choisie. De même, la diminution du pas de la grille permet d'alléger les calculs et de limiter les besoins en mémoire vive.

5.2.4.3 Descripteurs sur grille multi échelles

L'approche *Pyramid Histogram of Visual Words* (PHOW [24]) est la continuation logique de l'approche Dense-SIFT, celle-ci consiste à quadriller l'image de la même façon mais en faisant varier le paramètre d'échelle. Le nombre de descripteurs PHOW est donc égal au nombre de descripteurs SIFT mais la dimension d'un descripteur est multipliée par le nombre d'échelles, tous les descripteurs d'un même point étant concaténés ensemble. Un exemple de grille multi-échelles est présenté dans la figure 5.15.

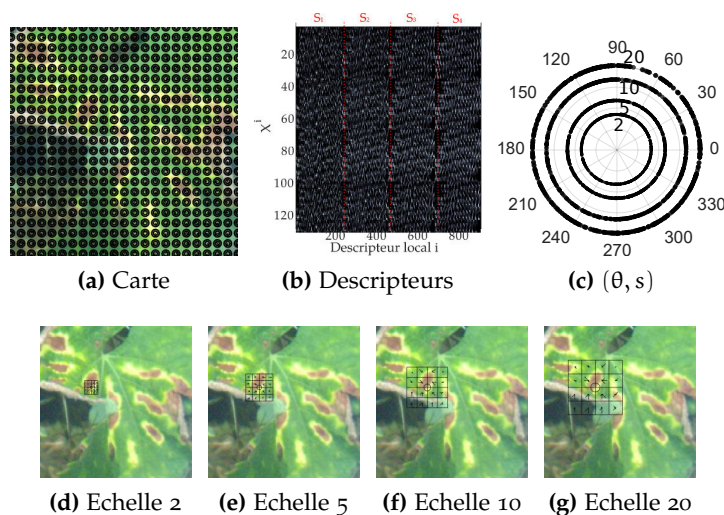


Figure 5.15 – Exemples de descripteurs locaux SIFT sur grille multi-échelles

Dans les expériences, on considère le même pas que pour les approches "descripteur sur grille" et les 4 échelles considérées sont [5,7,10,12].

5.2.5 Stratégies de fusion de l'information

5.2.6 Fusion des canaux pour une image couleur

En plus des méthodes de génération de points d'intérêt et des méthodes d'encodage, il est nécessaire ici de proposer une stratégie de fusion des canaux puisque l'on travaille avec une image à 3 canaux (RVB ou TSV). Le problème peut être abordé en fusionnant l'information des différents canaux avant ou après l'encodage. Dans le cas de cette étude,

on choisira de réaliser la fusion après l'encodage. Ainsi par exemple, l'utilisation d'un encodage par sacs de mots avec 250 mots fournira un vecteur final de 750 valeurs pour une image RVB.

5.2.7 Fusion des descripteurs SIFT avec des histogrammes couleur simples

Il est de même possible de considérer, avant l'étape d'encodage seulement, la fusion des descripteurs SIFT avec d'autres types de descripteurs locaux. Pour chaque descripteur SIFT, on considère un histogramme de 20 compartiments (proposant les meilleures performances d'après la figure 5.4) des valeurs rencontrées dans le voisinage autour du descripteur. Cet histogramme est ensuite concaténé au descripteur SIFT avant encodage et donc avant utilisation de l'algorithme k-means ou avant la modélisation par mélange de gaussiennes. Les performances sont par la suite testées en utilisant ou en omettant cette stratégie, appelée ici *color-sift*. On ajoute ainsi une nouvelle modalité aux expérimentations selon la concaténation ou non d'un histogramme couleur aux descripteurs SIFT. Cette fusion permet de compléter l'information apportée par les SIFT en y rajoutant la simplicité d'un histogramme simple.

La figure 5.16 présente un résumé de ces deux stratégies de fusion, la première (toujours utilisée si nécessaire) étant utilisée après l'encodage et la seconde (utilisée ou non) étant employée avant l'encodage. Les méthodes de fusion présentent cependant un défaut important : ces stratégies de fusion deviennent rapidement assez complexes et lourdes. La méthode idéale recherchée est simple, légère et dépend de peu de paramètres. Dans la stratégie de double fusion décrite plus haut, de nombreux paramètres (comme la taille l'histogramme couleur concaténé) ont un rôle crucial pour la qualité de la représentation finale.

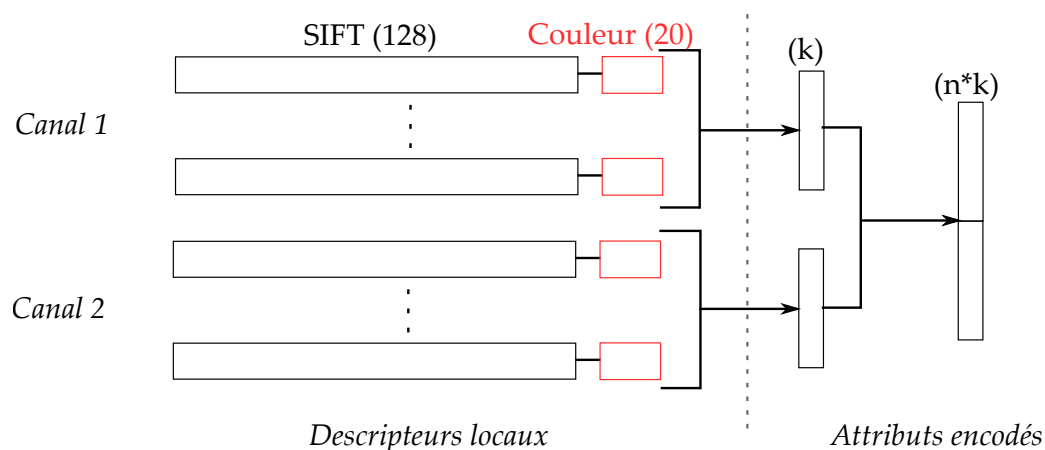


Figure 5.16 – Représentation schématique de la double stratégie de fusion. k : dimension du vecteur encodé (nombre de mots pour les approches sacs de mots). n : nombre de canaux fusionnés (3 pour les images RVB et TSV)

5.2.8 Taille des dictionnaires d'encodage

La taille de l'encodage est un paramètre important pour la qualité de la représentation. Trop peu de paramètres peuvent conduire à mal représenter la diversité de la base de données tandis que trop de paramètres font courir le risque de mots dupliqués trop proches les uns des autres. La table 5.1 présente les valeurs testées pour le paramètre k . Ces valeurs sont adaptées dans le cas des approches VLAD et FV afin de compenser pour l'importante hausse de dimensionnalité.

Tableau 5.1 – Dimensionnalité des approches d'encodage de l'expérimentation et valeurs de k testées

| | BoW | VLAD | FV |
|-------------------------|-----------|---------|---------|
| Dimensions | k | $128*k$ | $256*k$ |
| Valeurs testées (k) | 25 → 1600 | 2 → 32 | 2 → 16 |

5.2.9 Performances de classification

Les performances sont présentées respectivement, en fonction de la taille k du dictionnaire, pour l'approche sans fusion SIFT/couleur (figure 5.17) et l'approche avec fusion SIFT/couleur (figure 5.18). On commencera par analyser les résultats sans la fusion SIFT/couleur.

Le nombre de paramètres à prendre en compte rend ici l'analyse difficile. On remarque cependant que les résultats, ici affichés entre 78% et 90% de bonnes classification pour plus de clarté, sont assez instables. Le premier constat est l'effet du nombre de groupes ou de gaussiennes sur les performances. Celles-ci semblent généralement augmenter avec la taille du dictionnaire bien qu'il existe des exceptions (figure 5.17(c)). Dans le cas de l'approche sacs de mots, l'augmentation de la taille du dictionnaire est très bénéfique et une précision globale de 88% peut être obtenue en utilisant des descripteurs en grille calculés seulement sur la teinte avec un dictionnaire de 1600 mots (5.17(g)). Les descripteurs en grille semblent ici battre les descripteurs détectés par la méthode DoG. Dans le cas de l'encodage VLAD et Fisher Vector, on remarque que les performances sont assez stables lorsque l'on utilise la méthode DoG SIFT, bien que ne dépassant pas 86%. De manière générale, les performances de ces encodages semblent moins bonnes que pour un encodage simple par sacs de mots.

La comparaison entre les deux méthodes de générations de descripteurs SIFT sur grille fait apparaître quasi systématiquement de meilleures performances dans le cas d'une grille mono-échelle (en vert clair sur la figure 5.17). Cela pourrait être expliqué par le nombre très important des descripteurs lorsqu'ils sont calculés sur une grille multi-échelles (en vert foncé), ce qui aurait une mauvaise influence sur les performances de

l'algorithme k-means ou sur l'estimation des paramètres des gaussiennes.

Dans le cas où on ne considère que le canal de teinte, les performances sont mauvaises si les descripteurs SIFT sont détectés (5.17(g)). Elles s'améliorent légèrement si on fusionne 3 canaux TSV/RVB ensemble (5.17(a)(d)), ce qui pourrait signifier que la détection de points sur un canal ne fournit pas assez d'échantillons, problème résolu par l'approche SIFT sur grille. Dans le cas d'une grille, les meilleures performances sont cependant obtenues avec le canal teinte seul (5.17(g)), suivi par l'espace TSV (5.17(d)) et enfin l'espace RVB (5.17(a)). L'information contenue dans la teinte semble donc suffisante pour bien représenter la diversité des images et l'espace RVB est sans surprise le moins adapté dans ce cas.

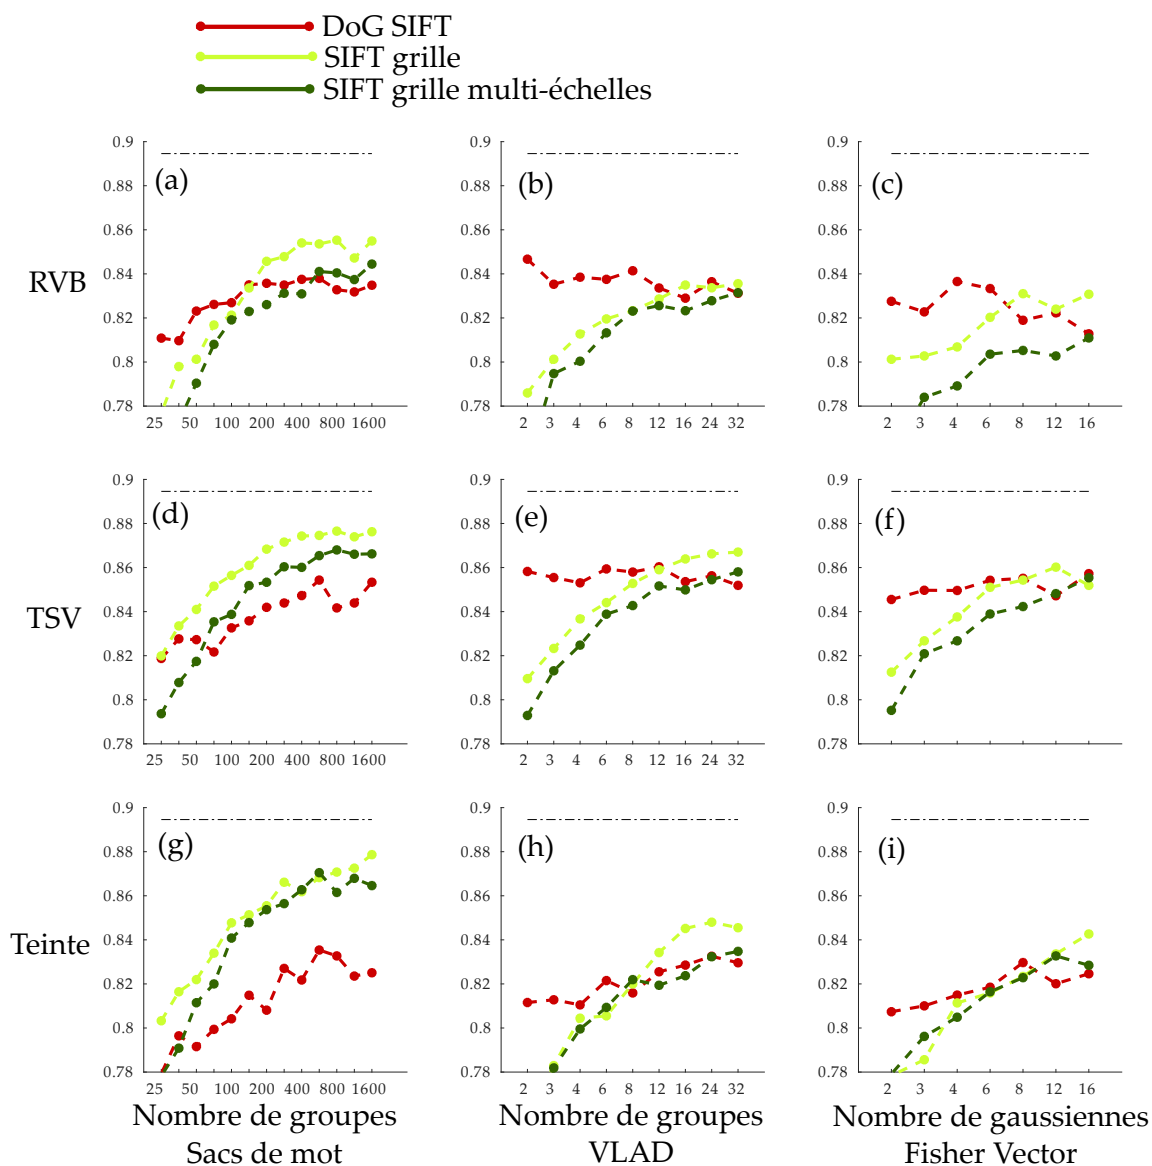


Figure 5.17 – Performances de classification globale sur la base cépage blanc en utilisant des descripteurs SIFT sur images RVB, HSV et sur cartes de teinte (H). Le trait en pointillés représente le meilleur résultat obtenu sur les figures 5.17 et 5.18.

Les performances semblent encore plus instables lorsque l'on fusionne les descripteurs SIFT avec des histogrammes couleurs (figure 5.18), ce qui est un résultat attendu car les deux données sont de natures différentes. Dans certains cas, on constate même des performances qui décroissent avec le nombre de mots dans le dictionnaire (figure 5.18(b)(c)). Les résultats semblent aussi stagner voire se dégrader au delà de 10 groupes dans le cas des approches VLAD sur grille (figure 5.18(e)(f)). Les meilleures performances utilisent cependant dans ce cas les Fisher Vectors (figure 5.18(f)(i)), avec un pic à presque 90% de bonnes classifications pour des descripteurs en grille calculés sur la teinte et encodés avec 16 gaussiennes (soit environ 2% de plus que le meilleur résultat sans fusion). Cela pourrait signifier que dans ce cas le mélange de gaussiennes est plus efficace pour modéliser un espace hybride contenant deux types de descripteurs concaténés. Des comportements similaires ont été constatés sur la base cépage rouge non montrée ici, avec un pic à 86.4% obtenu grâce à l'encodage FV sur descripteurs color-SIFT. Les performances sont moins élevées sur cette base en raison de plus grandes difficultés à bien classer les facteurs confondants.

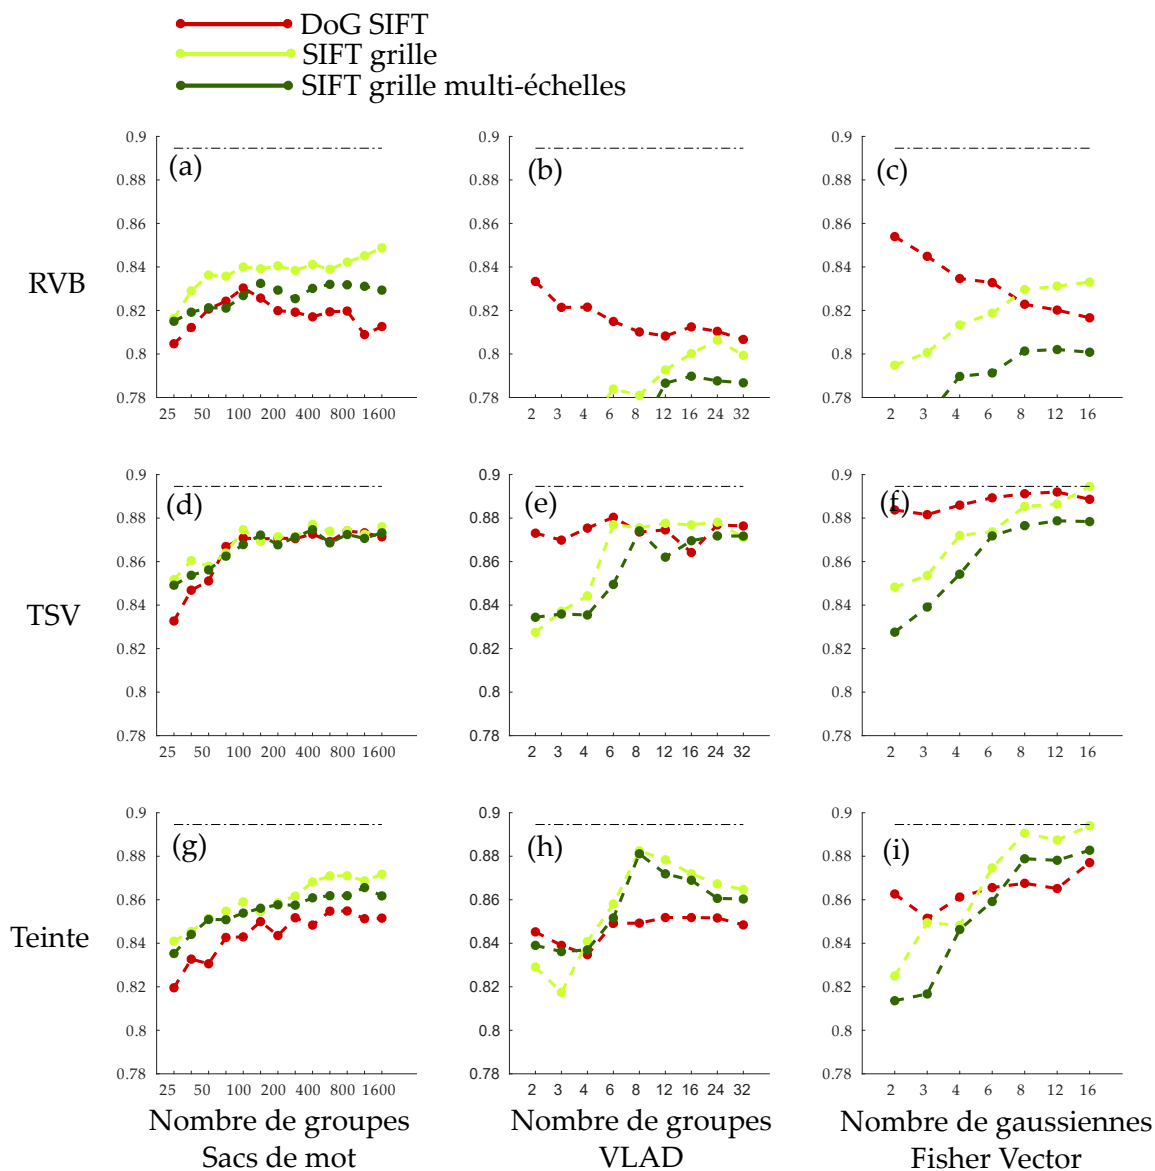


Figure 5.18 – Performances de classification globales sur la base cépage blanc en utilisant des descripteurs ColorSIFT sur images RVB, HSV et sur cartes de teinte (H). Le trait en pointillés représente le meilleur résultat obtenu sur les figures 5.17 et 5.18.

Il est possible de visualiser plus en détail l'expérimentation avec les meilleures performances. La figure 5.19 présente les descripteurs dans un espace à 2 dimensions grâce à 2 méthodes. La méthode supervisée (LDA) permet de séparer efficacement les échantillons, les échantillons esca les plus touchés étant logiquement plus éloignés des autres classes. L'algorithme t-SNE permet quand à lui une discrimination plus intéressante, bien que les deux classes symptomatiques soient en partie superposées. Cela met en évidence le rôle d'un apprentissage supervisé afin d'exploiter l'information riche contenue dans les descripteurs encodés.

Les courbes de probabilités postérieures du SVM nous donnent une information complémentaire. On remarque un progrès notable par rapport aux approches plus basiques

détaillées précédemment (figure 5.5). Les feuilles saines ne posent plus de problème et la répartition des probabilités pour les facteurs confondants tend vers des valeurs faibles, avec moins de faux positifs observés. On constate de même un progrès dans la capacité à discriminer des symptômes d'esca plus difficiles, qui sont le principal facteur de dégradation des performances.




Figure 5.19 – Projection des attributs issus de l'encodage de descripteurs SIFT dans un espace à deux dimensions à l'aide de méthodes (a)-supervisées (LDA) et (b)-non supervisées (t-SNE). (c) Probabilités esca postérieures du SVM séparées par classe et sous classe puis ordonnées

5.2.10 Résumé des expérimentations SIFT

Ces expériences montrent qu'il est possible d'adopter des méthodes d'extraction des descripteurs plus complexes basées sur les descripteurs SIFT afin de répondre au problème de classification et d'améliorer les performances. Cependant, ces améliorations vont de paire avec plusieurs contrecoûts. La complexité des algorithmes combinée aux stratégies de fusion signifie qu'un grand nombre de paramètres doit être pris en compte, tous ne pouvant pas être testés. La variation de ces paramètres peut de même rendre les performances instables (utilisation d'une autre méthode d'encodage par exemple). Les

méthodes utilisant le canal de teinte seul ont aussi dans ce cas montré des performances très intéressantes, voire supérieures par rapport aux méthodes avec fusion de 3 canaux.

La deuxième partie de ce chapitre examinera alors l'apport de méthodes issues du *deep learning* par rapport aux résultats obtenus grâce aux descripteurs SIFT.

5.3 APPROCHES TRANSFER LEARNING

5.3.1 Motivations au *deep learning*

Comme nous l'avons vu au chapitre précédent, les méthodes de classification basées autour du *deep learning* proposent des performances souvent inégalées, sur des applications générales ou sur des applications agricoles plus spécifiques. Cela prend la forme de réseaux de neurones convolutifs, réseaux de filtres permettant d'extraire divers niveaux d'information dans une image. L'objectif de cette partie est d'évaluer et exploiter le potentiel de ces approches.

Outre les performances, il existe d'autres motivations conduisant à tester les méthodes de *deep learning*. Malgré le nombre de paramètres élevés dans un réseau convolutif (jusqu'à plusieurs centaines de millions), le nombre de paramètres réellement définis par l'utilisateur, une fois la structure du réseau convolutif fixée, est relativement faible. L'apprentissage des paramètres se fait principalement coté machine, une simplicité qui évite d'avoir à concevoir des solutions *ad-hoc* et à devoir imaginer dans les détails l'étape d'extraction de descripteurs.

De façon plus générale, il existe un paradoxe lié au *deep learning*. D'un côté l'apprentissage de réseaux convolutifs complets demande des bases de données importantes. A première vue les CNN sont donc peu adaptés aux petites bases de données d'environ 500 échantillons par classe comme dans notre cas. Il faut cependant prendre une autre de leurs qualités en compte : l'adaptabilité. Des couches convolutives déjà entraînées sur une autre base nous fournissent un ensemble de filtres qui sont relativement généraux dans les premières couches et spécifiques dans les dernières. On peut donc les appliquer à des jeux de données très différents de leur application d'origine. Selon le degré de similarité des jeux de données, on pourra décider de re-entraîner une partie du réseau convolutif (*fine-tuning*) ou de réutiliser directement les descripteurs en sortie des couches convolutives pour y entraîner un nouveau classifieur (*transfer learning* ou extraction *off-the-shelf*). L'idée d'un extracteur de descripteurs universel est ainsi très prometteuse pour des tâches de classification simples et flexibles.

5.3.2 Modèles envisagés

Le choix d'un réseau de neurones convolutif peut être complexe étant donné le nombre de références existantes en 2018. A première vue les réseaux peuvent être classés selon leur nombre de couches et selon leur nombre de paramètres (les deux n'étant pas forcément corrélés). Les réseaux les plus profonds sont connus pour être plus lourds à entraîner mais plus performants sur des tâches complexes. Dans notre étude, on re-

tiendra 4 réseaux candidats, représentant un compromis entre profondeur et simplicité. Le *benchmark* du réseau présenté dans le tableau 5.2 est souvent réalisé en mesurant la performance "top-5" (pourcentage de bonnes classifications en considérant les 5 premières classes prédites) sur la base ImageNet contenant 1000 classes. Les réseaux actuels peuvent atteindre une précision top-5 d'environ 90%. Les caractéristiques des 4 réseaux sont présentés dans le tableau 5.2.

Tableau 5.2 – Résumé des réseaux envisagés. Les paramètres sont indiqués pour le réseau en gras si présent

| Modèle | Année | Profond. | Nb. Paramètres | Top 5 | | | |
|------------|---------|----------|----------------|-------|-----------------------------|----------|-------|
| ImageNet | Famille | Entrée | Ref | | | | |
| VGG | 2015 | 23 | 138 357 544 | 0.901 | VGG16 VGG19 | 224x224 | [177] |
| ResNet | 2015 | 168 | 25 636 712 | 0.929 | Resnet50 Resnet80 | 224x224 | [73] |
| MobileNet | 2017 | 88 | 4 253 864 | 0.918 | (taille, α) | variable | [75] |
| Squeezenet | 2016 | 10 | 421 098 | 0.803 | - | 224x224 | [81] |

VGG et ResNet sont deux familles de réseaux d'usage très répandu dans le monde du *deep learning*. La principale différence est que VGG possède peu de couches mais de nombreux paramètres pour définir les filtres tandis que ResNet possède de nombreuses couches mais moins de paramètres. Le réseau ResNet tente de résoudre les problèmes liés à l'entraînement de réseaux très profonds (difficulté à propager le gradient) en utilisant des blocs résiduels dans sa structure. Les deux autres réseaux sont pensés pour être plus légers et s'adapter à des problèmes nécessitant une prédiction en temps réel. On considérera ainsi la famille de MobileNet. Cette famille de réseaux est pensée pour s'adapter aux différents besoins mobiles, en particulier selon la consommation nécessaire pour faire fonctionner le réseau en mode prédiction sur des applications temps réel (de 1 à 20 images par seconde selon l'application). Plusieurs modèles MobileNet différents peuvent être générés en considérant deux paramètres : la profondeur du réseau (α) liée au nombre de paramètres et donc de couches convolutives et la taille de l'image en entrée (224 pixels de côté dans la version de base de l'algorithme). La famille générée par ces paramètres permet des couples performance/vitesse variés sur la base ImageNet [75]. Celui-ci s'intègre ainsi très facilement dans une architecture mobile, particulièrement s'il est utilisé conjointement à TensorFlow mobile, permettant ainsi de déployer des applications *deep learning* natives, personnalisées et performantes sur les terminaux mobiles. Le réseau MobileNet est aussi caractérisé par la présence de blocs convolutifs avec sous-échantillonnage hybride (*depthwise pooling*). Le réseau SqueezeNet [81] est quant à lui conçu pour être aussi portable que possible en allégeant au maximum le réseau. Les filtres convolutifs 3x3 habituels sont ainsi par exemple remplacés par des filtres 1x1. Tous ces réseaux (sauf certaines déclinaisons de MobileNet) fonctionnent avec des images de taille 224x224 en entrée.

La perspective d'une application temps réel pousse fortement à considérer des réseaux légers et modulables. On fera par la suite le choix du réseau MobileNet, présentant des performances très intéressantes tout en étant plus léger que les approches VGG et ResNet.

5.3.3 Implémentation des algorithmes et modèles

Tous les algorithmes présentés dans cette partie ont été implémentés à l'aide du langage Python 3 et du framework Keras² (surcouche haut niveau à TensorFlow). Le choix s'est porté sur Keras pour la simplicité de son langage, l'importance de la communauté (nombreux algorithmes basés sur Keras) et le support natif de nombreux réseaux pré-entraînés sur ImageNet. La proximité avec Tensorflow rend aussi plus aisée le déploiement potentiel sur architecture mobile (Tensorflow Mobile). Afin d'accélérer les calculs, une carte graphique GTX 1060 avec 6Go de mémoire vidéo et un support CUDA est utilisée. Les cœurs CUDA sont utilisés afin de paralléliser les calculs durant la phase d'apprentissage et de prédiction. L'utilisation d'un GPU à la place du CPU est ici essentielle, le gain de temps étant au moins d'un facteur 10.

5.3.4 Stratégie d'entraînement du réseau

L'entraînement d'un réseau convolutif peut se faire de 3 façons décrites dans la figure 5.20. Le type d'apprentissage dépend principalement des modifications que l'on apporte à la partie convolutive. Ici les 3 approches correspondent respectivement à un apprentissage total, partiel ou nul de la partie convolutive. L'apprentissage se fera par contre toujours au niveau du classifieur.

- L'apprentissage complet consiste à faire évoluer les filtres de toutes les couches convolutives
- Le *fine-tuning* fige les filtres de couches superficielles afin de n'apporter des modifications qu'à des couches profondes
- L'approche *transfer learning* utilise sans modification les descripteurs en sortie d'une des couches du réseau




Figure 5.20 – Méthodes d'apprentissage d'un réseau convolutif. Éléments rouges : Apprentissage bloqué. Éléments verts : Apprentissage possible

On peut faire plusieurs observations :

2. <https://keras.io/>

- La méthode transfert peut être appliquée en sortie de n'importe quelle couche convolutive (non limité à la dernière), ce qui permet à un classifieur d'apprendre sur des descripteurs superficiels ou profonds
- L'apprentissage complet et le *fine-tuning* impliquent l'utilisation un réseau de neurones *fully-connected* à la fin du Convolutional Neural Network (CNN) pour la classification (l'entraînement se fait en considérant les deux). La méthode transfert n'est quand à elle pas contrainte par un choix de classifieur étant donné que toute la partie convolutive n'est pas modifiée durant l'apprentissage.
- Le plus souvent, l'apprentissage complet part d'un réseau dont les poids sont initialisés aléatoirement tandis que les deux autres utilisent un réseau pré-entraîné que l'on va légèrement modifier (*fine-tuning*) ou transférer intact.
- L'apprentissage complet est plus long que les autres approches et nécessite une base de donnée de taille considérable.

Compte tenu de la taille de nos bases d'apprentissage, on se concentrera principalement sur le transfert dans cette étude. Les approches de transfert semblent retenir beaucoup d'attention ces dernières années [157] grâce à leur simplicité et leurs performances. La base la plus utilisée pour le *transfer learning* est la base ImageNet, qui sera par la suite considérée comme base de référence lorsque l'on considérera des modèles pré-entraînés. Étant donné le matériel et le temps nécessaires pour entraîner un réseau avec ce type de base, les poids pré-entraînés sont souvent mis à disposition sur le web, ce qui permet à chacun de les réutiliser facilement.^{3 4}

5.3.4.1 Comparaison des descripteurs issus de la base MBV avec les descripteurs issus d'ImageNet

On réalise ici une comparaison rapide entre notre base sur les Maladies du Bois de la Vigne (MBV) et la base ImageNet servant pour le pré-entraînement du réseau. 2000 images ont été sélectionnées au hasard dans chaque base puis injectées dans le réseau MobileNet avec poids pré-entraînés sur cette même base ImageNet. Les descripteurs en sortie ont ensuite été réduits en deux dimensions à l'aide la méthode t-SNE afin de les visualiser (figure 5.21).

3. VGG/Resnet/MobileNet : <https://keras.io/applications/>

4. Squeezenet : https://github.com/onnx/models/tree/master/models/image_classification/squeezenet

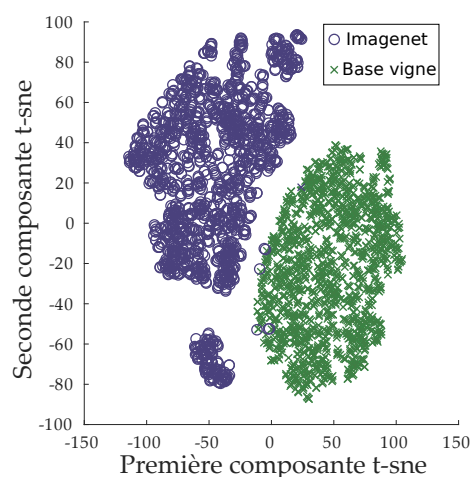


Figure 5.21 – Réduction non supervisée en deux dimensions par la méthode t-SNE des descripteurs issus du réseau MobileNet pré-entraîné pour 1000 images de la base ImageNet (cercles bleus) et 1000 images de la base MBV (croix vertes)

La séparation (calculée de façon non supervisée) entre les deux nuages de points est assez nette, ce qui montre clairement que les deux bases de données sont de nature différentes. Certains échantillons de la base ImageNet semblent cependant se rapprocher de la base vigne. D'après la figure 5.22, ces échantillons peuvent être prévisibles mais aussi parfois insolites. On remarque par exemple des feuilles et des tiges mais aussi des objets plus originaux comme des cactus ou des oiseaux.




Figure 5.22 – 8 échantillons d'ImageNet les plus proches des échantillons de la base MBV sur la base des descripteurs issus du modèle MobileNet préentraîné

5.3.5 Espaces de représentation

Les contraintes sur l'espace colorimétrique utilisé sont ici plus importantes que pour les expérimentations basées sur l'encodage de descripteurs SIFT. Étant donné que l'on réutilise des réseaux appris sur des images Rouge Vert Bleu (RVB), l'espace RVB seul sera utilisé par la suite.

5.3.6 Expérimentation transfer learning

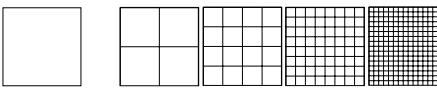
Afin d'évaluer les performances du réseau pré-entraîné en comparaison aux approches SIFT, on considérera les descripteurs en sortie de la partie convolutive du réseau avant de les injecter dans le même classifieur SVM qu'auparavant, avec les mêmes métriques d'évaluation. Le réseau MobileNet considéré sera le réseau original dont la taille des images en entrée est de 224x224 pixels et le paramètre α est égal à 1.

En partant de cette stratégie, il y a cependant plusieurs paramètres que l'on peut changer :

- La profondeur du réseau à laquelle les descripteurs sont extraits.
- La méthode de transformation des cartes d'activation (matrices) en descripteurs (vecteur) : vectorisation.

Il n'est pas obligatoire de considérer seulement la dernière couche convolutive. Au contraire, il serait intéressant d'évaluer des couches moins profondes mais peut être moins spécifiques aux échantillons d'ImageNet. Les couches convolutives sont au nombre de 13 à l'intérieur du réseau MobileNet, ils peuvent cependant être regroupées en 5 groupes (les 5 lignes du tableau 5.3) selon la taille des cartes d'activation en sortie. Plus on avance dans le réseau, plus les cartes d'activation sont petites mais nombreuses. Ces différences sur la taille en sortie signifient que la stratégie permettant de transformer les cartes d'activation en descripteurs dépendra de la profondeur. Typiquement la transformation se fait à l'aide d'une étape de *pooling* suivie d'une vectorisation.

Le rôle de l'étape de sous-échantillonnage (*pooling*) consiste à réduire la taille de la matrice en considérant localement la moyenne (*average pooling*) ou le maximum (*max pooling*). Bien que le maximum soit plus courant, les deux approches sont complémentaires. L'approche moyenne donne une information globale sur la carte d'activation mais est sensible aux cartes clairsemées (majorité de valeurs nulles), l'approche maximum permet d'éviter ce problème mais n'est en contrepartie pas forcément représentative de l'information globale. Dans notre cas, on considérera des grilles spatiales de taille différentes, divisant la taille de la matrice par 2, 4, 8 ou 16. Les matrices ne seront cependant plus réduites si leur taille atteint 7x7. On prévoira aussi le cas où le *pooling* est fait sur la matrice entière, le descripteur final sera alors constitué d'une valeur par carte d'activation. Ces différentes stratégies entraînent des descripteurs de dimension variable, le tableau 5.3 décrit en détail les dimensionnalités possibles, le minimum étant 64 et le maximum 16384.



| Couche[sortie] | 1x1 (global) | 2x2 | 4x4 | 8x8 | 16x16 |
|-------------------------------|--------------|------|------|------|-------|
| Conv1 [112 x 112 x 64] | 64 | 256 | 1024 | 4096 | 16384 |
| Conv2/3 [56x56x128] | 128 | 512 | 2048 | 8192 | . |
| Conv4/5 [28x28x256] | 256 | 1024 | 4096 | . | . |
| Conv6/7/8/9/10/11 [14x14x512] | 512 | 2048 | . | . | . |
| Conv12/13 [7x7x1024] | 1024 | . | . | . | . |

Tableau 5.3 – Dimensionnalité des descripteurs après stratégie de sous-échantillonnage par grille spatiale

En plus des stratégies de *max pooling* et *average pooling*, on considèrera aussi une fusion des deux dans un vecteur concaténé, doublant ainsi la dimension du descripteur final (maximum 32768).

5.3.7 Résultats

Les résultats sont présentés individuellement pour chaque cépage, respectivement dans la figure 5.23 pour les blancs et 5.24 pour les rouges. Afin de présenter toutes les expérimentations en une figure, on représente les performances selon la profondeur du réseau (numéro de la couche en abscisse). La taille des cercles utilisés est alors proportionnelle à la dimensionnalité des descripteurs. Les performances pour les 3 sous-classes esca sont de même indiquées dans les sous figures (a)(b)(c).

On constate une augmentation globale des performances avec la profondeur du réseau, bien que celles-ci commencent à stagner à partir de la 6ème couche. Une légère dégradation entre la 6ème et la 11ème couche est cependant visible. Au niveau des couches superficielles, les meilleures performances utilisent majoritairement le *pooling* par la moyenne ou par la moyenne et le maximum combinés tandis que pour les couches profondes le *max pooling* domine les performances. Les performances pour une couche donnée peuvent être très variables selon la stratégie de *pooling* adoptée. Cette variabilité semble être maximale pour la 1ère et la 11ème couche, tandis que les couches 6 et 13 sont relativement stables.

Une autre tendance liée à la dimensionnalité semble visible. Dans les couches superficielles, les meilleures performances sont obtenus avec les plus gros descripteurs. Tandis que dans les couches profondes, ce sont les petits descripteurs qui prennent ce rôle. Une hypothèse pour expliquer cette inversion de tendance peut être avancée. A un niveau superficiel, les descripteurs ne sont pas compacts, d'où le besoin d'empiler de nombreuses informations. Au contraire les descripteurs profonds sont compacts, une représentation informative pourra donc se faire avec de petits descripteurs, et augmenter leur taille ne ferait que "alourdir" l'information déjà présente de base.

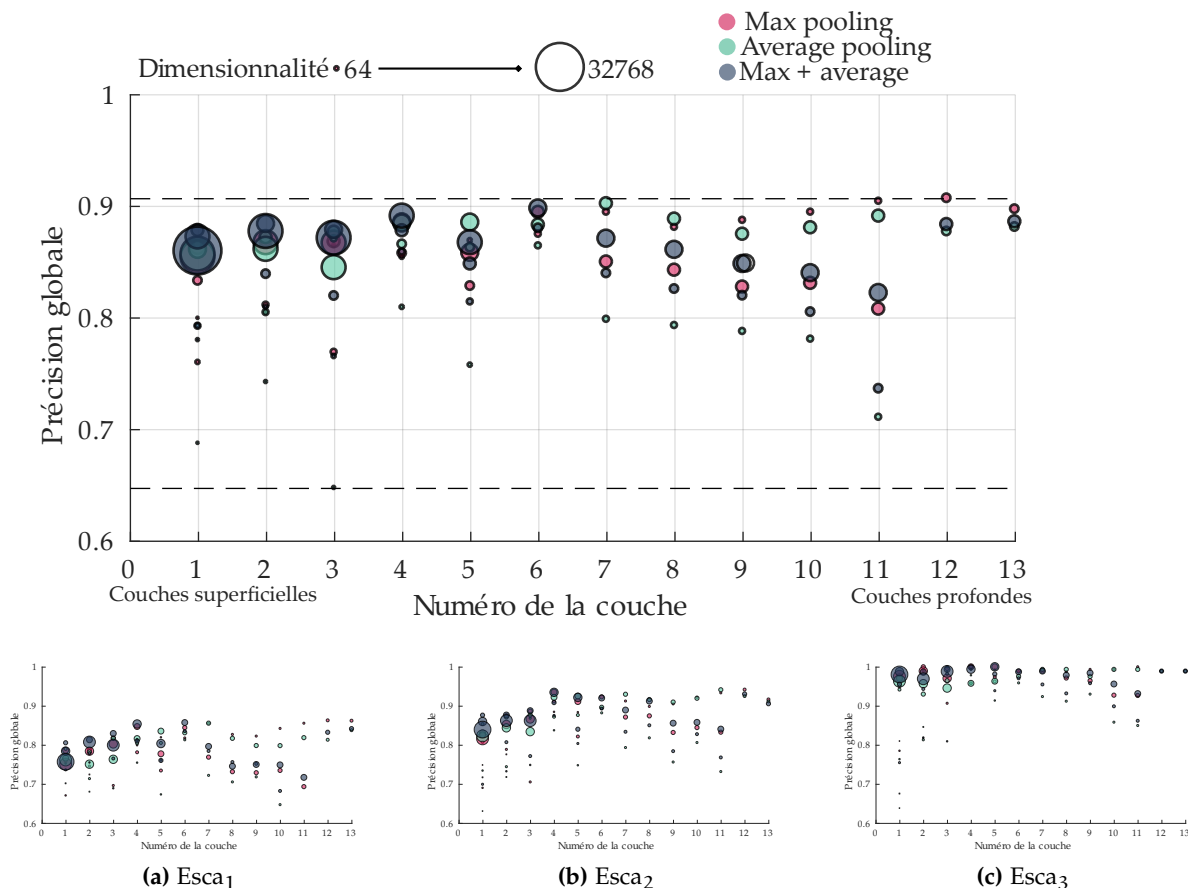


Figure 5.23 – Performances de classification sur la base Cépage Blanc à l’aide des descripteurs du réseau MobileNet à différentes profondeurs. Bas : Détail des performances pour les 3 sous-classes d’esca

Les performances sur les sous-classes esca suivent le comportement attendu, celles-ci sont meilleures lorsque l’on considère des échantillons esca plus marqués. On remarque aussi que les échantillons *esca*₃ sont très bien classés à l’aide de couches superficielles seulement. Les échantillons *esca*₁ et *esca*₂ nécessitent quand à eux des couches plus profondes pour être bien reconnus, la meilleure progression étant obtenue entre la couche 3 et la couche 4.

Quand à la base cépage rouge (figure 5.24), on y retrouve des performances légèrement moins intéressantes que pour les cépages blancs, en partie dû à la difficulté de certains facteurs confondants rencontrés. De même que pour le cépage blanc, les performances augmentent au fur et à mesure entre la 1^{ère} et la 7^{ème} couche puis commencent à stagner. Les performances les plus stables, quelle que soit la stratégie de *pooling*, sont aussi obtenue pour la 6^{ème} et la dernière couche.

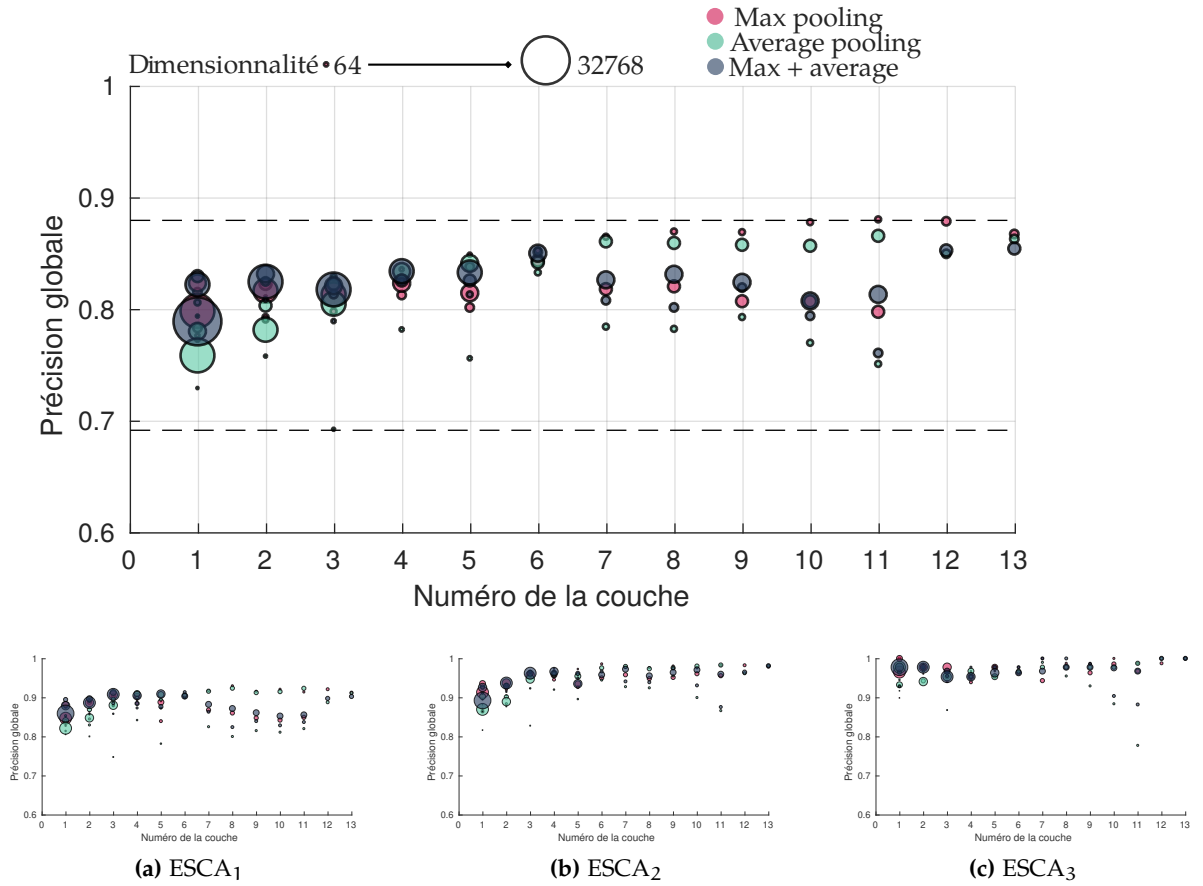


Figure 5.24 – Performances de classification sur la base Cépage Rouge à l’aide des descripteurs du réseau MobileNet à différentes profondeurs. Bas : Détail des performances pour les 3 sous-classes d’esca

La figure 5.25 permet de confirmer les impressions précédentes sur le rôle de la dimensionnalité. Celle-ci affiche les résultats des expériences en fonction de la dimensionnalité pour les deux cépages sans prendre en compte la profondeur du réseau. On remarque que les performances semblent meilleures pour les deux cépages pour des descripteurs de dimension 10^{-3} . Une dimensionnalité plus importante ($> 10^4$) ou plus faible ($< 10^2$) semble être préjudiciable pour les performances.

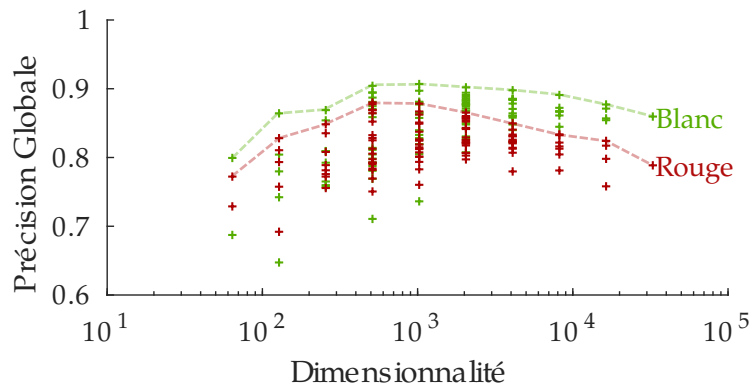


Figure 5.25 – Fusion des performances sur les deux bases d’images en fonction de la dimensionnalité des attributs obtenus. Les deux lignes en pointillés correspondent aux meilleures performances pour chaque dimensionnalité

La figure 5.26 présente enfin, de la même manière qu’avec les approches SIFT, des exemples de réduction en deux dimensions et la répartition des probabilités postérieures en sortie du classifieur. Les cartes obtenues sont assez similaires globalement. Les répartition de probabilité semblent cependant meilleures que pour les SIFT, avec un bien meilleur traitement des facteurs confondants.

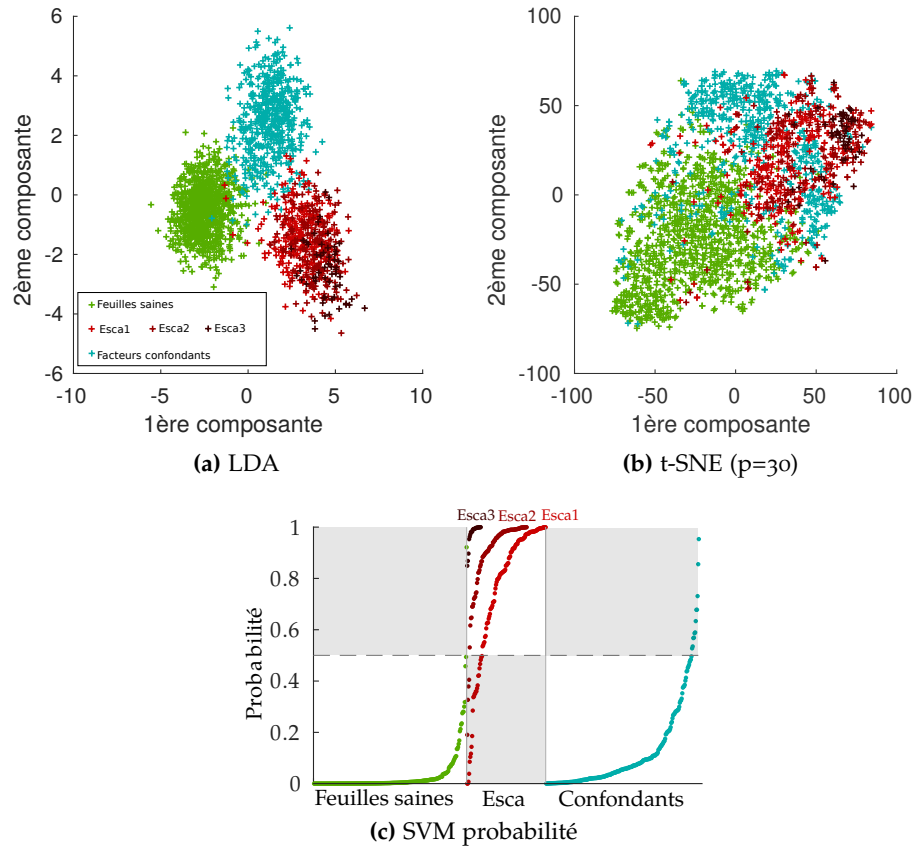


Figure 5.26 – Projection des attributs issus du Deep Learning dans un espace à deux dimensions à l’aide de méthodes (a) - supervisées (LDA) et (b) - non supervisées (t-SNE). (c) Probabilités esca postérieures du SVM séparées par classe et sous classe puis ordonnées

5.3.8 Visualisation du fonctionnement du réseau

Les CNN utilisés précédemment donnent de bons résultats mais leur fonctionnement est complexe. On prête souvent aux CNN une image de boîte noire, c’est à dire d’un outil que l’on ne peut pas ouvrir et dont le fonctionnement interne est mystérieux voire imprévisible. Cette considération vient en partie du constat que les CNN ne laissent pas le choix des descripteurs à l’utilisateur, la machine se charge à notre place de déterminer la nature des filtres convolutifs qui permettront de distinguer les éléments importants de chaque classe. Il est facile d’accéder aux poids du réseau mais ils sont nombreux et leurs interconnexions empêchent de les visualiser directement. Il existe cependant des méthodes permettant de mieux comprendre le fonctionnement interne des CNN. La plus simple est de visualiser les cartes d’activation en sortie des couches convolutives.

Les cartes d’activation en elles même sont cependant peu informatives. Elles permettent de représenter facilement l’effet des filtres. Les premiers filtres convolutifs (bords et couleurs) sont simples à interpréter mais deviennent de plus en plus difficiles à in-

interpréter au fur et à mesure que l'on avance dans les couches du réseau (figure 5.27). D'autres méthodes plus sophistiquées ont donc été imaginées pour générer des images provoquant l'activation maximale de certains neurones [176] ou pour générer des images provoquant la même activation qu'une image test [117].




Figure 5.27 – Exemple de cartes d'activation à différentes profondeurs du réseau convolutif

On présentera ici un autre outil appelé Grad-CAM [172] permettant de déterminer quelles zones d'une image participent à la décision pour une classe⁵. La figure 5.28 présente quelques exemples de cartes d'attention à l'aide la méthode Grad-Cam. L'échelle des couleurs est ici relative à chaque image, ce qui veut dire qu'une zone rouge dans une image ne représente pas forcément la même importance que dans une autre image. On remarque plusieurs comportements différents selon la taille du motif esca. Si le motif est petit, l'attention du réseau va naturellement se porter sur la zone symptomatique. Si la zone est par contre étendue, l'attention ne va pas se porter sur la zone entière mais sur une petite partie. Cela pourrait signifier que le réseau prend sa décision en se basant sur des zones précises de l'image, sans considérer la répétition du motif. La figure présente aussi des exemples de cartes d'attention sur des facteurs confondants. Les deux derniers cas sont ici les plus intéressants car ils montrent des fausses détections, où l'attention s'est portée sur des zones ressemblant à des motifs esca, bien que le symptôme global soit différent. Ce genre de confusion, en particulier sur les feuilles carencées, semble difficile à éviter et met en avant les limites de l'apprentissage automatisé pour la reconnaissance de symptômes.

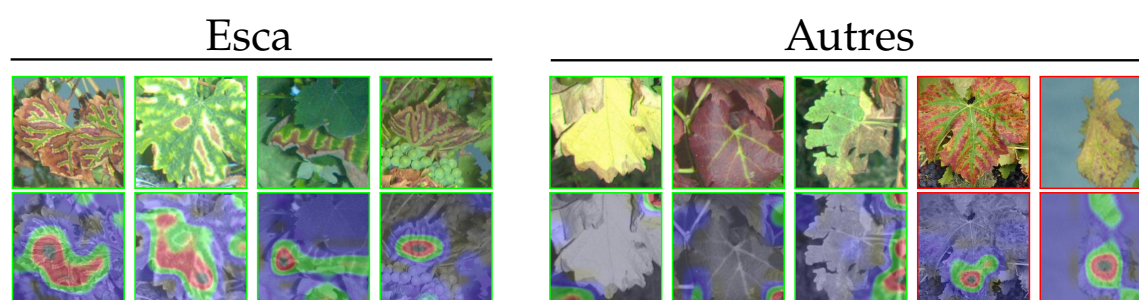


Figure 5.28 – Cartes d'attention pour la classe esca pour 5 échantillons d'esca et 5 échantillons d'autres symptômes. Les deux derniers échantillons (cadre rouge) sont mal classés

5. <https://github.com/jacobgil/keras-grad-cam>

5.4 RÉSUMÉ : COMPARAISON ENTRE LES DEUX APPROCHES

Après ces expérimentations, on peut faire un bilan de comparaison entre les approches SIFT et *deep learning*. Le tableau 5.4 présente un résumé quantitatif de ces résultats. En plus de la précision globale, le tableau indique les précisions pour les 3 sous-classes esca ainsi que la précision pour les facteurs confondants et ce pour les deux types de cépages. Les meilleurs résultats ont été retenus en considérant les différents espace colorimétriques (Rouge Vert Bleu (RVB), Teinte Saturation Valeur (TSV) et teinte) ainsi que les différents types de descripteurs (SIFT, color-SIFT).

Tableau 5.4 – Résumé des meilleures performances moyennes en % pour toutes les classes (OA), les sous-classes esca (esca1 à esca3) et les facteurs confondants (Conf) sur 10 répétitions équilibrées. L'écart type sur toutes les expériences est d'environ 1.6%. Caractères gras : Meilleures performances pour les approches d'encodage SIFT et les approches *deep learning*

| | | Cépage Blanc | | | | | Cépage rouge | | | | |
|-------------------------|--------------|--------------|-------------|-------------|-------------|-------------|--------------|-------------|-------------|-------------|-------------|
| | | OA | Esca1 | Esca2 | Esca3 | Conf | OA | Esca1 | Esca2 | Esca3 | Conf |
| DoG SIFT | BoW | 87.4 | 82.4 | 88 | 97 | 79.5 | 83.6 | 90.2 | 92.4 | 97.4 | 70.4 |
| | VLAD | 88 | 85 | 92.4 | 99.3 | 81.1 | 84.5 | 87.5 | 94 | 98.6 | 75.2 |
| | FV | 89.2 | 86.2 | 90.3 | 98.6 | 82.8 | 86.4 | 88.4 | 94 | 98.6 | 77.5 |
| Dense SIFT | BoW | 87.9 | 82.3 | 90.2 | 100 | 81.1 | 85.4 | 85.9 | 90.8 | 99.7 | 76.7 |
| | VLAD | 88.3 | 84.4 | 92.4 | 99.7 | 80.7 | 84.9 | 89.4 | 93.1 | 99.2 | 75.2 |
| | FV | 89.5 | 86.4 | 92 | 99.1 | 82.8 | 85.6 | 88.9 | 94.4 | 98.6 | 75 |
| PHOW SIFT | BoW | 87.5 | 83.6 | 89.4 | 97.1 | 79.1 | 84.4 | 91.1 | 91.9 | 96.7 | 72.7 |
| | VLAD | 87.5 | 83.5 | 91.5 | 99.4 | 80.8 | 83.7 | 87.7 | 93.1 | 98.9 | 73.7 |
| | FV | 88.3 | 85.7 | 90.9 | 98.9 | 81 | 84.3 | 87.3 | 92.6 | 97.6 | 73.9 |
| MobileNet + ImageNet | 1ère couche | 87.8 | 78.6 | 83.1 | 97.6 | 82.1 | 82.9 | 89.5 | 93.6 | 100 | 71.4 |
| | 7ème couche | 90.2 | 85.6 | 91.2 | 99.4 | 85.9 | 86.4 | 89.4 | 97.9 | 100 | 76.1 |
| | 12ème couche | 90.7 | 86.3 | 94.2 | 98.9 | 86.9 | 87.8 | 91.3 | 98.1 | 100 | 78.3 |

On remarque que le principal progrès introduit par le *deep learning* concerne en réalité la précision sur les facteurs confondants, qui est le point fondamental des performances. Les performances sur la classe esca sont similaires bien que certains progrès peuvent être constatés. La différence entre les approches SIFT et *transfer learning* est au final légère si on prend en compte l'écart type sur les expérimentations, bien que les meilleurs performances soient obtenues grâce aux couches profondes du réseau (respectivement 90.7% et 87.8% pour les deux cépages). En plus de présenter des performances légèrement supérieures, les approches *transfer learning* ont l'avantage de leur simplicité. Dans leur cas, les paramètres par défaut donnent souvent les meilleurs résultats.

Comme on le voit dans le tableau 5.5 il est parfois difficile de prévoir l'apport de techniques plus avancées sur des exemples concrets. Une amélioration globale des performances ne veut pas forcément dire que l'on ne fait que corriger des mauvaises classifications. Il existe ainsi des cas où des méthodes plus avancées donnent de moins bons résultats sur des imagerie précises. Ces résultats sont en réalité très difficiles à interpréter car il est compliqué de déterminer quelle particularité de l'image et des algorithmes influe réellement sur la décision. Les outils de visualisation présentées dans le cas du

deep learning pourraient aussi s'appliquer, sous une autre forme, aux descripteurs SIFT, afin de comprendre notamment l'influence de l'échelle des descripteurs et de déterminer les mots les plus utiles dans la représentation.

Les algorithmes de classification testés dans ce chapitre portent cependant des promesses positives pour la détection de l'esca et la différenciation vis à vis d'autres symptômes. Le pouvoir discriminatif des descripteurs issus du *deep learning* sera ainsi utilisé dans le chapitre suivant afin de détecter les feuilles symptomatiques sur des photographies de pieds entiers.

Tableau 5.5 – Exemples de résultats de classification avec 4 méthodes choisies :

Hist simple : TSV 20 histogrammes 20 catégories

Hist grille : Grille 8x8, Histogrammes + FV (30 gaussiennes)

SIFT : Grille dense 28x28, échelle 5, Color-Sift + FV (16 gaussiennes)



















Deep : 1ère couche MobileNet, average + max pooling 4x4

Légende des classes :

Cercles verts : Feuilles saines

Cercles rouges : Esca

Cercles bleus : Facteurs confondants

| | |
|---|-----------------|
|  | Imagette |
|  | Notation |
|  | Hist simple |
|  | Hist Grille |
|  | SIFT |
|  | Deep |
|  | Imagette |
|  | Notation |
|  | Hist simple |
|  | Hist Grille |
|  | SIFT |
|  | Deep |
|  | Imagette |
|  | Notation |
|  | Hist simple |
|  | Hist Grille |
|  | SIFT |
|  | Deep |

6

DÉTECTION DES SYMPTOMES VISIBLES À L'ÉCHELLE DE LA PLANTE

Sommaire

| | | |
|-------|--|-----|
| 6.1 | Introduction | 106 |
| 6.1.1 | Choix de l'architecture de détection | 106 |
| 6.1.2 | Métrique d'évaluation | 108 |
| 6.2 | Paramètres de l'expérience | 111 |
| 6.2.1 | Résolution de l'image | 111 |
| 6.2.2 | Augmentation de données | 112 |
| 6.2.3 | Paramètres d'apprentissage | 113 |
| 6.3 | Résultats détection | 114 |
| 6.3.1 | Exemple de résultats | 114 |
| 6.3.2 | Exemple de comparaison temporelle | 119 |
| 6.3.3 | Application à d'autres images réelles | 120 |
| 6.3.4 | Evaluation des résultats | 122 |
| 6.3.5 | Correspondance entre surface annotée et détectée | 125 |
| 6.3.6 | Temps de calcul | 127 |
| 6.4 | Conclusions et perspectives | 128 |
| 6.4.1 | Conclusions | 128 |
| 6.4.2 | Perspectives | 129 |

6.1 INTRODUCTION

L'étude en imagerie visible était jusqu'à présent centrée sur la classification de petites imagettes à l'échelle de la feuille. Cette étape n'est cependant qu'une étape intermédiaire au service d'un objectif principal : déterminer la position des feuilles symptomatiques sur l'image d'une plante entière. Passer d'un problème de classification à un problème de détection est loin d'être trivial car la machine n'a pas de connaissance *a priori* sur la position et la taille des zones intéressantes. Nous dressons dans un premier temps un panorama succinct des algorithmes pouvant être utilisés pour générer un détecteur. Puis la méthode retenue sera utilisée sur la base de données vigne. Le potentiel de la méthode retenue sera discuté à l'aide d'exemples de segmentations puis évalué par le biais de métriques adaptées à ce type de problème.

6.1.1 Choix de l'architecture de détection

En premier lieu, les termes détection et segmentation peuvent renvoyer à deux procédés qui sont la détection par zone rectangulaire et la segmentation par régions homogènes. Cette question est facilement tranchée par notre choix préalable de considérer des

rectangles dans la délimitation manuelle. Par soucis de cohérence et pour calculer les métriques d'évaluation, la délimitation machine sera donc faite sous forme d'un rectangle. La précision supplémentaire liée à la segmentation précise des symptômes ne nous intéresse pas ici. En partant de cette base, trois grandes familles de détection par boîtes peuvent être utilisées, elles sont détaillées dans l'ordre chronologique d'apparition :

- **Approches par fenêtre glissante.** On fait circuler une fenêtre sur l'image entière afin de réaliser la classification de chaque zone et fournir une carte de décision. Plus le pas de déplacement de la fenêtre est petit, plus le nombre de zones à classer est important mais plus la détection est précise. La technique produit beaucoup de détections dans le voisinage de la zone d'intérêt, celles-ci peuvent être fusionnées ou filtrées en ne gardant que la détection avec le meilleur score. Cette approche teste exhaustivement toutes les combinaisons. Elle est donc extrêmement lente. Elle a par exemple été utilisée pour la reconnaissance de chiffres dans un texte [102] ou de visages [196].
- **Approches en deux étapes.** Ces approches visent à proposer en premier lieu une liste de zones potentiellement intéressantes. Ce nombre est largement inférieur au nombre de boîtes explorées par une fenêtre glissante et est donc plus rapide. La sélection se fait sur la base d'une carte de descripteurs, souvent issue d'un réseau convolutif (tels que ceux utilisés pour la classification). Le contenu des boîtes proposées est alors donné en entrée d'un classifieur pour obtenir la classe de chacune d'entre elles. Des exemples d'architecture de ce type incluent les R-CNN proposés en 2012 [65] ou les plus récents Faster R-CNN utilisant l'algorithme *Region Proposal Network* (RPN) pour la première étape [161]. Ces approches détiennent les performances à la pointe de l'état de l'art.
- **Approches à une étape.** Motivés par le gain de temps durant la prédiction, ces approches tentent de réaliser simultanément les étapes de proposition de boîtes et de classification. Les architectures permettant d'arriver à ce résultat sont variées et ont fait l'objet de nouveaux réseaux souvent destinés à des terminaux mobiles. Des exemples, souvent plus récents que les approches à deux étapes, incluent You Only Look Once (YOLO) [158], Single Shot Detector (SSD) [110] ou RetinaNet [107]).

Les approches à une étape et deux étapes sont souvent comparées en terme de rapidité et de précision. Les approches à une étape sont ainsi plus rapides, au détriment des performances que peuvent atteindre celles à deux étapes. Le choix dépend donc des besoins et des contraintes de l'utilisateur.

Le passage d'un algorithme de classification à un algorithme de détection est facilité dans le cadre d'une architecture *deep learning*. On considère dans ce cas les couches convolutives du réseau de détection que l'on traite comme un extracteur de descripteurs inclus dans un réseau de détection. Le choix d'un réseau convolutif de détection est cependant difficile car le domaine est de nos jours en perpétuel changement. Le côté pratique est cependant ici très important, à savoir adopter une architecture que l'on peut facilement mobiliser dans son cadre de préférence (Keras/TensorFlow dans notre cas, utilisé pour ses nombreuses fonctionnalités couplées à celles de Python). On choisira ici RetinaNet [107] qui présente de bonnes performances, avec une inférence rapide. Il utilise une pyramide de descripteurs [108] calculée au préalable sur l'image entière.

Il est aussi caractérisé par l'utilisation originale d'une nouvelle fonction de perte, appelée *focal loss*. Cette fonction permet de pondérer différemment les échantillons selon leur degré de difficulté. Cette fonction est donc particulièrement adaptée pour les problèmes de détection où des échantillons témoins faciles sont présents en grand nombre tandis que les échantillons d'intérêt sont rares. C'est le cas pour la vigne où le feuillage sain est majoritaire dans les images tandis que les feuilles atteintes par l'esca ne sont qu'une minorité. Ses paramètres sont ici laissés aux valeurs par défaut telles que recommandées dans l'article de présentation [107]. Le réseau, dont l'architecture est illustrée en figure 6.1 est aussi facilement utilisable à l'intérieur de Keras.

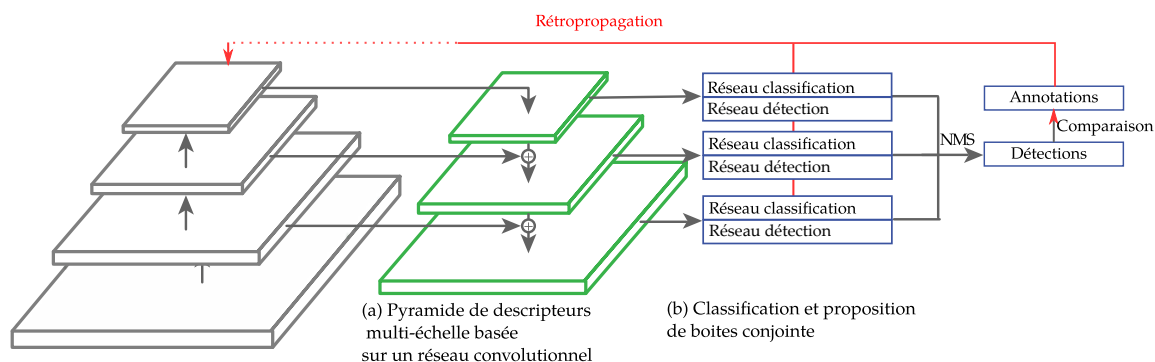


Figure 6.1 – Architecture du réseau RetinaNet. Lors de l'apprentissage, les résultats de détection sont comparés aux annotations de la base d'apprentissage et le gradient de la fonction de coût est retropropagé. La rétropropagation jusqu'au réseau convolutif est indiquée en pointillés car les poids du réseau peuvent être gelés afin de ne pas modifier la nature des descripteurs extraits (c'est l'approche qui est adoptée ici)

La pyramide multi-échelles de descripteurs est suivie de plusieurs sous-réseaux parallèles respectivement dédiés à la détermination de boîtes englobantes (réseau de détection) et à la classification de leur contenu. Ces deux réseaux de nature différente utilisent des fonctions de coût à minimiser différentes, respectivement l'erreur sous forme de norme L_1 (telle qu'utilisée dans Fast R-CNN) et de la fonction *focal loss* (qui remplace ici l'entropie croisée utilisée habituellement pour les problèmes de classification). Les paramètres du réseau entier sont appris de la même façon que pour un réseau convolutif classique, la différence étant ici que le *batch-size* ne contient plus des imageries mais des images entières. La dernière étape de *Non Maximum Suppression* (NMS) a pour but d'éliminer les boîtes superposées redondantes. Il en ressort une liste de boîtes, de scores et de classes à partir de laquelle on peut représenter les zones détectées sur l'image d'origine.

6.1.2 Métrique d'évaluation

Ici le problème de détection n'est pas aussi simple que celui de classification. Dans un problème classique de classification, un échantillon annoté sera forcément accompagné d'un unique score de prédiction pour chaque classe (score en sortie de la dernière couche *softmax* du réseau). Dans le cas d'un problème de détection, un échantillon annoté n'aura pas forcément de détection et de score associés ou il pourra en avoir plusieurs. A l'échelle d'une image, le nombre de détections est variable et ne rejoint pas forcément le nombre

d'annotations.

Pour comparer un couple de régions (une région annotée et une détectée) et déterminer si elles sont "associées", il est aussi nécessaire de définir une métrique tenant compte de leur superposition. La mesure la plus couramment utilisée est **l'intersection de l'union (IoU)**. Soit deux rectangles A et B (détection et annotation), la mesure IoU est simplement définie par :

$$\text{IoU} = \frac{A \cap B}{A \cup B}, \text{IoU} \in [0, 1] \quad (11)$$

Celle-ci est donc égale à 0 si les deux rectangles n'ont aucune zone d'intersection et à 1 si la superposition est parfaite. Dans notre cas, la valeur exacte de l'IoU n'a qu'un intérêt relatif étant donné que le positionnement très précis des symptômes sur une image ne nous est pas utile. On considérera ainsi un seuil arbitraire fixe à 0,5 indiquant si une détection est approximativement associée ou non à une annotation. Dans le cas de cette étude, il est possible de calculer l'IoU quelque soit la base considérée, la base de test ayant été étiquetée de la même façon que la base d'apprentissage.

Le problème de la détection est plus généralement illustré dans la figure 6.2 où tous les cas possibles pour une tâche de détection sont détaillés. On reprendra les termes Vrai Positif (VP), Faux Négatif (FN) et Faux Positif (FP) définis dans le cadre de la classification d'images, bien que leur sens soit ici légèrement différent. La principale différence est qu'on peut ici délimiter 3 types différents de vrais positifs. Ces configurations sont importantes car elles sont fréquemment rencontrées pour les images de vignes dans lesquelles une détection peut couvrir deux annotations ou une annotation peut être couverte par deux détections.




Figure 6.2 – Associations possibles entre annotation (carrés verts) et détection (carrés bleus avec un score p)

(a) - Annotation associée à une seule détection (VP)

(b) - Annotation associée à deux détections (VP)

Exemple vignes : feuille symptomatique détectée plusieurs fois

(c) - Détection associée à deux annotations (VP)

Exemple vignes : grande zone de détection sur plusieurs feuilles symptomatiques

(d) - Annotation sans détection associée (FN)

(e) - Détection non associée à une annotation (FP)

Les Vrais Négatifs (VN) sont une catégorie à part ici étant donné qu'ils désignent les échantillons non annotés et non détectés. Dans le cas d'une application de détection, ceux-ci sont très majoritaires dans une image et ne présentent en soit pas d'intérêt. En pratique, dans le cas où plusieurs détections correspondent à une seule annotation (cas C) on ne garde que celle avec le meilleur score. Le problème devient plus complexe lorsque l'on considère plusieurs classes. Une annotation pour une classe donnée peut ainsi être détectée à la fois avec la bonne et la mauvaise classe (exemple dans la figure 6.9.(a)). On considérera ainsi les performances pour une classe seulement, ici la classe esca.

En plus du paramètre IoU, les résultats de détection dépendent d'un paramètre de seuil sur le score de classification. Plus le seuil sera faible et se rapprochera de zéro, plus le nombre de détections liées à une classe augmentera. Le nombre de faux positifs risque ainsi d'augmenter à mesure que l'on relâche la contrainte sur le seuil de classification. Chaque seuil sera associé à un couple VP/FP et l'ensemble des couples peut permettre de tracer la courbe Receiver Operating Characteristic (ROC) du problème. Cette courbe ne nous intéresse cependant pas directement. On cherche ici à mesurer la capacité de l'algorithme à "retrouver" le maximum de symptômes esca en fournissant le moins de fausses détections possible. Ce compromis entre efficacité et exhaustivité est communément mesuré à l'aide des valeurs de Précision (P) et de Rappel (R). Celles-ci sont définies simplement par la formule :

$$R_i = \frac{VP_i}{N} \quad (12)$$

$$P_i = \frac{VP_i}{VP_i + FP_i} \quad (13)$$

où i désigne un point de la courbe ROC (et une valeur de seuil associée), TP le nombre de vrais positifs pour un seuil i , FP_i le nombre de faux positifs pour le même score et N le nombre total d'échantillons.

Le rappel et la précision fonctionnent comme des indicateurs de la quantité et la qualité de l'information récupérée. Le rappel résume la proportion de l'information totale récupérée tandis que la précision résume la proportion de bonnes décisions parmi l'information récupérée. En théorie, plus on récupère d'échantillons, plus ceux-ci risquent d'être liés à une fausse détection, la précision diminue donc lorsque le rappel augmente. Ceci n'est cependant pas strictement vrai étant donné que seule la mesure de précision dépend du seuil. Par conséquent on observe souvent, dans les cas où peu d'échantillons sont disponibles, des courbes en forme d'escalier" non strictement décroissante.

Il existe de nombreuses façons de résumer le compromis rappel/précision en une métrique. Une métrique courante est celle de l'**Average Precision (AP)**. Celle-ci ne consiste pas simplement en la moyenne des valeurs de précision, elle considère une pondération par les variations de rappel entre deux seuils consécutifs.

$$AP = \sum_{i=1}^n (R_i - R_{i-1})P_i \quad (14)$$

où n est le nombre d'échantillons rappelables (le nombre d'échantillons annotés qui ont une détection associée, quelque soit son score). Ce nombre d'échantillons est inférieur ou égal au nombre d'échantillons annotés réels. Cela explique le fait que l'abscisse de la courbe Précision/Rappel ne va pas nécessairement jusqu'à 1 (tous les échantillons annotés ne sont pas nécessairement associés à une détection). On mentionnera aussi la métrique **mean Average Precision (mAP)** qui correspond simplement à la moyenne des **AP** sur toutes les classes. Cette métrique globale ne nous intéresse pas ici étant donné que seule la classe esca est d'intérêt.

6.2 PARAMÈTRES DE L'EXPÉRIENCE

6.2.1 Résolution de l'image

Le premier paramètre consiste simplement à faire varier la taille des images en entrée. Les tailles d'images adoptées (figure 6.3) sont 500, 1000 et 1500 pixels de largeur. Sur cette figure, on remarque des différences très légères entre 1000 et 1500 pixels (bien que celles-ci soient visibles localement) tandis que l'image de 500 pixels de côté a subi une dégradation nette. On perd par exemple le liseré jaune des symptômes de l'esca ou l'aspect circulaire des grappes. La question est ici de savoir à quel point on peut dégrader la résolution sans trop dégrader les performances. Ce paramètre est essentiel car le temps de calcul est lié à la taille des images, cette taille conditionne aussi le *batch-size* maximal que l'on peut utiliser sans surcharger la mémoire du GPU. Le *batch-size* désigne le nombre d'échantillons utilisés par paquet durant un epoch (pouvant être vu comme une itération du procédé d'optimisation) pour mettre à jour les paramètres du

réseau. Plus le *batch-size* est élevé, plus la convergence des paramètres est attendue de façon stable, au prix d'une consommation mémoire plus importante.




Figure 6.3 – Effet de la dégradation des images originales (en pixels de côté) sur des structures locales.

6.2.2 Augmentation de données

L'augmentation de données (ou *data augmentation*) vise à augmenter artificiellement la taille et la variété de la base de données en appliquant aléatoirement à chaque epoch des transformations aux images (figure 6.4). L'objectif de l'opération est d'apporter plus de diversité et d'invariance aux bases de données avec un nombre d'échantillons limité. Cela permet entre autre de limiter le phénomène d'*overfitting*, c'est à dire l'apprentissage de règles trop spécifiques à un jeu de données. Les types de transformations sont fixées par l'utilisateur et peuvent être plus ou moins variées et intenses. Le type d'augmentation de données utilisé dépend ainsi de la nature de la base. Dans le cas de la vigne par exemple, on n'utilisera pas de transformations altérant sévèrement la teinte des images, car les feuilles seront toujours globalement vertes et les symptômes de jaune à marron. On influera ici principalement sur la géométrie du couvert. Les différents types d'augmentation de données mis en œuvre sont ainsi :

- Rotations de l'image
- Translations
- Cisaillements
- Zooms
- Miroirs horizontaux ou verticaux

- Cartes de déformations locales

Ces transformations peuvent être réalisées seules ou simultanément. Dans le cas où ces transformations font apparaître des zones vides dans l'image (rotation par exemple), on utilise la symétrie axiale pour remplir automatiquement la partie manquante.




Figure 6.4 – Procédé de *data augmentation* appliqué 16 fois à une image

6.2.3 Paramètres d'apprentissage

Enfin, certains paramètres d'apprentissage ont été fixés :

- Taille du *batch-size* : variable selon la taille des images en entrée. Contraint par les limitations mémoire du GPU
- Algorithme d'optimisation : Adam
- Taux d'apprentissage : $1e^{-4}$. Plus le taux d'apprentissage est élevé, plus les poids évoluent vite. L'apprentissage complet d'un réseau utilise souvent des valeurs autour de $1e^{-3}$ tandis que les approches de transfert ont un taux plus faible, c'est le cas ici.
- Couches convolutives du réseau MobileNet gelées afin d'utiliser l'approche *transfer learning*.

En plus des trois classes déjà utilisées dans la partie classification, on inclut dans l'apprentissage 2 autres classes couramment rencontrées dans la vigne : la classe grappes et la classe tronc. Cela permet d'éviter la détection de faux positifs liés à ces classes. Afin d'augmenter le nombre d'échantillons d'apprentissage, on fusionnera de même les bases en blanc et en rouge. La base d'apprentissage se compose ainsi de 1123 images pour l'apprentissage et 91 images pour le test (détail de la répartition dans le tableau 6.1). La séparation apprentissage/test est ici faite manuellement de manière à avoir des échantillons de test variés car de nombreuses images ne sont pas d'intérêt pour la base

test (les pieds atteints par l'esca sont minoritaires). Le prétraitement des images est assuré avec les paramètres de normalisation estimés sur la base Imagenet.

Tableau 6.1 – Repartition des pieds entre apprentissage et test pour la tâche de détection. Les pourcentages additionnés ne sont pas forcément égaux à 100% étant donné qu'un pied peut à la fois avoir des symptômes d'esca et d'autres symptômes

| | Nombre d'images | Images sans symptômes | Images avec symptômes esca | Images avec facteurs confondants |
|---------------|-----------------|-----------------------|----------------------------|----------------------------------|
| Apprentissage | 1133 | 669 (59%) | 170 (15%) | 353 (31%) |
| Test | 91 | 23 (25%) | 25 (27%) | 48 (52%) |

6.3 RÉSULTATS DÉTECTION

6.3.1 Exemple de résultats

Lorsque l'apprentissage du réseau est terminé, il est possible de l'utiliser en mode prédiction sur les images de la base de test. On obtient en sortie des coordonnées de boîtes accompagnées d'une classe et d'un score de classification. À l'aide de ces informations, il devient facile de les superposer à l'image d'origine pour une représentation visuelle des résultats de détection. On se concentrera d'abord sur des exemples de cartes de détection. Ces cartes sont obtenues en retenant le modèle au bout de la 20^{ème} epoch. Les figures 6.5 et 6.6 présentent respectivement des exemples de détection sur la base en blanc et en rouge. Un seuil de 0.5 a été appliqué au score de classification afin de sélectionner les détections validées. De même, seules les classes esca (cadre rouge) et facteurs confondants (cadre orange) seront présentées.




Figure 6.5 – Exemples de cartes de détection sur des images de 1500 pixels de coté sur des pieds atteints par l’esca avec utilisation de la *data augmentation*. Cépage blanc.

Les pieds en question sont plus ou moins atteints et l’intensité des symptômes rencontrés est variable. On remarque que le score associé aux symptômes est souvent corrélé à leur intensité, les scores proches de 1 étant obtenus pour des symptômes très bien définis. Des défauts sont cependant présents sous la forme de faux positifs et de faux négatifs. Parmi les faux négatifs, on remarque des petites feuilles (6.5.(a)) ou des symptômes très peu prononcés et/ou cachés (6.5.(b)(d)). On remarque de même des cas intermédiaires où la décision n’est pas toujours facile. La figure 6.5.(b) présente ainsi un exemple de feuille en cours de dessèchement détectée à la fois comme esca et facteur confondant, avec des scores similaires. On remarque aussi que les symptômes à l’ombre (bord supérieur gauche figure 6.5.(a)) peuvent être détectés avec une bonne confiance.

Ces tendances se retrouvent pour les résultats sur cépages rouge, avec des résultats satisfaisants pour des enchevêtrements de feuilles aux symptômes très bien définis (6.6.(a)) mais de grandes difficultés quand ces symptômes sont moins marqués (6.6.(c)). La figure 6.6.(d) semble illustrer une certaine tolérance aux changements d’échelle bien que l’algorithme ait des difficultés à délimiter une grande feuille symptomatique en une seule détection. L’aspect quasi fractal des symptômes de l’esca pourrait inciter l’algorithme à

segmenter des parties séparées de la feuille lorsque celle-ci est plus grande que d'habitude. De manière générale, on remarque peu de sensibilité aux objets du second plan, malgré la variabilité des situations rencontrées.

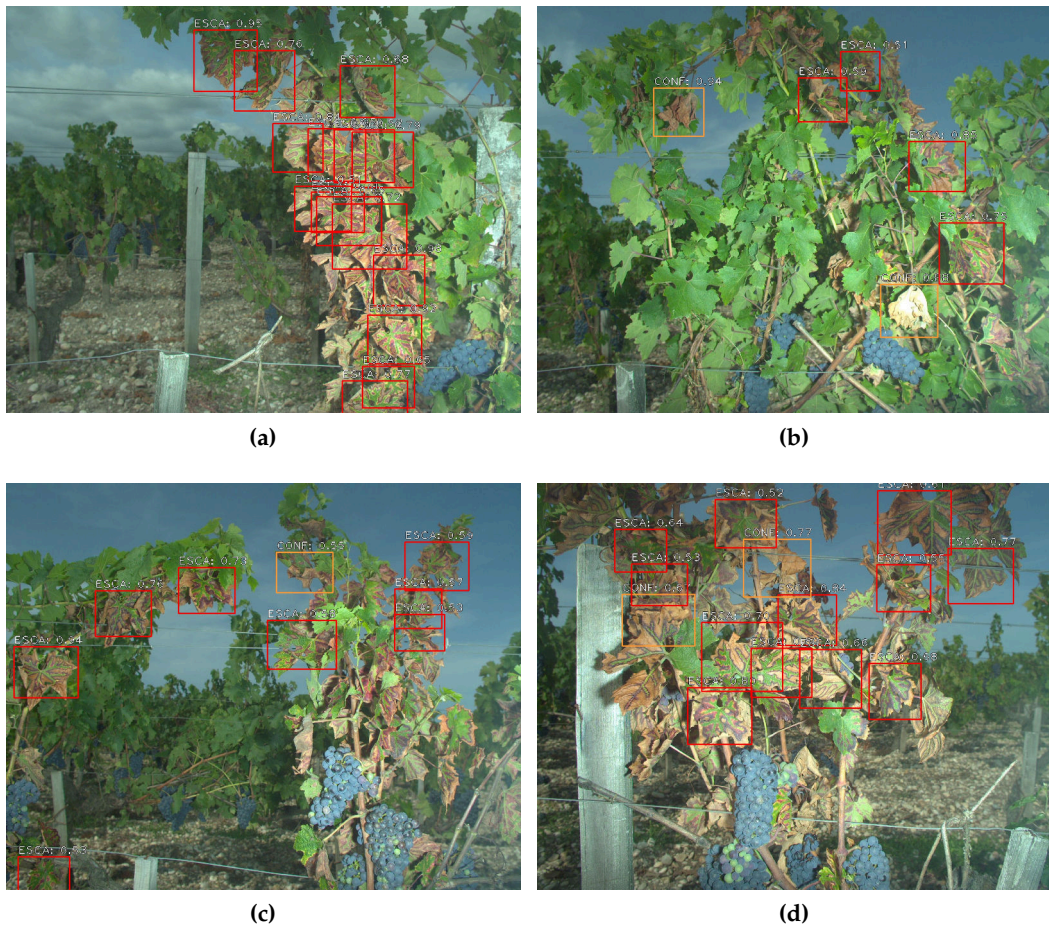


Figure 6.6 – Exemples de cartes de détection sur des images de 1500 pixels de coté sur des pieds atteints par l’esca avec utilisation de la *data augmentation*. Cépage rouge.

Concernant les facteurs confondant, les plus répandus sont des pieds partiellement ou entièrement desséchés (bien que cela puisse correspondre à une forme lente de l’esca devenue apoplectique) tels que les deux exemples de la figure 6.7. La couleur et la texture particulière de ces symptômes ne semblent pas déranger le réseau, bien que certaines petites feuilles en groupes (6.7.(b)) ou zones moins éclairées par le flash (6.7.(a)) semblent mettre l’algorithme en défaut.



Figure 6.7 – Exemples de cartes de détection sur pieds desséchés

La figure 6.8 présente d'autres exemples de décolorations diverses. On remarque là aussi la présence de faux négatifs. La classe des autres symptômes est moins spécifique que la classe esca, il n'est donc pas étonnant de voir des scores plus faibles et plus de faux négatifs. Certains symptômes mélangeant teintes rouges et jaunes comme l'esca sont le plus souvent bien classés.




Figure 6.8 – Exemples de cartes de détection sur pieds atteints de facteurs confondants - Bonnes détections

Des faux positifs peuvent cependant survenir, comme illustré dans la figure 6.8. Les faux positifs sont de natures variées, principalement dus à un mélange de teintes rouges et jaunes et/ou des motifs internervaires pouvant être similaires à l'esca.



Figure 6.9 – Exemples de cartes de détection sur pieds atteints de facteurs confondants - Faux positifs

Enfin, la figure 6.10 présente des exemples de vrais négatifs. Ici les principaux risques de faux positifs sont les enchevêtrements de tiges sur des vignes au palissage dense (6.10.(a)) ou le second plan flou sur des vignes plus clairsemées. Les deux configurations sont rencontrées couramment dans le vignoble du bordelais et sont donc importante à prendre en compte. Peu de faux négatifs sont reportés sur ce type de pieds. Les seules occurrences de fond déclenchant des faux positifs concernent les grappes du rang suivant qui sont parfois détectées (cas non représenté dans les figures).




Figure 6.10 – Exemples de cartes de détection sur pieds sains.
Gauche : cépage blanc. Droite : Cépage rouge.

6.3.2 Exemple de comparaison temporelle

L'algorithme peut être utilisé pour le suivi entre deux dates. La figure 6.11 présente un exemple de pied pris deux fois à un mois d'intervalle, début août et début septembre.




Figure 6.11 – Détection de l’esca et des facteurs confondants sur un pied à deux dates différentes

Cette évolution illustre l’une des principales difficultés dans la cartographie de l’esca qui est le caractère imprévisible de la maladie. Ici beaucoup de feuilles sont déjà desséchées et les symptômes d’esca sont peu prononcés, bien que quelques feuilles aient été détectées. Les plantes passent vite d’un stade a priori sain à un stade plus sévère.

6.3.3 Application à d’autres images réelles

Bien que l’algorithme ait appris dans des conditions particulières sur un jeu de données spécifique, les règles peuvent être appliquées dans d’autres situations. On s’intéressera ici à des photographies de pieds prises dans d’autres conditions, que ce soit sur une parcelle, avec un autre capteur ou en changeant l’angle de la prise de vue, la résolution et la portion du feuillage concernée. On testera d’abord des images acquises de près où seules quelques grandes feuilles sont visibles (figure 6.12).




Figure 6.12 – Détection de l’esca sur images de feuilles proches de l’objectif (a) basse résolution (b) très haute résolution

La détection est correcte, on retrouve cependant une tendance constatée plus tôt : les grandes feuilles sont parfois détectées à l’aide de plusieurs cadres. La forme complète de la feuille n’est donc pas forcément un critère indispensable pour déclencher une détection. La figure 6.13 présente aussi une photographie prise avec un autre capteur (smartphone) sur une partie de pied, en lançant la détection pour 3 tailles d’images obtenues par sous-échantillonnage.




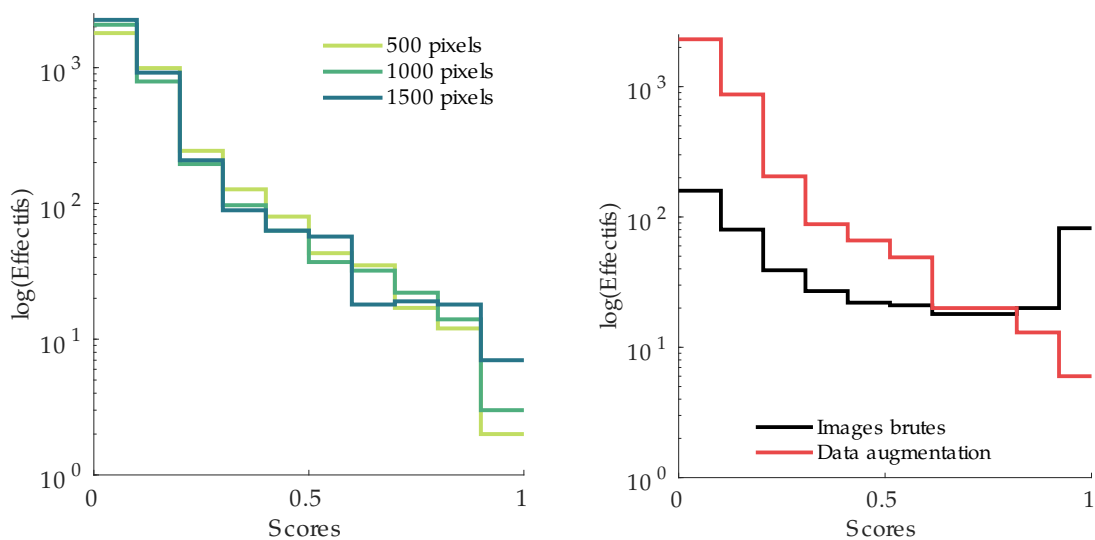
Figure 6.13 – Détection sur photographie proche du pied à l’aide des modèles appris sur des images de largeurs 500, 1000 et 1500 pixels.

Bien que les approches soient dans une certaine mesure invariante à l’échelle (pyramides de descripteurs), certaines tailles d’images peuvent être plus avantageuses. Lorsque l’image est conservée en haute résolution, l’algorithme est plus hésitant à segmenter de larges régions couvrant les feuilles entières. En contrepartie, il segmentera plus facilement certaines petites zones difficiles de l’image. Ces problèmes d’invariance nous poussent à penser qu’une base de données hybride contenant des images prises dans des

conditions variées serait bénéfique à la généralisation du réseau ou alors qu'il convient de standardiser les conditions de prises de vue.

6.3.4 Evaluation des résultats

Afin de compléter les exemples de détection, cette section présente une évaluation quantitative des résultats notamment à l'aide des métriques de Rappel Précision (RP) présentées au début du chapitre. On commence par examiner les scores des détections esca obtenus en sortie sur la base de test. La figure 6.14 présente un résumé statistique de ces scores sous forme d'histogrammes. Ces histogrammes présentent l'effectif pour chaque tranche de score (tous les 0.1), l'ordonnée étant présentée en échelle logarithmique pour plus de clarté. Le seuil d'intersection entre boîtes (IoU) est ici fixé à 0.5.



(a) Variation de la taille (avec augmentation de données) (b) Augmentation de données (taille 1500 pixels)

Figure 6.14 – Répartition des scores des détections étiquetées dans la classe esca.

On remarque facilement qu'une grande majorité des détections sont associées à un score très faible (<0.2). Cette distribution particulière montre la nécessité d'utiliser un seuil de score, le plus logique étant de le fixer à 0.5. La figure 6.14.(a) s'intéresse au rôle de la taille des images en entrée, celle-ci semble avoir très peu d'influences sur la répartition des scores, ni sur le nombre de détections. L'augmentation de données (6.14.(b)) a par contre une grande influence à la fois sur le nombre de détections et sur la répartition des scores. Sans augmentation de données, de nombreuses détections au dessus de 0.5 sont assignées à un score parfait. L'introduction de l'augmentation de données équilibre la distribution des scores au dessus de 0.5, elle diminue aussi le score maximal rencontré. Le nombre de détections au dessus de 0.5 est légèrement inférieur, le nombre total de détections est par contre largement supérieur. En résumé, l'augmentation de données rend l'algorithme moins binaire dans sa décision et augmente radicalement le nombre de décisions avec un score faible. Nous allons voir par la suite si ces changements sont

reliés ou non à de meilleures performances.

Les scores obtenus peuvent être utilisés pour calculer les courbes RP en faisant varier le seuil sur le score. On calcule ici les courbes RP pour plusieurs epochs, allant de la 1ère à la 50ème epoch. On rappelle qu'une epoch est une itération du processus d'apprentissage pendant laquelle tous les échantillons d'apprentissage sont utilisés par petits paquets pour faire évoluer les poids du réseau. Les figures 6.15 et 6.16 présentent respectivement ces courbes sur la base d'apprentissage et de test, en utilisant ou non l'augmentation de données.

L'effet de l'augmentation est facilement visible sur la base d'apprentissage. Les performances évoluent très vite vers une situation où la courbe rappel/précision est parfaite. Ce cas anormal témoigne d'un surapprentissage important. L'introduction de l'augmentation de données permet de corriger cette tendance, le réseau apprend plus progressivement et apprend plus de diversité et les performances obtenues après 50 epochs ne sont pas parfaites, un comportement plus cohérent.

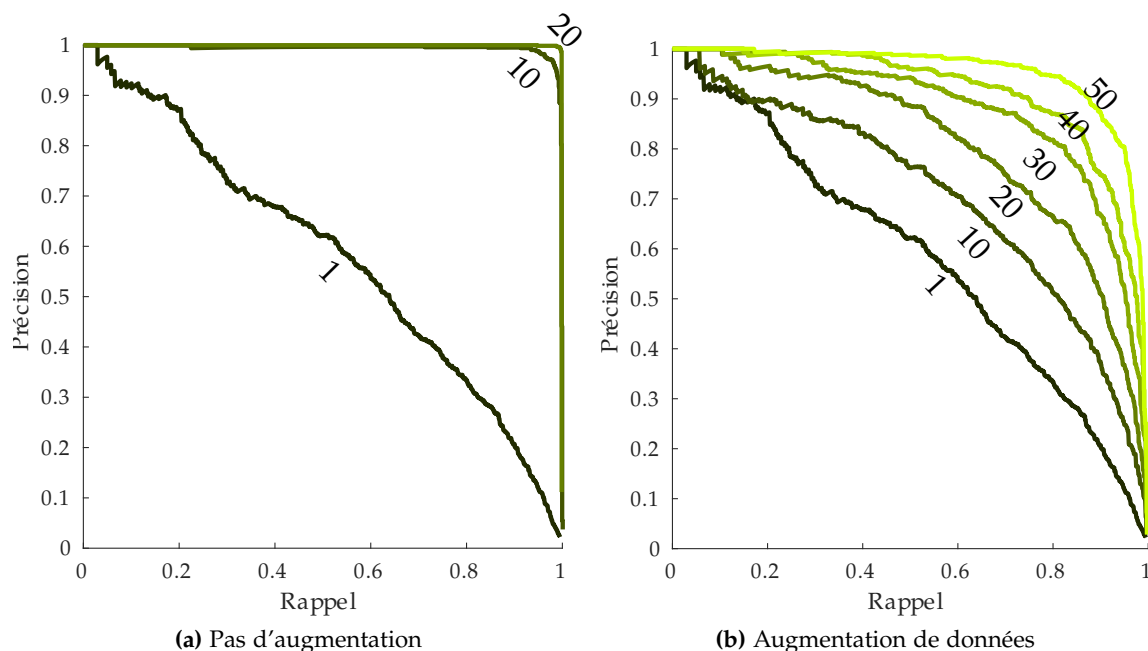


Figure 6.15 – Effet de l'augmentation de données sur les courbes Rappel/Précision MBV du jeu d'apprentissage. Chaque courbe et nombre associé représente un nombre d'epochs.

On peut alors mettre en regard ces observations avec celles sur la base de test (figure 6.16). L'imperfection des résultats confirme l'hypothèse du sur-apprentissage : les règles apprises étaient trop spécifiques et ne fonctionnent plus de façon satisfaisante sur la base de test. On remarque aussi un autre phénomène lié au sur-apprentissage : le rappel maximal diminue avec le nombre d'epoch sur la base de test (indiqués par des traits pointillés verticaux sur la figure 6.16(a)). C'est une conséquence logique des règles trop spécifiques, car de nombreuses feuilles ne seront jamais détectées, même avec un score faible. L'augmentation de données permet de corriger logiquement ce problème. Les performances évoluent assez vite sur la base test. Dans les deux cas, il suffit de 10 epochs pour atteindre le pallier de performances. Dans l'ensemble, les performances semblent

meilleures avec augmentation de données, en particulier pour les échantillons les plus difficiles à rappeler (ovales en pointillés sur la figure 6.16).

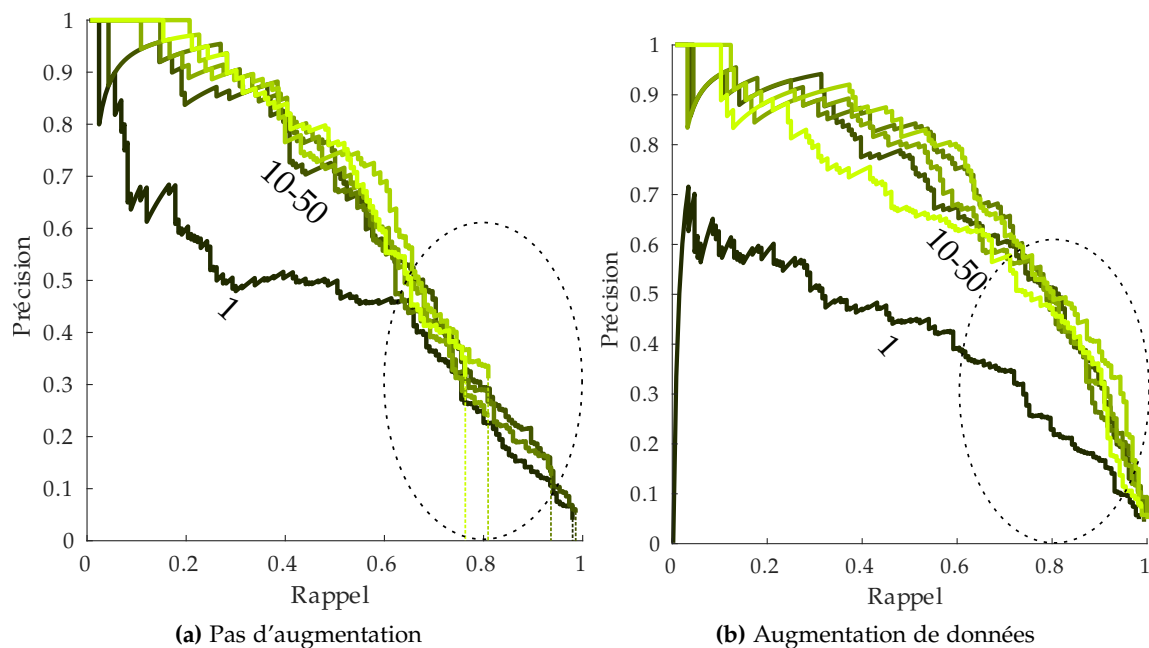


Figure 6.16 – Effet de l'augmentation de données sur les courbes rappel précision MBV du jeu de test. (a) : Les traits verticaux en pointillés représentent le rappel maximal obtenu pour chaque expérience

La figure 6.17 représente la précision pondérée pour l'ensemble des échantillons esca labellisés. Les mesures de Average Precision (AP) sont généralement assez faibles, surtout dans le cas où une partie non négligeable des échantillons est difficilement détectable. C'est le cas ici où les symptômes d'esca peu prononcés sont présents en majorité. On retrouve dans cette figure le pallier de performances après 10 epochs.

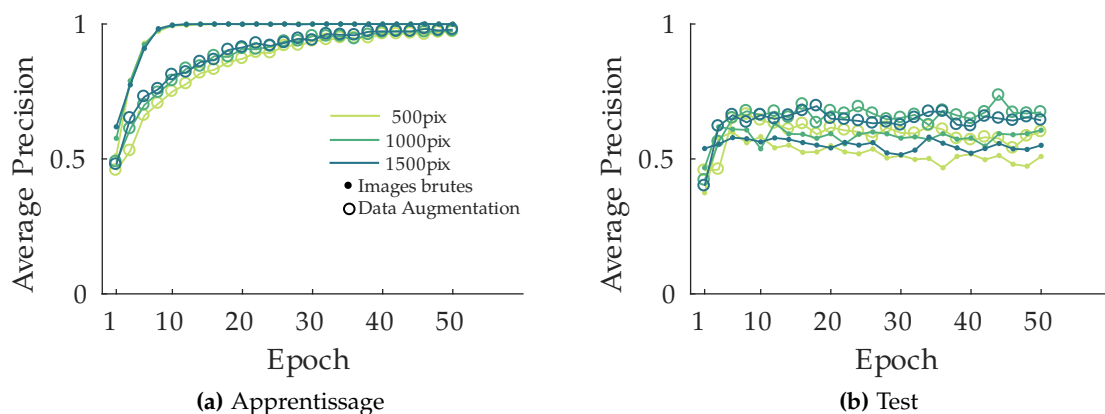


Figure 6.17 – Métrique Average Precision pour la classe esca sur les jeux d'apprentissage et de test, en fonction de la taille de l'image et de l'utilisation ou non de *data augmentation*

Le surapprentissage peut ici être appréhendé en considérant la différence entre la mesure de précision sur la base d'apprentissage et sur la base de test, différence moins importante lorsque l'augmentation de données est active. On observe aussi des gains de précision importants d'environ 10% sur la base de validation en utilisant l'augmentation de données. Le rôle de la taille de l'image en entrée est plus subtil. On constate peu de différences selon que l'image soit redimensionnée à 1000 ou 1500 pixels de côté. La différence est un peu plus importante pour des images de 500 pixels de côté, où la structure des symptômes commence à être altérée (voir figure 6.3). Encore une fois, l'altération dépend de la taille originale des feuilles, les grandes feuilles sont donc sûrement moins touchées par le passage à 500 pixels de côté.

6.3.5 Correspondance entre surface annotée et détectée

Les métriques sur la base de données ne prennent cependant pas en compte les performances individuelles par image. A l'échelle du pied, le but est de déterminer si des symptômes d'esca sont présents et en quelle quantité. En d'autres termes, l'évaluation du modèle doit déterminer si la quantité de symptômes prédite sur un pied correspond approximativement à la quantité annotée. En réalité, on souhaiterait pouvoir séparer les pieds en quelques catégories simples d'atteinte, sans se préoccuper de la quantification exacte.

Cette idée peut être concrétisée de façon simple en considérant le nombre de détections ou la surface en détections. Le premier peut être vu comme le nombre de feuilles atteintes et le second comme une superficie foliaire. On fera ici le choix de la superficie comme indicateur. On fixera de même le seuil de score à 0.5. La correspondance entre surfaces annotées et détectée est représentée visuellement dans la figure 6.18 sans data augmentation et dans la figure 6.19 avec *data augmentation*. On considérera alors que tous les pieds sur l'axe des abscisses (annotations présentes mais pas de détections) sont des faux positifs, ceux sur l'axe des ordonnées (détections mais aucune annotation) des faux négatifs et ceux sur l'origine des vrais négatifs (aucune détection ni annotation). Les autres échantillons en noir peuvent être considérés comme des vrais positifs, bien que leur qualité soit variable.

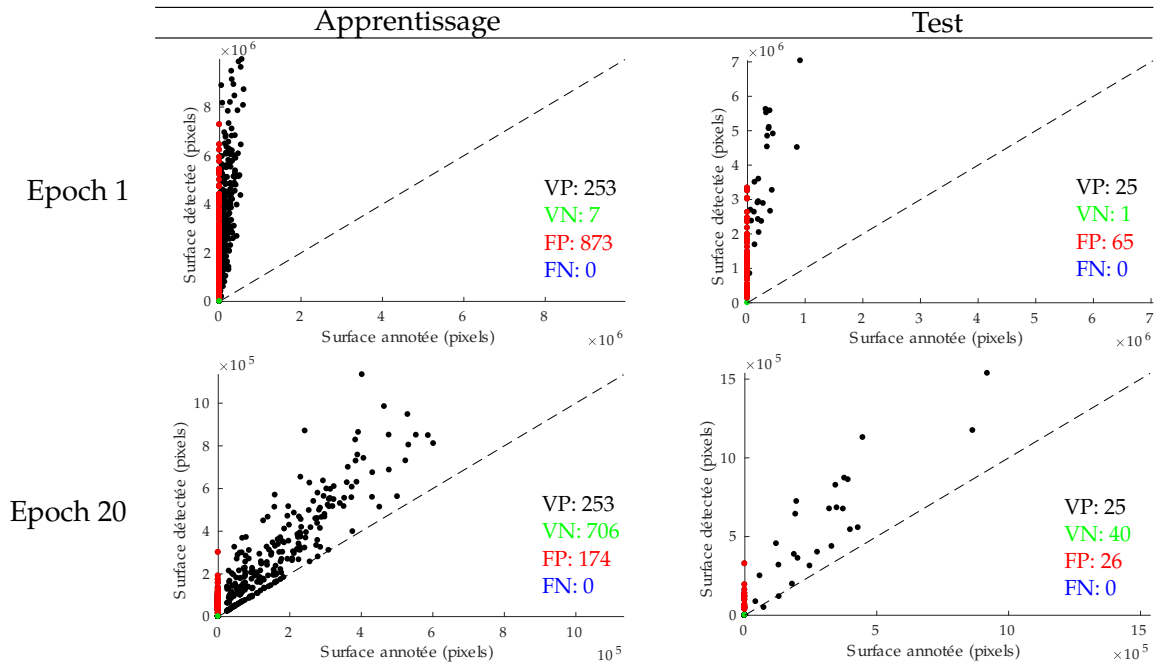


Figure 6.18 – Corrélation entre surface détectée et surface annotée pour les jeux d'apprentissages et de test à différentes epochs. Pas de data augmentation. Seuil score = 0.5

En début d'apprentissage, la surface détectée est bien supérieure à la surface annotée dans le cas où l'augmentation de données n'est pas utilisée. Celle-ci est d'apparence plus aléatoire et comprend de nombreux faux négatifs si l'augmentation est activée. Au fil des epochs, une corrélation directe entre les deux surfaces commence à être visible, pour les données d'apprentissage et de test. La surface détectée a cependant tendance à être légèrement supérieure à la surface annotée pour un seuil de 0.5 sur le score. Les résultats sont comparables mais semblent de meilleure qualité en utilisant l'augmentation de données, le nombre de pieds faux positifs est ainsi plus faible et aucun faux négatif n'est constaté. On obtient une corrélation satisfaisante entre les deux surfaces, rendant possible la détection de pieds symptomatiques esca en l'accompagnant d'un indice de sévérité.

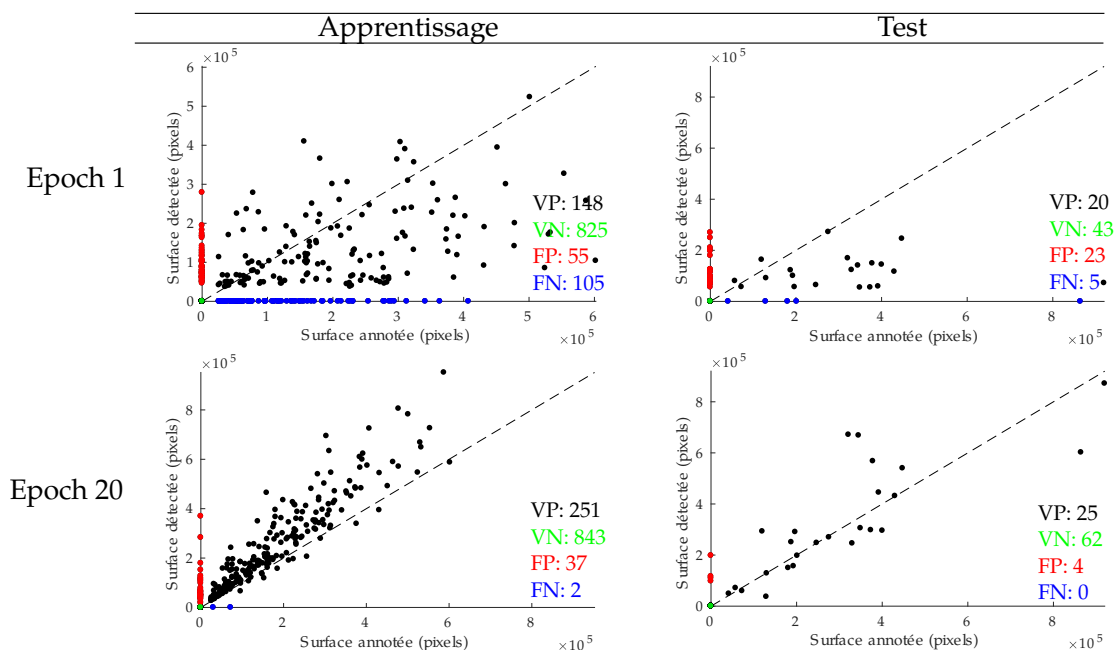


Figure 6.19 – Corrélation entre surface détectée et surface annotée pour les jeux d'apprentissages et de test à différentes epochs. Utilisation de la *data augmentation*. Seuil score = 0.5. Points bleus : Faux Négatifs. Points rouges : Faux positifs. Points verts : Vrais Négatifs

On notera ici que la surface détectée étant comparée à la surface annotée, celle-ci n'est pas comparée à la surface véritable. Des zones d'occlusion sont à prévoir et le passage n'est réalisé que sur un côté du rang. Il est ainsi impossible de retrouver tous les symptômes de la plante, même en ne ratant pas de feuilles sur les images. Ce décalage ici est moins important que pour d'autres tâches comme le calcul du rendement car la variable que l'on souhaite obtenir en sortie est plus qualitative ("pas de symptômes", "peu de symptômes", "beaucoup de symptômes") que quantitative.

6.3.6 Temps de calcul

Il est possible de mesurer le temps de calcul pour chacun de ces tests, en considérant le temps mis pour apprendre le réseau et le temps mis pour prédire. Bien que le temps mis pour apprendre soit le plus élevé, l'élément important est le temps de prédiction car il conditionne la possibilité d'une application en temps réel au champ. Les temps mesurés dans le code Python sont indiqués dans le tableau 6.2.

Tableau 6.2 – Temps de calcul sur une carte graphique GTX 1060 (mémoire 6Go)

| Taille d'image | 500 | 1 000 | 1 500 |
|---|------|-------|-------|
| Temps d'apprentissage (nombre d'heures pour 1 epoch) | 0.12 | 0.40 | 0.44 |
| Temps de prédiction (nombre de secondes pour 1 image) | 0.15 | 0.16 | 0.18 |

Étonnamment, la taille des images semble avoir très peu d'influence sur le temps de prédiction, alors que la taille agit (de façon non linéaire) sur la phase d'apprentissage. A première vue, ces temps semblent compatibles avec une application terrain, ils ne nous renseignent cependant pas sur le temps de calcul réel sur un appareil mobile non doté d'une carte graphique pour ordinateur de bureau. Des versions moins profondes du réseau MobileNet pourraient alors être envisagées pour améliorer les temps de calcul à condition que la perte de performances ne soit pas trop importante.

6.4 CONCLUSIONS ET PERSPECTIVES

6.4.1 Conclusions

Dans cette partie, nous avons étudié les possibilités, problèmes et perspectives liés à un algorithme de classification puis de détection des maladies du bois de la vigne prenant en compte d'autres troubles courants. Une comparaison entre descripteurs SIFT et méthodes de *deep learning* a de même été réalisée. Sur la base de cette comparaison, la branche *transfer learning* des algorithmes *deep learning* s'est avérée être un outil simple et performant pour répondre au problème de classification d'images posé. Le réseau MobileNet a ainsi été retenu pour conduire les expérimentations. Ces expériences ont de même permis de mettre respectivement en évidence l'importance de la base de données (variété, nombre d'échantillons, format de la notation terrain), de la dimensionnalité (problèmes liés aux grandes dimensionnalités, réduction de l'information) et du paramétrage (stabilité des résultats aux paramètres de l'expérience). Les solutions de classification *deep learning* ont apporté des réponses relativement satisfaisantes aux problèmes de dimensionnalité et de paramétrage, tout en proposant les meilleures performances.

Leur autre avantage est leur capacité à s'intégrer naturellement dans des réseaux plus importants dédiés à la détection. C'est ce qui a été montré à l'aide du réseau RetinaNet, adapté aux problèmes de détection où la classe de fond (le feuillage sain) est majoritaire. L'architecture entraînée permet alors de qualifier puis de quantifier approximativement l'atteinte du pied à l'esca en temps réel sur un GPU. Les algorithmes d'augmentation de données permettent d'améliorer de façon significative les performances de cette architecture, ce qui mène encore une fois à constater l'influence primordiale de la base de données.

L'approche accuse cependant certaines limitations. Les performances du réseau proposé peuvent être tout d'abord limitées par plusieurs facteurs algorithmiques. L'invariance à l'échelle, la rotation et l'éclairage en font partie, bien que celles-ci soit partiellement prises en compte par l'architecture *deep learning* et par l'utilisation de la data augmentation. L'intégration sur ordinateur embarqué sur un engin agricole est aussi à tester, le temps réel n'étant possible que si les images peuvent être traitées avant la prise de l'image suivante. Dans le cas où le temps réel n'est pas possible, l'application des traitements en différé pour obtenir une carte de symptômes reste cependant envisageable.

Il existe aussi d'autres facteurs limitants liés au terrain. Le comportement de l'esca et l'apparition de symptômes sont erratiques. Cela veut dire qu'il est nécessaire d'avoir

plusieurs années de mesures pour réaliser une cartographie quasi exhaustive de tous les pieds malades à la parcelle. L'évolution des symptômes à l'échelle d'un été peut être aussi rapide et difficile à prévoir, on passe très vite d'un pied sain à un pied en forme apoplectique sans pouvoir constater les symptômes de la forme lente.

6.4.2 Perspectives

On peut tirer deux perspectives principales pour améliorer les résultats et généraliser l'architecture en un produit robuste applicable au champ. La première concerne logiquement la base de données. La base de données idéale pour cette tâche comprend de nombreuses parcelles, cépages et conditions d'éclairages. Elle peut aussi comprendre plusieurs échelles et angles de vue. L'augmentation de la taille de la base de données pourrait être accompagnée d'une séparation de la meta-classe de facteurs confondants en symptômes distincts (flavescence, mildiou, carences, dégâts d'insecte, etc.). En plus de potentiellement améliorer les performances, cela permettrait de mettre au point une cartographie de plusieurs types de symptômes à la parcelle. La deuxième perspective concerne l'architecture du *deep learning*, domaine en perpétuelle évolution. De nombreuses autres formes de réseaux pourraient être mobilisées pour réaliser la détection des symptômes. On pourrait par exemple réaliser une détection plus fine qu'avec des boîtes, en considérant aussi la segmentation individuelle des organes de la vigne dans le procédé (grappes, tiges etc). L'idéal serait donc un algorithme d'analyse de la vigne remplissant plusieurs fonctionnalités telles que la détection de maladies ou l'estimation du rendement en temps réel. Le *deep learning* fournit un cadre unifié permettant d'y parvenir, mais sa complexité et ses constantes évolutions impliquent de nombreuses recherches avant d'aboutir à un produit adapté.

Troisième partie

ETUDE DES SYMPTÔMES DE L'ESCA PAR IMAGERIE HYPERSPÉCTRALE

Cette partie s'intéresse aux possibilités nouvelles offertes par l'imagerie hyperspectrale en proxidtection pour l'étude des symptômes de l'esca. La démarche est à la fois motivée par la description du comportement spectral des symptômes visibles et par celle de symptômes invisibles à l'œil, dont l'existence est seulement supposée. Un protocole expérimental spécifique à l'hyperspectral doit être mis en place : celui-ci comporte un montage adapté au terrain mais aussi un ensemble d'algorithmes permettant de traiter la donnée. Les mêmes parcelles que pour l'imagerie visible seront ici utilisées pour la constitution de la base de données hyperspectrale. De nombreuses difficultés (principalement les corrections radiométriques) jalonnent l'exploitation de la donnée hyperspectrale, certaines non surmontables en conditions réelles. Le premier chapitre examinera les moyens permettant de réduire ces difficultés par le biais de prétraitements éliminant les effets additifs et multiplicatifs puis le deuxième chapitre se penchera sur les méthodes de réduction de la dimensionnalité permettant de retenir l'information d'intérêt dans le spectre. Les longueurs d'onde d'intérêt retenues et leur capacité de discrimination pour les différents problèmes de classification permettent d'apporter de nouvelles pistes sur le potentiel de cette technologie.

7

APPLICATION DE L'IMAGERIE HYPERSPECTRALE : ETAT DE L'ART ET PROTOCOLE EXPÉRIMENTAL

Sommaire

| | | |
|--------|---|-----|
| 7.1 | Problématique | 132 |
| 7.2 | Exemples d'applications en agriculture | 133 |
| 7.3 | Problématiques méthodologiques associées à l'imagerie hyperspectrale | 135 |
| 7.3.1 | Le problème de la réflectance : de la donnée brute à la mesure physique | 135 |
| 7.3.2 | Le problème de la fidélité spatiale : limitations des capteurs hyperspectraux | 137 |
| 7.3.3 | Le problème de dimensionnalité : Extraction de l'information en haute dimension | 138 |
| 7.4 | Définition du problème de classification | 139 |
| 7.5 | Protocole expérimental | 139 |
| 7.5.1 | Capteur hyperspectral utilisé | 139 |
| 7.5.2 | Travaux préliminaires : acquisition aérienne | 140 |
| 7.5.3 | Montage d'acquisition terrestre | 141 |
| 7.5.4 | Conditions d'acquisition | 142 |
| 7.5.5 | Échantillonnage | 142 |
| 7.5.6 | Exemple d'image acquise | 143 |
| 7.6 | Choix des classes et étiquetage | 144 |
| 7.6.1 | Première échelle : organes de la vigne | 144 |
| 7.6.2 | Seconde échelle : Symptômes visibles de l'esca | 144 |
| 7.6.3 | Troisième échelle : Symptômes non visibles | 145 |
| 7.6.4 | Agrégation des échantillons par régions | 145 |
| 7.6.5 | Résumé des notations | 146 |
| 7.6.6 | Premières observations sur les données | 147 |
| 7.7 | Redondance de l'information et influence de la résolution spectrale . . | 148 |
| 7.8 | Lissage spectral des données | 149 |
| 7.9 | Première correction radiométrique par la référence | 150 |
| 7.10 | Seconde correction des spectres | 151 |
| 7.10.1 | Correction des effets additifs | 151 |
| 7.10.2 | Correction des effets multiplicatifs | 152 |
| 7.11 | Conclusions | 154 |

7.1 PROBLÉMATIQUE

Comme nous l'avons vu dans le [chapitre 2](#), l'information visible (que l'on exploite dans le [chapitre 4](#) pour la classification de symptômes) n'est qu'une partie de l'information

réelle du spectre exploitable. Le domaine du proche infra-rouge et sa transition avec le visible (*red-edge*) sont aussi des candidats sérieux pour l'étude de l'état sanitaire des plantes. Les feuilles, dont les propriétés optiques sont bien connues (voir [41] et [63]), sont d'un intérêt tout particulier car des changements très fins liés aux troubles physiologiques peuvent y être mesurés. On citera par exemple les pics d'absorption caractéristiques dus à la chlorophylle et à la teneur en eau de la feuille ou le plateau du proche infra-rouge tenant compte de la structure cellulaire. Le capteur hyperspectral fournit de son côté un cube de données combinant les avantages d'une caméra classique et d'un spectroradiomètre ponctuel. Il permet donc d'obtenir une image de la feuille où le spectre est mesuré en chaque pixel. On s'intéressera ici à la mise en place d'un protocole de mesures au champ et à l'analyse des données correspondantes. Le capteur hyperspectral fournit une image, mais la différence avec un capteur RVB est le nombre de canaux et la plage de mesure spectrale. Les méthodes et concepts mobilisés seront très différents. On s'inspirera dans un premier temps des diverses applications agricoles utilisant ce type de capteur avant de définir le protocole et les traitements permettant de répondre aux problématiques.

7.2 EXEMPLES D'APPLICATIONS EN AGRICULTURE

Dans le domaine agricole, l'application de l'imagerie hyperspectrale la plus répandue dans la littérature est la détection précoce de maladies dans le proche infra-rouge, qui est permise par la vaste gamme de longueurs d'ondes mesurée par le capteur et par leur précision spectrale (mesure d'un spectre continu). En serre, l'imagerie hyperspectrale peut être intégrée dans un protocole complet de détection, par exemple pour la détection d'infection virale sur des plantes de tabac [93]. L'étude rapporte notamment un décalage classique dans l'origine du *red-edge* 20 jours après l'infection et avant l'apparition des symptômes visibles. Les spectres ne sont cependant pas forcément utilisés de façon brute, Barwoski *et al* utilisent la dérivée seconde dans le proche infrarouge pour détecter une infection fongique chez le colza et obtenir des résultats similaires à l'imagerie thermique [11]. D'autres études adoptent des méthodes de réduction de la dimensionnalité du spectre pour prédire l'état de la plante. C'est le cas sur le blé par exemple, une Analyse en Composantes Principales (ACP) est appliquée au spectre dans le visible et le proche-infrarouge pour ne garder que l'information d'intérêt dans les composantes principales [14]. L'étude précise cependant que cette différenciation dépend du stade phénologique, celle-ci étant impossible à certains stades. Parmi les sujets de recherche souvent abordés, on citera la détection précoce du stress biotique chez le pommier. D'abord appuyé par des mesures au spectroradiomètre de terrain [48], des ratios entre bandes ont été utilisés pour détecter le stress biotique 10 jours avant l'apparition visible des symptômes. La recherche continuera plus tard avec l'utilisation de caméras hyperspectrales introduisant une dimension spatiale aux images [135]. Ces travaux tirent profit des conditions contrôlées pour mettre en correspondance les pixels d'image en image au sein d'une série temporelle et créer une base de données hyperspectrale temporelle, chose qui serait impossible en conditions réelles.

Toujours en lien avec la composante spatiale, Mahlein *et al* insistent sur le rôle de la résolution spatiale dans la détermination des zones infectées sans pixels de mélange,

l'étude étant dédiée aux symptômes provoqués par différentes maladies de la betterave sucrière [118]. Les problèmes liés au stress abiotique peuvent aussi être remarqués de façon précoce, comme en témoigne une étude sur la détection du stress hydrique de la plante d'orge en proxidtection [16]. Dans cette étude, divers indices de végétation résumant l'information en un seul canal sont utilisés pour détecter différents niveaux de sénescence. Les indices de végétation utilisés semblent permettre de détecter la sécheresse 10 jours avant la détection grâce à l'indice de végétation Normalized Difference Vegetation Index (NDVI). L'étude aborde aussi la question du transfert des règles de classification sur une autre culture en l'appliquant au maïs, avec un succès modéré. D'autres applications plus originales ne sont pas appliquées à la détection précoce sur feuille mais sur fruit, en détectant les effets des chocs sur le fruit lors du transport avant l'œil humain [53]. Les méthodes utilisées pour exploiter les spectres restent cependant similaires.

Des montages spécifiques sont toujours nécessaires pour adapter la technologie au champ, que l'étude soit précédée d'expérimentations en laboratoire ou non. L'importance du protocole expérimental est souvent mise en avant, avec des dispositifs complets permettant de réaliser l'acquisition et d'obtenir les données nécessaires aux prétraitements. Dans un premier temps, ces considérations ont surtout été appliquées à l'imagerie hyperspectrale aérienne, avec la conception de caméras hyperspectrales dédiées ainsi que des protocoles d'acquisition et de traitement correspondants [1]. On retrouve aussi ces considérations pour l'imagerie multispectrale terrestre [25]. Ici, un montage est conçu spécifiquement pour mesurer la vigueur de la vigne en proxidtection. D'autres applications viticoles semblent aussi pouvoir bénéficier de l'information apportée par l'imagerie hyperspectrale. La discrimination de plusieurs cépages à l'aide d'un montage hyperspectral terrestre spécifique a été récemment abordée [70]. La prédiction y est réalisée pour 30 cépages à 2 stades phénologiques différents. Le même objectif de discrimination de cépage peut aussi être atteint par un vecteur hyperspectral aérien [5]. A ce sujet, les différences spectrales fines entre cépages sont de même abordées dans [31], mettant en évidence un effet cépage plus ou moins marqué. Ces conclusions illustrent les difficultés potentiellement rencontrées pour la généralisation d'algorithmes ayant appris sur des cépages isolés.

Dans les exemples précédents, un seul capteur est utilisé pour une seule application spécifique. Ce n'est cependant pas le cas pour toutes les études. La plate-forme *HyperArt* appliquée à la betterave sucrière utilise l'imagerie hyperspectrale pour l'estimation de la sévérité des maladies mais aussi pour une estimation de la vigueur [20]. Un spectroradiomètre de terrain est utilisé conjointement pour fournir des mesures de référence. De même, certains montages utilisent plusieurs capteurs (dont une caméra hyperspectrale) comme dans Busemeyer *et al* où le montage tiré par un tracteur utilise conjointement l'imagerie couleur et hyperspectrale ainsi qu'un dispositif laser (LIDAR) permettant de reconstituer la géométrie du couvert [30]. L'ensemble est utilisé pour le phénotypage général sur les cultures céréalières. L'objectif à moyen terme de ces dispositifs est de pouvoir être intégré à un engin agricole à vitesse réelle afin de réaliser rapidement une cartographie de la donnée recherchée. On retrouve cependant des approches similaires pour la détection précoce avec un vecteur aérien [32]. La verticilliose de l'olivier y est détectée précocement à l'aide d'indices de végétation classiques, en la combinant à des

mesures de fluorescence et de température.

Malgré son potentiel attrayant, de nombreux problèmes pratiques complexifient cependant l'utilisation de l'imagerie hyperspectrale en conditions réelles.

7.3 PROBLÉMATIQUES MÉTHODOLOGIQUES ASSOCIÉES À L'IMAGERIE HYPERSPECTRALE

Les images obtenues par une caméra hyperspectrale, bien que spectralement et spatialement riches, sont complexes à traiter. Il existe plusieurs barrières méthodologiques pour l'exploitation des images hyperspectrales. Ces problèmes sont rencontrés dans la littérature depuis très longtemps et font l'objet de contributions méthodologiques à part entière. Ces barrières au nombre de trois séparent largement les applications hyperspectrales des applications multispectrales ou spectrométriques :

- La correction des données en réflectance
- Les déformations sur les dimensions spatiales
- La dimensionnalité des spectres résultants

7.3.1 *Le problème de la réflectance : de la donnée brute à la mesure physique*

Le capteur hyperspectral mesure pour chacune de ses longueurs d'onde une quantité de lumière reçue. Cette quantité physique analogique est convertie en quantité numérique souvent appelée Compte Numérique (CN). Cette valeur sans unité pourrait être exploitée de façon brute mais son manque de signification physique universelle implique que seules les variations relatives à l'intérieur d'une scène homogène ont du sens. Le CN est donc différent de la réflectance qui est la véritable valeur recherchée et qui dépend seulement de la nature de la surface (et de la longueur d'onde) et non des conditions d'éclairage. La réflectance peut être définie par le biais de l'équation de conservation de l'énergie incidente. Soit $L_I(\lambda)$ la luminance incidente (éclairage) sur un matériau, cette énergie peut être soit réfléchi (L_R), soit absorbée (L_A) soit transmise (L_T) par la surface. On obtient alors, pour une longueur d'onde λ :

$$L_I(\lambda) = L_R(\lambda) + L_A(\lambda) + L_T(\lambda) \quad (15)$$

$$r(\lambda) = \frac{L_R(\lambda)}{L_I(\lambda)} \quad (16)$$

où $r(\lambda)$ est le coefficient de réflectance pour la longueur d'onde λ , compris entre 0 et 1. En réalité, il n'est pas forcément nécessaire de calculer les autres termes pour déduire la réflectance. Il est possible de calculer la réflectance d'une surface en considérant une autre surface dont l'énergie est quasi intégralement réfléchi (pas d'absorption ni de transmission). Si on considère que l'énergie incidente est la même pour les deux objets (c'est le cas si la source d'éclairage est identique, par exemple la lumière naturelle du soleil), le rapport entre les valeurs mesurées sur les deux surfaces peut s'apparenter à une estimation de la réflectance.

Les termes d'énergie de l'équation sont en pratique remplacés par le CN, après réduction du bruit électronique mesuré lorsque aucun signal ne parvient à la caméra, permettant ainsi d'estimer très facilement la réflectance. Le matériau de référence radiométrique (souvent appelé *spectralon* par abus de langage) doit avoir des propriétés connues et si possible constantes (lambertien) dans la gamme de longueurs d'ondes où a lieu le mesure. On considérera ainsi souvent un matériau certifié à 95% de réflectance dans le visible et le proche infrarouge.

$$r(\lambda) \simeq \frac{CN(\lambda) - CN_{\text{bruit}}(\lambda)}{CN_{\text{ref}}(\lambda) - CN_{\text{bruit}}(\lambda)} \quad (17)$$

La réalité est cependant plus complexe. La part d'énergie réfléchi ne dépend pas seulement de la longueur d'onde mais aussi de l'angle d'impact du rayon incident et de l'angle d'observation du rayon réfléchi. On peut définir deux cas simples correspondants à un matériau ne réfléchissant que dans un unique angle (réflexion spéculaire) et celui d'un matériau réfléchissant de la même façon dans toutes les directions (lambertien). La plupart des matériaux ne correspondent pas à ces deux cas idéaux, présentant à la fois une composante spéculaire et diffuse. Afin de formaliser ce phénomène, la Bidirectional Reflectance Distribution Function (BRDF) décrit la distribution des réflectances observées selon un angle incident et un angle réfléchi. Ces deux angles peuvent être en réalité eux mêmes décomposés en deux autres angles dans un espace à 3 dimensions : l'angle azimutal φ et l'angle zénithal θ . Le problème de la BRDF est connu depuis les années 1960 [134] et peut être résumé par la fonction :

$$r(\lambda) = f(\theta_i, \varphi_i, \theta_r, \varphi_r) \quad (18)$$

Cette fonction ne peut être ramenée à une constante que lorsque le matériau a un comportement diffus homogène. L'hypothèse lambertienne pour les surfaces sur la gamme de longueurs d'onde étudiée est donc cruciale. Celle-ci est par définition vérifiée pour un spectralon mais ne l'est pas pour une feuille de vigne (on observe des différences selon l'angle d'observation de la feuille). Cela pose un problème car les feuilles de vignes d'un palissage ont des angles variés et l'angle solaire n'est en principe pas constant entre deux acquisitions. Cela veut dire que la réflectance estimée est une pseudo-réflectance dépendant en réalité de la BRDF de l'objet (dont les paramètres ne sont pas mesurables directement).

Ce cadre théorique rend l'acquisition de données hyperspectrales en condition réelles périlleuse. On peut résumer la situation en citant les facteurs de variabilités des spectres mesurés (en dehors de la variabilité du matériel végétal en lui même) :

- La géométrie de la scène combinant l'angle solaire, l'angle des feuilles et l'angle d'observation,
- Le caractère non lambertien des feuilles et la présence conjointe de réflexion diffuse et spéculaire,
- La présence d'ombres au sein du couvert,

- La couverture nuageuse pouvant rendre le rayonnement incident diffus ou direct, mais aussi instable au cours de l'acquisition,
- Les multi-trajets des rayons lumineux au sein du feuillage (souvent considéré négligeable).

En pratique, lorsque l'on mesure un même type d'objet avec des conditions variables, la population de spectres obtenue sera variée en amplitude et en forme sur toute la gamme de longueurs d'onde. On peut cependant grossièrement séparer ces effets en deux catégories :

- Des effets additifs,
- Des effets multiplicatifs.

On peut alors considérer un spectre mesuré comme une fonction affine du spectre invarié. A ce titre, on considère souvent que l'effet multiplicatif ne dépend pas de la longueur d'onde, tandis que l'effet additif en dépend.

On a donc le choix de considérer seulement la pseudo-réfectance et d'utiliser des méthodes de prétraitement pour gommer ou modéliser la variabilité (dérivées [50], Standard Normal Variate (SNV), lissage [168], modélisation statistique [58], etc) ou alors de tenter de retrouver la réflectance réelle. Cela revient cependant à résoudre un problème d'inversion car on ne connaît pas les paramètres (ou seulement une gamme de valeurs *a priori*). La calibration radiométrique des images hyperspectrales peut être par exemple obtenue en utilisant conjointement une représentation 3D de la plante pour récupérer les angles foliaires précis [17]. D'autres études s'attachent à développer des modèles de transfert radiatif tel que COSINE permettant de retrouver une estimation de la réflectance sur des feuilles non plates en laboratoire [86]. La méthode semble cependant difficile à utiliser au champ. Les travaux de Wendel *et al.* se penchent quand à eux sur les possibilités de compensation des conditions de luminosité pour un dispositif hyperspectral terrestre [200]. En plus de la correction par référence radiométrique, une méthode nommée REGLOSS-SEP pour la récupération de la réflectance est implémentée. Des acquisitions en lumière directe ou avec couverture nuageuse sont aussi testées.

7.3.2 Le problème de la fidélité spatiale : limitations des capteurs hyperspectraux

D'ordinaire, les capteurs dédiés à l'imagerie visible et PIR utilisent des matrices CCD. Cela veut dire que toute l'image est par exemple acquise simultanément sur les 3 canaux R, V et B. Le problème devient plus complexe lorsque l'on augmente significativement le nombre de canaux pour un capteur imageur. Cela concerne par exemple les capteurs multispectraux embarqués sur les satellites ou les caméras hyperspectrales. Pour ces capteurs, l'acquisition de l'image se fait avec un montage dit *push-broom*, ce qui signifie que l'image est acquise ligne par ligne, le capteur matriciel étant utilisé pour une dimension spatiale et la dimension spectrale. L'autre dimension spatiale sera formée en concaténant plusieurs matrices lignes consécutives, formant ainsi le cube hyperspectral (figure 7.1). Cela implique aussi que le capteur se déplace le long de la cible. La méthode a pour inconvénient majeur d'être sensible au mouvement de la caméra ou des objets dans son champ durant la période d'acquisition. Sans correction, ces déformations visibles sur l'image rendent difficile voire impossible toute étape de segmentation tirant partie

des dépendances spatiales. Il est à noter que l'on peut trouver des exemples de caméras hyperspectrales *snapshot* permettant de réaliser des acquisitions en une seule prise [23].

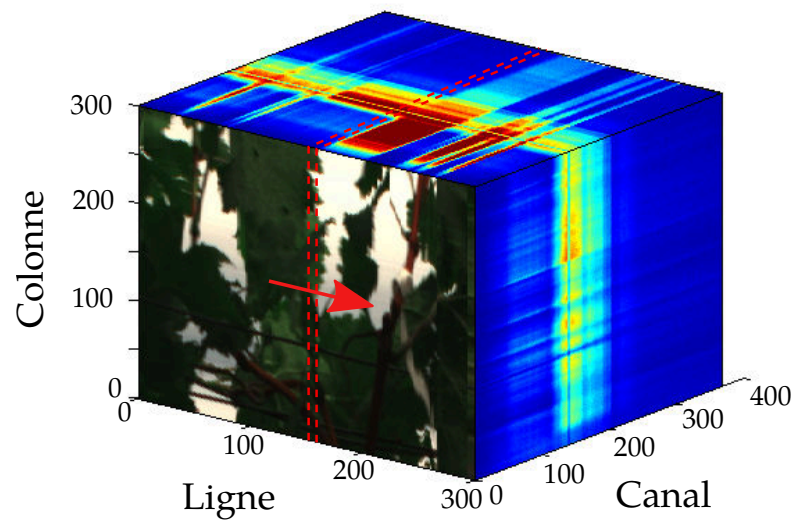


Figure 7.1 – Visualisation du cube hyperspectral de taille $300 \times 300 \times 368$ d'une scène contenant du feuillage et du ciel. L'image complète est acquise ligne par ligne, un exemple de ligne est indiqué par des pointillés rouge et le sens d'acquisition par la flèche rouge.

L'autre problème lié au capteur est la résolution spatiale des images. La résolution spatiale d'une image hyperspectrale est typiquement bien inférieure à celle d'une caméra multispectrale du commerce. Cela veut dire à première vue que la caméra enregistre moins de détails. L'interprétation est cependant légèrement différente en terme d'analyse de spectre. Lorsqu'un pixel hyperspectral recouvre deux matériaux adjacents, le spectre obtenu est un spectre dit de mélange, c'est à dire un intermédiaire entre ce que sont véritablement les deux spectres purs. C'est un problème lorsque l'on souhaite exploiter des signatures spectrales fines dans une étude. Par exemple une acquisition hyperspectrale aérienne risque de mesurer des spectres mélangeant végétation et sol dont les proportions de mélange sont variables selon la couverture végétale. Le démelange de spectres fait l'objet de recherches spécifique dans le domaine de l'imagerie hyperspectrale. De nombreux algorithmes sont ainsi dédiés à ce problème, notamment pour la détection de cibles [169].

7.3.3 Le problème de dimensionnalité : Extraction de l'information en haute dimension

Le dernier problème de l'imagerie hyperspectrale concerne la nature des jeux de données fournis par le capteur. Leurs deux signatures caractéristiques sont :

- Une dimensionnalité importante, souvent de l'ordre de plusieurs centaines d'attributs. La donnée hyperspectrale est touchée par ce qu'on appelle la fatalité de la dimension [79]. On tend dans certains cas à constater des performances de classification inférieures dans des espaces de très haute dimensionnalité en grande partie

car ces espaces sont majoritairement vides au sens de la métrique euclidienne classique (augmentation de la distance moyenne au proche voisin).

- Une importante corrélation, conséquence naturelle de l'aspect quasi continu du spectre. Prises indépendamment, les valeurs mesurées sont extrêmement redondantes. Prises ensemble, leur forme générale peut cependant être très informative.

Les problèmes liés à ces caractéristiques peuvent le plus souvent être évités en mettant en place des algorithmes résumant l'information hyperspectrale dans un espace de plus faible dimension, la décorrélation des bandes étant souvent effectuée de façon conjointe. En réalité, il est intéressant de constater que la dimensionnalité est aussi indirectement liée à la complexité du dispositif et à son coût. Une caméra hyperspectrale est plus coûteuse et contraignante qu'une caméra multispectrale, qui est elle-même plus coûteuse qu'une caméra RVB. L'acquisition dans des longueurs d'onde plus avancées du proche infrarouge est de même moins aisée. L'uni-dimensionnalité (une seule bande) correspond ainsi au capteur le plus simple. Ce n'est cependant pas forcément le moins coûteux à mettre en place dans une application commerciale.

En résumé, l'enjeu principal en hyperspectral est la mise en place d'un protocole et d'une méthodologie de prétraitement permettant d'aboutir à des spectres en réflectance ou pseudo-réflectance exploitables pour un problème donné. Selon l'application ce problème est plus ou moins surmontable. Les problèmes de fidélité spatiale et de dimensionnalité sont dans la plupart des cas moins contraignants que le problème central de correction radiométrique.

7.4 DÉFINITION DU PROBLÈME DE CLASSIFICATION

De la même façon que pour l'imagerie visible, on définit ici un problème de classification que l'on souhaite résoudre à l'aide de la donnée hyperspectrale. Le problème est ici centré autour d'une classe de référence qui est la feuille asymptotique sur pied sain. Cette classe doit représenter la population des feuilles saines pouvant être mesurées par la caméra. On articulera ainsi autour de cette classe pilier d'autres classes qui nous intéressent. L'idée sera ici de déterminer si la donnée hyperspectrale (attributs en entrée) permettra de les différencier de la classe référence à l'aide d'un classifieur. Afin de réaliser ces expériences de classification, il sera de même nécessaire de délimiter manuellement des échantillons d'apprentissage pour chaque classe (classification supervisée). Nous verrons ainsi dans la prochaine partie comment les données seront acquises et comment la base d'échantillons sera constituée.

7.5 PROTOCOLE EXPÉRIMENTAL

7.5.1 Capteur hyperspectral utilisé

Le capteur hyperspectral employé est issu d'une collaboration avec l'Université de Vigo. Il comporte 368 bandes équitablement réparties entre 404nm et 1376nm ainsi que 1280 pixels sur la dimension spatiale. Toutes les images obtenues à l'aide de ce capteur seront de taille 1280x1x368 où 1 est le nombre de lignes obtenues. Il est composé d'une caméra *BASLER ACA 1300-60 GM-NIR* associé à un monochromateur *HEADWALL* et à

des objectifs de 4.8mm et 8mm. Au sein d'un canal, chaque pixel est quantifié sur 12 bits. La fréquence d'acquisition de chaque ligne peut être fixée afin de s'adapter à différentes vitesses d'acquisition et d'obtenir une image aux proportions peu déformées (pixels aussi carrés que possible).

7.5.2 Travaux préliminaires : acquisition aérienne

Le capteur a d'abord été utilisé pour des travaux préliminaires en étant embarqué sur un avion léger (ULM) durant l'été 2015, permettant ainsi d'obtenir un cliché hyperspectral des parcelles d'étude du projet Advantage (figure 7.2).

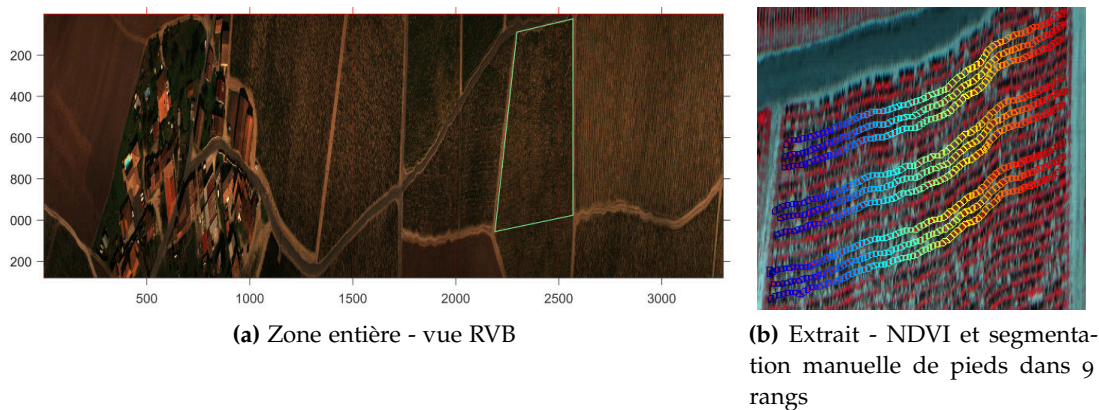


Figure 7.2 – (a) - Exemple d'image aérienne ULM au dessus de la parcelle en rouge représentée par un rectangle vert et (b) - délimitation semi-automatique des pieds de 9 rangs.

Une première étude a été réalisée afin de délimiter semi-automatiquement les pieds sur les images et d'extraire les pixels de chaque pied. La résolution de ces images est d'environ 50cm (en réalité la résolution est variable selon l'angle de visée du capteur, pouvant atteindre 2m dans les pires cas), ce qui signifie qu'un pied sera représenté par très peu de pixels. La séparation des pieds est d'ailleurs très difficile à faire avec ce type d'image car le feuillage de deux pieds consécutifs peut se confondre si des bras s'étalent à l'horizontale. Pire, les pixels mesurés sont le plus souvent issus d'un mélange avec les zones de sol et de végétation basse situées sous la vigne. L'ensemble de ces incertitudes rend les données difficilement exploitables.

Les difficultés rencontrées avec les données de télédétection ont poussé à envisager une utilisation alternative du capteur hyperspectral au sol. D'autres études préliminaires ont été réalisées pour juger la possibilité d'une acquisition par drone mais cette voie n'a finalement pas été explorée durant la thèse. Bien que représentant un bon compromis, cette méthode se heurte à de nombreux autres problèmes liés à la géométrie de l'acquisition. L'acquisition d'images de résolution centimétrique à basse altitude nécessite ainsi de voler à des vitesses où la stabilité de l'appareil et du capteur ne sont pas assurés (même en utilisant un stabilisateur gyroscopique). La suite sera donc seulement dédiée à l'hyperspectral terrestre.

7.5.3 Montage d'acquisition terrestre

Le dispositif d'acquisition se compose de la caméra hyperspectrale montée sur un petit chariot automoteur. Le capteur de la caméra nous oblige à multiplier les lignes d'acquisition afin d'obtenir une image complète. Cela veut donc dire que le chariot doit pouvoir se déplacer à vitesse constante sans perturbations le long du rang de vigne. L'acquisition à même le sol ne serait donc pas adaptée. Il est de même nécessaire de positionner la caméra de façon à pouvoir prendre le palissage dans sa hauteur. Nous avons fait le choix ici de faire circuler un petit chariot sur des rails à vitesse constante. L'acquisition se termine une fois que le chariot a atteint la fin des rails, résultant en des images contenant environ 3000 lignes pour 1280 colonnes et 368 bandes spectrales. La résolution des images est de l'ordre du centimètre. Cette distance d'acquisition permet dans notre cas d'acquérir le plus souvent 3 pieds de vigne à la fois. La caméra et le chariot sont tous deux déclenchés à distance depuis un ordinateur, permettant de fixer les paramètres de l'expérimentation et de récupérer les données par la suite. Les données sont volumineuses, 5Go environ. La figure 7.3 présente une photo du dispositif d'acquisition monté entre deux rangs de vigne.



Figure 7.3 – Photo du dispositif d'acquisition hyperspectral progressant dans un inter-rang. Le chariot avance sur l'échelle à vitesse constante et la caméra couvre plusieurs pieds de vigne.

Le dispositif expérimental a cependant comme inconvénient majeur d'être encombrant et long à transférer lorsque l'on passe d'un rang à l'autre. Son but est ici principalement d'acquérir des images très stables sur un nombre restreint de pieds, ce qui peut être réalisé au cours d'une journée d'expérimentation terrain.

7.5.3.1 Référence radiométrique

Afin de prendre en compte les conditions d'acquisition, il est nécessaire d'inclure dans les images un matériau fixe servant de référence. Étant donné qu'il est difficile d'adapter une référence radiométrique au terrain, on considère alors un jeu de trois feuilles de carton avec différents niveaux de gris dont le comportement est approximativement lambertien. Ces feuilles sont placées à la verticale devant l'objectif (angle d'observation constant) de manière à ce qu'une petite partie en bas de l'image hyperspectrale offre en

permanence une mesure de la référence. Le rôle de la référence à niveaux de gris multiple est d'obtenir plusieurs lectures et de pouvoir sélectionner la plus appropriée selon les conditions d'éclairage. En cas de saturation de la référence avec la plus grande réflectance, on pourra ainsi se rabattre sur le niveau précédent avec une réflectance inférieure.

7.5.3.2 *Élimination du fond*

Les rangs en arrière plan apparaissent naturellement sur l'image hyperspectrale à travers la porosité du feuillage. La présence des éléments du fond n'est cependant pas souhaitée car elle peut alourdir la lisibilité de l'image ou tout simplement induire d'éventuels algorithmes de détection en erreur. Un drap noir de très faible réflectance dans le visible et le proche infra-rouge est alors utilisé ici. Sa signature spectrale est suffisamment différente du matériel végétal pour pouvoir être différenciée sans erreur.

7.5.4 *Conditions d'acquisition*

Les conditions d'acquisition regroupent le moment de la journée et les conditions météorologiques. La variation principale induite par la météorologie est la présence d'un rayonnement direct (existence d'ombres) ou au contraire diffus (pas d'ombres). Selon la situation, le signal récupéré peut être plus ou moins fort et les mesures plus ou moins instables. Le tableau 7.1 présente un aperçu rapide des différences relatives entre les différentes conditions d'acquisition.

Tableau 7.1 – Influence du moment de la journée et de la météo sur l'acquisition

| | Lever/Coucher | Matin/après-midi | Zenith | Ensoleillé | Nuageux |
|----------------------|---------------|------------------|------------|------------|----------|
| Rayonnement | Diffus | Direct | Direct | Direct | Diffus |
| Rapport signal/bruit | Faible | Élevé | Très élevé | Élevé | Faible |
| Variabilité | Instable | Moyenne | Faible | Faible | Instable |

Dans notre cas, les acquisitions 2017 ont été réalisées en après-midi avec un rayonnement direct pour la parcelle en rouge et un rayonnement diffus pour la parcelle en blanc. Il serait intéressant de déterminer quels sont les effets concrets de ces conditions d'acquisition sur la qualité et la reproductibilité des résultats.

7.5.5 *Échantillonnage*

Le processus d'acquisition peut être assez long donc l'échantillonnage doit être adapté à un faible nombre d'images. On peut par exemple échantillonner environ 60 pieds avec une session de 20 images. L'échantillonnage est ici centré autour de la notation terrain. On tâche de sélectionner des pieds *a priori* sains, des pieds symptomatiques esca et des pieds malades mais ne présentant pas de symptômes l'année en cours. Les piquetées sélectionnées seront aussi réparties dans la partie de la parcelle étudiée. Un total de 38 images (soit une centaine de pieds) ont ainsi été acquises avec les rails de 3m sur l'année 2017.

7.5.6 Exemple d'image acquise

On peut représenter l'image hyperspectrale dans le sous espace Rouge Vert Bleu (RVB) en ne conservant que 3 bandes parmi les 368 (figure 7.4). Le contraste des images est augmenté après coup pour mieux distinguer certains éléments. La visualisation RVB n'est cependant pas représentative de la gamme de valeurs encodée par le capteur. Le fond noir est ici facilement visible, permettant de bien distinguer le palissage du rang mesuré.




Figure 7.4 – Exemple d'image hyperspectrale sur plusieurs pieds montrant le fond uni noir et la référence radiométrique (en bas de l'image)

Bien que l'image soit stable et non étirée, on remarque certains problèmes géométriques localement (exemple en figure 7.5(d)). Ceux-ci sont dus au mouvement des feuilles avec le vent ou à une irrégularité dans le mouvement du chariot. La figure 7.5 présente une comparaison entre deux zones prises à l'aide du capteur RVB de la partie précédente et du capteur hyperspectral. Deux semaines séparent les deux clichés donc des différences sont constatées, notamment pour l'avancée des symptômes d'esca. On retrouve de même un bruit de fond plus important dans ces images.




Figure 7.5 – Comparaison imagerie visible et hyperspectrale (avec deux semaines de décalage). Cadre bleu : exemple de déformation géométrique due au déplacement de la feuille durant l'acquisition

7.6 CHOIX DES CLASSES ET ÉTIQUETAGE

La feuille saine sera ici considérée comme la référence, toutes les classes considérées seront donc implicitement comparées à cette référence. Les classes sont séparées en trois grandes catégories. On commence par considérer les spectres facilement différenciables à l'aide de la donnée hyperspectrale pour arriver sur des classes plus subtiles (voire pour lesquelles on ne peut assurer l'existence de facteurs de différenciation).

7.6.1 Première échelle : organes de la vigne

Les organes de la vignes autres que les feuilles ne nous intéressent pas directement mais sont naturellement présents dans les images. On s'attend à ce que ces matériaux de natures variées aient une signature spectrale radicalement différente de celle de la feuille saine et ce, sur toute la gamme de longueurs d'onde mesurées. On considérera ainsi dans cette meta-classe :

- Les grappes de raisin (●)
- Les tiges, que l'on séparera en tiges "vertes" (●) et tiges lignifiées (●) selon l'état d'avancement de l'aoutement. Selon le moment de l'été, la proportion en ces deux types de tiges est variable. Des aberrations chromatiques peuvent être exceptionnellement constatées sur le bord des tiges pour les plus petites d'entre elles (le phénomène est en réalité surtout remarquable sur les fils tendeurs de la vigne).
- Le bois (●) présent sur le tronc de la plante

Tous ces échantillons sont présents en nombre dans les images, il n'est donc pas difficile de constituer une base conséquente. La classe grappe est cependant limitée aux stades phénologiques mesurés durant les expérimentations. On peut facilement conjecturer que la signature spectrale d'une grappe de raisin est en réalité très variable selon le cépage et le stade de maturation (pigmentation et composition chimique différente).

7.6.2 Seconde échelle : Symptômes visibles de l'esca

Les symptômes visibles de l'esca peuvent être grossièrement séparés en trois plages de décolorations différentes :

- Les décolorations jaunes (●)
- Les décolorations rouges (●)
- Les dessèchements marron/gris (●)

Ces trois stades sont facilement distinguables à l'œil nu et ne posent donc pas de gros problèmes de différenciation, bien que la frontière soit parfois floue entre les différents stades. La connaissance des longueurs d'onde impliquées dans le visible mais aussi le proche infrarouge font cependant de ces classes un objet d'étude intéressant. Les décolorations rouges ainsi que les dessèchements sont les plus faciles à échantillonner. Les décolorations jaunes sont moins nombreuses et plus difficiles à retrouver car le liseré jaune peut apparaître très fin avec la résolution d'une caméra hyperspectrale. Des mélanges de spectres risquent de même de survenir. Le nombre d'échantillons est donc plus faible dans la base de données constituée.

7.6.3 Troisième échelle : Symptômes non visibles

Cette catégorie est particulière car elle concerne des symptômes "virtuels", c'est à dire dont on ne peut vérifier l'existence réelle. La détection précoce consiste à faire l'hypothèse qu'il est possible de détecter les symptômes avant leur apparition, hypothèse qui pourrait être fautive. Il existe plusieurs cas de figure possibles pour classer les feuilles vertes appartenant à un pied malade :

- Les zones "vertes" sur feuilles symptomatiques, classe appelée ici *Asympt1* (●)
- Les feuilles sans symptôme sur un pied avec des feuilles symptomatiques, appelée ici *Asympt2* (●). On ne fera pas de distinction selon que les feuilles symptomatiques soient sur le même bras ou non.
- Les feuilles sans symptôme sur un pied sans symptôme mais ayant exprimé des symptômes au moins une fois les années précédentes, appelée ici *Asympt3* (●)

On peut imaginer que la présence d'un signal différent des feuilles saines devient progressivement plus incertaine avec ces trois classes. Etant donné que les pieds correspondant aux deux premières classes expriment des symptômes, ces classes ne sont en réalité pas vraiment intéressantes pour la détection précoce. Cependant, bien que seule la classe *Asympt3* corresponde à la détection précoce, d'éventuelles longueurs d'onde d'intérêt sur les deux autres classes seraient déjà une information précieuse.

La base de données est constituée en notant à l'échelle du pixel les échantillons sur un calque à l'aide du logiciel GIMP. Au moment de la notation des pixels, on prend comme référence visuelle l'image hyperspectrale projetée dans l'espace Rouge Vert Bleu (RVB).

7.6.4 Agrégation des échantillons par régions

Les échantillons annotés sont nombreux mais en réalité partiellement redondants. Plusieurs pixels voisins avec la même classe sur une feuille sont par exemple vraisemblablement très similaires. L'agrégation des échantillons par régions homogènes permettrait entre autres de lisser les spectres en considérant la moyenne par région. Elle permet surtout d'améliorer l'échantillonnage lors d'une future tâche de classification et d'éviter d'avoir des jeux d'apprentissage et de test en réalité identiques. En effet, si on choisit aléatoirement des pixels pour l'apprentissage et le test sans considération spatiale, les deux jeux seront au final très proches l'un de l'autre. Cette considération peut se retrouver aussi sur les jeux de données standard de la littérature tels que *Pavia University* où l'échantillonnage pixel à pixel fournit de meilleurs résultats mais est moins représentatif de la réalité des éléments qui constituent chaque classe. En considérant un tirage sur des régions, on élimine en partie ce problème bien qu'il soit toujours en partie présent à l'échelle d'un pied ou d'une image. Les résultats doivent par conséquent être interprétés avec ces incertitudes en tête, aggravées par la taille relativement restreinte de l'échantillon.




Figure 7.6 – Exemples de présegmentations. Première ligne : images hyperspectrales dans l’espace RVB. Deuxième ligne : images segmentées en régions grâce à l’algorithme Quickshift. Paramètres : ratio spatial/couleur = 0.32, taille du noyau=3, distance maximale = 3.

Dans notre cas, la pré-segmentation est réalisée à l’aide de l’algorithme *Quickshift* sur la base des images RVB [194]. On pourrait considérer les images hyperspectrales dans le procédé de segmentation mais par gain de temps on utilisera seulement un sous-espace réduit pratique et facilement interprétable. Des exemples de résultats sont présentés dans la figure 7.6. Il est à noter qu’il existe des études sur la segmentation de cubes hyperspectraux, souvent en généralisant des algorithmes opérant sur des niveaux de gris [9]. Au lieu de considérer tous les pixels d’apprentissage, on considérera ainsi la moyenne des pixels annotés appartenant à chaque région.

7.6.5 Résumé des notations

Le tableau 7.2 présente un résumé des échantillons notés pour la base hyperspectrale. On y indique le nombre d’images annotées par classes, le nombre de segments contenant des pixels annotés et finalement le nombre de pixels annotés. On y retrouve un déséquilibre relatif entre les différentes entrées. Au total, on dénombre environ 5000 spectres par cépage après agrégation. On verra par la suite que les spectres appartenant à une classe sont en réalité d’une très grande diversité.

Tableau 7.2 – Description de la base de données hyperspectrale 2017. Nombre d'échantillons par classe

| | Libellé | Label | Cépage rouge | | | Cépage blanc | | |
|---------------------|----------------|--|--------------|---------|--------|--------------|---------|--------|
| | | | Images | Régions | Pixels | Images | Régions | Pixels |
| Organes de la vigne | Feuille saine | ● | 11 | 1489 | 8958 | 13 | 2022 | 16164 |
| | Grappe | ● | 9 | 242 | 2733 | 4 | 58 | 1408 |
| | Bois | ● | 6 | 131 | 3866 | 10 | 392 | 5676 |
| | Tige lignifiée | ● | 13 | 330 | 2226 | 14 | 1003 | 8078 |
| | Tige | ● | 14 | 331 | 2242 | 14 | 345 | 3247 |
| Décolorations esca | Dessèchements | ● | 8 | 192 | 1923 | 8 | 163 | 1828 |
| | Rougissemments | ● | 12 | 672 | 3102 | 9 | 358 | 2040 |
| | Jaunissements | ● | 8 | 109 | 735 | 9 | 327 | 2024 |
| Esca précoce | Asymp 1 | ● | 9 | 345 | 1798 | 8 | 400 | 2995 |
| | Asymp 2 | ● | 8 | 381 | 2663 | 5 | 250 | 1572 |
| | Asymp 3 | ● | 6 | 803 | 4979 | 11 | 1407 | 10016 |
| Total | | | - | 5025 | 35225 | - | 6725 | 38884 |

7.6.6 Premières observations sur les données

Une première observation des données peut être réalisée en visualisant des spectres répartis sur une feuille de vigne saine choisie au hasard. L'inclinaison de la feuille varie localement, par conséquent les spectres mesurés pour chaque pixel sont variables. La figure 7.7 présente une visualisation RVB de la feuille et des zones d'étude ainsi que les spectres de ces zones.




Figure 7.7 – a - Position de 14 zones d'étude au sein de la feuille superposés à la vue RVB de l'image hyperspectrale, b - Enveloppe des spectres bruts moyens à l'intérieur de chacune des zones

On devine dans les spectres de valeurs brutes la courbe de réflectance typique dans le visible ainsi que le saut du red-edge des végétaux. Les valeurs diminuent cependant rapidement dans le plateau du proche infra-rouge car le capteur devient progressivement moins sensible. Il atteint alors des valeurs quasi nulles après 1100nm environ. Une partie du spectre est donc plus difficilement exploitable, avant 500nm et après 1100nm.

On remarque aussi rapidement de grandes variations dans la population des spectres. En dehors d'un point aberrant présentant une décoloration foliaire, tous les spectres au sein de la feuille semblent approximativement similaires à une constante multiplicative près. Le phénomène est ici mieux visible après le saut du *red-edge*, les valeurs numériques brutes étant plus faibles dans le visible. Les échantillons à l'ombre présentent alors le plus mauvais rapport signal/bruit. Cette première expérience à petite échelle illustre le défi que représente le traitement des spectres en conditions réelles. Cette variabilité est logiquement encore plus prononcée à l'échelle d'un pied ou d'une parcelle.

7.7 REDONDANCE DE L'INFORMATION ET INFLUENCE DE LA RÉOLUTION SPECTRALE

Nous avons vu en introduction que la donnée hyperspectrale était connue pour être extrêmement corrélée. Ce constat peut se vérifier en considérant la corrélation au sens de Pearson entre les différentes longueurs d'ondes. Dans la figure 7.8, cette corrélation est calculée pour tous les couples de longueur d'onde (a) et par rapport au plus proche voisin (sur la dimension spectrale) pour différentes résolutions spectrales (b).




Figure 7.8 – (a) - Matrice de corrélation entre les bandes d'un jeu de données de pixels de feuilles saines. (b) - Effet du sous-échantillonnage spectral sur la corrélation moyenne aux plus proches voisins. La légende indique la résolution spectrale après sous-échantillonnage (en nm). Les bandes rouges indiquent la position du *red-edge*

Les deux plus grandes zones de corrélation sont situées respectivement avant et après le red-edge, atteignant parfois presque 100% de corrélation. L'autre enseignement est aussi que la dégradation de la résolution change très peu la corrélation entre bandes voisines. Un jeu de données sous-échantillonné à l'extrême avec une résolution spectrale d'environ 50nm présentera ainsi des corrélations proches du jeu d'origine. Il faut cependant bien garder à l'esprit que cette analyse considère les éléments du spectre pris

individuellement, elle ne prend pas en compte la composante de forme que l'on retrouve dans un spectre continu. La forme apporte un supplément d'information qui n'apparaît pas en considérant les corrélations entre paires.

7.8 LISSAGE SPECTRAL DES DONNÉES

Les données hyperspectrales sont le plus souvent bruitées et des prétraitements y sont typiquement appliqués afin de limiter cet effet, permettant ainsi de lui donner un aspect continu. L'étape de lissage doit pouvoir éliminer les pics dus aux bruits tout en conservant ceux liés au signal, problématique classique en traitement du signal.

Le filtre moyenneur est la méthode la plus intuitive permettant de lisser un signal 1D (e.g. un spectre) ou 2D (une image). Dans un signal bruité, la différence entre un point et ses voisins proches peut être élevée ce qui génère des transitions brutales. Au contraire un signal lissé aura un aspect continu, avec de très faibles variations entre points voisins. Le filtre moyenneur assigne ainsi à chaque point la valeur moyenne de tous les autres points dans un voisinage donné (par exemple 5 points de chaque côté soit une moyenne sur 11 points). C'est donc tout simplement une moyenne locale. La méthode a cependant des limites car elle ne prend pas en compte la forme locale du signal, elle risque donc d'altérer la nature du signal.

Pour remédier à ce défaut, la méthode de Savitzky-Golay calcule un polynôme sur les fenêtres locales [168]. Les résultats dépendent donc en grande partie de la taille de la fenêtre et du degré du polynôme utilisé comme montré dans la figure 7.9




Figure 7.9 – Effet du lissage par la méthode Savitzky-Golay sur un spectre brut selon les paramètres c (fenêtre de lissage) et k (degré polynomial). Pour plus de clarté, les spectres sont légèrement décalés en hauteur

Un plus haut degré polynomial permet ici de prendre en compte de manière plus fine les variations naturelles du signal. L'augmentation de la taille de la fenêtre permet quand à elle de réduire drastiquement le bruit mais des valeurs trop importantes peuvent altérer le signal original, même en considérant un polynôme de degré 4. L'algorithme doit donc être testé avant d'être appliqué afin de sélectionner les meilleurs réglages. On considèrera par la suite les paramètres $k = 3$ et $c = 5$.

7.9 PREMIÈRE CORRECTION RADIOMÉTRIQUE PAR LA RÉFÉRENCE

Une partie des sources de variabilité à l'échelle des images peut être corrigée grâce aux lectures de la référence à plusieurs niveaux de gris situées dans la partie basse de chaque image hyperspectrale. A l'intérieur d'une image, les valeurs de référence (visibles dans la figure 7.4) peuvent être lues pour chaque ligne individuellement. La correction par ligne est très utile dans le cas de conditions d'acquisition instables, notamment si le temps est nuageux. Dans ce cas, l'intensité lumineuse peut varier à l'échelle d'une acquisition. On retrouve dans la figure 7.10 l'évolution de la norme des spectres mesurées lors d'une expérimentation contenant 16 acquisitions. Les traits rouges délimitent la période chaque acquisition.



Figure 7.10 – Lectures de la norme des spectres bruts de la référence à 3 niveaux de gris sur une séance d'expérimentation (temps couvert et instable). Les niveaux de gris des 3 traits correspondent aux valeurs mesurées des 3 références utilisées. Pour la visualisation, l'axe temporel des abscisses est présenté non continu.

L'instabilité des mesures se remarque entre deux acquisitions consécutives mais aussi parfois au sein d'une acquisition (durant une vingtaine de secondes environ). Ces normes peuvent être utilisées pour recalibrer les spectres de référence entre eux. C'est ce que présente la figure 7.11 où les enveloppes de spectres pour les 3 niveaux de référence sont présentés avant et après correction par la norme (les normes sont calculées sur la référence radiométrique la plus claire car elle présente le meilleur rapport signal/bruit et est récupérable pour toutes les lignes).

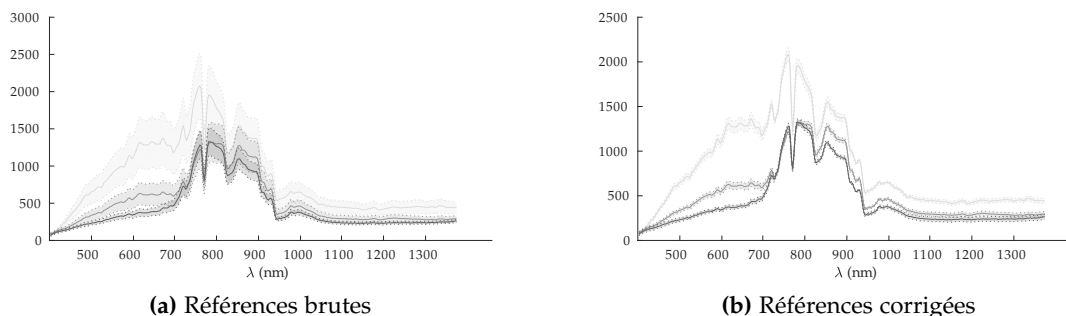


Figure 7.11 – Correction par la norme des spectres de référence pour les trois classes de référence (du gris clair au gris foncé). Le trait plein indique la moyenne tandis que l’enveloppe et les traits en pointillés indiquent l’écart type pour chaque longueur d’onde.

Comme attendu, les spectres de la référence radiométrique peuvent être vus comme un unique spectre à une constante multiplicative près (l’intensité incidente). On remarquera aussi que les niveaux de gris utilisés n’ont pas les mêmes propriétés spectrales dans la gamme de longueurs d’onde mesurée. Cela se voit particulièrement dans le *red-edge*. La correction calculée pour chaque ligne est ensuite appliquée aux spectres annotés des images. On obtient ainsi un premier niveau de correction basé sur les lectures de la référence permettant de remettre toutes les lignes d’acquisition au même niveau.

7.10 SECONDE CORRECTION DES SPECTRES

Comme nous l’avons vu précédemment, la variabilité restante après avoir corrigé par la référence radiométrique peut être principalement vue comme un mélange d’effets additifs et d’effets multiplicatifs.

7.10.1 Correction des effets additifs

Une façon non paramétrique simple de supprimer l’effet additif est de dériver le signal. Bien que d’apparence continue, un spectre n’est en réalité pas continu. Le mot "dérivée" désigne donc ici une approximation finie. On considère ainsi la différence entre deux valeurs successives divisée par le pas $\Delta\lambda$. Dans le cas de la première dérivée cela correspond à la pente entre mesures successives :

$$\left. \frac{dS}{d\lambda} \right|_i = \frac{S(\lambda_i) - S(\lambda_j)}{\lambda_i - \lambda_j} \quad (19)$$

où $\lambda_i > \lambda_j$ et i, j sont deux bandes voisines et S est le spectre brut. En répétant l’opération plusieurs fois on obtient alors les dérivées successives du spectre original.

En plus de supprimer une partie des interférences de fond, ces méthodes permettent plus de sensibilité pour des tâches demandant une résolution spectrale précise, par exemple pour distinguer des pics d’absorption quasi superposés. L’approximation de la

dérivée est le plus souvent précédée du lissage de l'information par la méthode Savitzky-Golay (SG) dont les paramètres ont été fixés au préalable. Le lissage est très utile pour effacer le bruit naturel du spectre mais pourrait altérer le signal, surtout s'il est appliqué à chaque dérivée. La figure 7.12 présente un signal initialement lissé par la méthode SG dérivé 3 fois.




Figure 7.12 – Dérivations successives d'un spectre feuille avec lissage initial par la méthode SG. Le point rouge indique la position d'inflexion du red-edge

Le signal est ici progressivement noyé dans le bruit, jusqu'à devenir inexploitable pour la troisième dérivée. Les bords deviennent également non exploitables dès la première dérivée (non lissés par la méthode SG). Il serait possible de lisser à chaque dérivée le signal obtenu mais cela risque de modifier encore plus les propriétés originales du spectre. Certains auteurs préconisent la première dérivée pour sa simplicité ([147]) tandis que d'autres conseillent la seconde permettant de repérer les points d'inflexion du signal [111].

Afin de repérer les longueurs d'ondes absorption, il est aussi possible d'utiliser un critère combinant des dérivées de plusieurs ordres. Le plus communément utilisé est le critère décrit dans Tsai *et al* [192]. Celui-ci considère que les longueurs d'onde d'absorption se trouvent pour des longueurs d'onde où la dérivée seconde est négative (point d'inflexion), la quatrième est positive et la cinquième nulle. Par la suite on considèrera seulement la dérivée première qui permet d'éliminer l'effet additif.

7.10.2 Correction des effets multiplicatifs

La correction des effets multiplicatifs consiste à trouver les valeurs permettant de caler les spectres entre eux. Les deux principaux algorithmes utilisés sont la méthode Multiplicative Scatter Correction (MSC) et la méthode Standard Normal Variate (SNV) [13]. Ces méthodes supposent que le facteur multiplicatif lié à la diffusion est constant et réalisent le plus souvent une correction de l'effet additif en même temps. La méthode MSC se compare à un spectre de référence tandis que la SNV utilise les propriétés du spectres pour le normaliser. Les spectres corrigés sont alors définis comme :

$$\text{MSC} : X_i = \frac{S_i - a_i}{b_i} \quad (20)$$

$$\text{SNV} : X_i = \frac{S_i - \mu_i}{\sigma_i} \quad (21)$$

où i est l'indice d'un spectre du jeu de données, μ_i sa moyenne, σ_i son écart type, a_i et b_i les paramètres obtenus par régression moindres carrés avec un spectre de référence. Dans le cas de la correction SNV on obtient en sortie un spectre dont la moyenne est nulle et l'écart type est égal à 1. D'autres techniques comme la PMSC généralisent la MSC en considérant que le facteur multiplicatif peut dépendre de la gamme de longueur d'onde considérée.

Un exemple de ces deux corrections est présenté dans la figure 7.13. En pratique, les résultats obtenus à l'aide de ces deux algorithmes sont très similaires.




Figure 7.13 – Corrections MSC et SNV sur les spectres de feuilles saines de la base après correction par la référence. La médiane est représentée par un trait rouge et les quantiles à 10% et 90% par un trait gris

La correction a tendance à globalement recaler les spectres dans le proche infra-rouge et à laisser une légère variabilité dans le visible. On considèrera par la suite la correction

SNV qui ne nécessite pas de spectre de référence pour fonctionner et permet d'obtenir des jeux de données centrés réduits. La dérivée ne sera pas retenue car elle est particulièrement sensible au bruit et aux choix de lissage.

Si on considère les spectres corrigés de plusieurs classes, on obtient ainsi des résultats relativement différents. La figure 7.14 présente une comparaison des spectres des classes d'intérêt aux spectres de la classe feuille saine après correction SNV. Pour clarifier la figure, le spectre moyen pour les feuilles saines a été soustrait aux spectres moyens des autres classes. On peut donc voir la figure comme une déviation de chaque classe au spectre de référence pour toutes les longueurs d'onde mesurées.

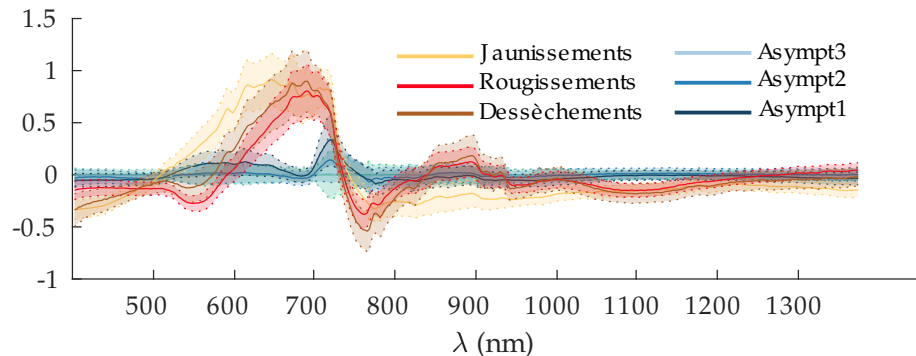


Figure 7.14 – Différences moyennes constatées entre les spectres de feuilles saines et les spectres de 6 classes de feuilles malades après correction SNV. Base cépage blanc.

Cette première visualisation permet de se rendre compte de l'existence de plusieurs gammes de longueurs d'onde importantes situées dans le visible, le *red-edge* (où la différence passe de positive à négative pour les symptômes visibles) et le proche infrarouge. On semble de même remarquer de légères déviations du signal dans le cas de la classe *Asympt1* voire plus légèrement *Asympt2* ce qui signifierait que les zones vertes sur pieds symptomatiques sont différentes. Cela se remarque principalement au niveau du visible et de façon plus accentuée au niveau du *red-edge* autour de 720nm.

7.11 CONCLUSIONS

Dans ce chapitre, nous avons détaillé la mise en place d'un protocole expérimental simple d'acquisition utilisant l'imagerie hyperspectrale. Les spectres de plusieurs classes liées aux symptômes visibles de l'esca et à une potentielle détection précoce peuvent être extraits pixel à pixel, en agrégeant ensuite les pixels appartenant à des régions homogènes (pré-segmentation Quickshift). L'utilisation d'une référence radiométrique simple permet de corriger les variations entre et à l'intérieur d'une image. Une importante variabilité reste cependant présente, les effets dus aux angles foliaires ne pouvant pas être corrigés. Les traitements permettant de répondre au problème de classification posé doivent donc prendre en compte cette variabilité.

Sommaire

| | | |
|-------|--|-----|
| 8.1 | Méthodologie d'évaluation des performances | 156 |
| 8.1.1 | Le cas binaire : Séparation vis à vis des feuilles saines | 156 |
| 8.1.2 | Le cas multiclassés : discrimination simultanée de plusieurs classes | 156 |
| 8.1.3 | Choix des indicateurs de comparaison | 156 |
| 8.2 | Performances avec le jeu de données entier | 157 |
| 8.3 | Performances avec bandes individuelles | 158 |
| 8.4 | Panorama des méthodes de réduction de la dimension | 160 |
| 8.5 | Transformation dans un nouvel espace | 161 |
| 8.5.1 | Indices de végétation | 161 |
| 8.5.2 | Projection du jeu entier dans un nouvel espace | 163 |
| 8.6 | Sélection de bandes | 165 |
| 8.6.1 | Qualités recherchées dans un algorithme de sélection | 165 |
| 8.6.2 | Choix aléatoire et sous-échantillonnage équilibré | 166 |
| 8.6.3 | Algorithme WaLuDi | 166 |
| 8.6.4 | Algorithme Random-Forest | 166 |
| 8.6.5 | Performances dans le cas binaire | 167 |
| 8.6.6 | Stabilité des algorithmes | 168 |
| 8.6.7 | Performances dans le cas multi-classes | 169 |
| 8.6.8 | Amélioration de la méthode de sélection par random forest | 171 |
| 8.6.9 | Longueurs d'onde retenues dans le cas binaire | 172 |
| 8.7 | Conclusions de la partie | 173 |
| 8.7.1 | Difficultés méthodologiques liées aux conditions réelles | 173 |
| 8.7.2 | Intérêt pour la discrimination d'organes et de symptômes visibles | 173 |
| 8.7.3 | Obstacles à la détection précoce | 174 |
| 8.7.4 | Perspectives d'améliorations | 174 |

Le présent chapitre s'attache au traitement de la donnée hyperspectrale afin de répondre aux problématiques soulevées dans le chapitre précédent. Les traitements repartent des données pré-traitées et corrigées par la référence radiométrique, qui sont ici considérées comme les descripteurs du problème. Ces spectres présentent cependant encore un degré de variabilité que l'on ne peut corriger avec ces méthodes.

On examine ici le potentiel de divers sous-ensembles et transformations de la donnée d'origine pour répondre à plusieurs questions de classification. Ces expérimentations nous mèneront notamment à sélectionner les longueurs d'onde d'intérêt associées à chaque classe et à déterminer si une détection précoce des symptômes de l'esca est envisageable à l'aide d'un imageur couvrant le visible et le Proche Infra-Rouge (PIR) jusqu'à 1300nm.

8.1 MÉTHODOLOGIE D'ÉVALUATION DES PERFORMANCES

Nous avons vu dans la partie précédente une méthodologie d'évaluation basée sur l'extraction de descripteurs associée à un classifieur standardisé en aval (Support Vector Machine (SVM)). Les performances étaient alors directement déduites de la bonne ou mauvaise classification des échantillons de test, en calculant une matrice de confusion et ses indicateurs associés (précision globale, précision par classe etc). On peut ici adopter deux points de vue selon l'objectif recherché. Le premier considère des problèmes de classification binaires tandis que le second considère des problèmes multi-classes.

8.1.1 *Le cas binaire : Séparation vis à vis des feuilles saines*

Le point de vue adopté ici est légèrement différent dans le sens où l'on souhaite examiner les propriétés de toutes les classes sans forcément les considérer en même temps. On souhaite principalement ici comparer chaque classe à la classe feuille saine et déterminer quelles transformations ou portions du spectre permettent de les différencier. Le classifieur s'impose de même beaucoup moins comme une évidence en raison du caractère exploratoire de l'étude. On souhaite surtout comprendre la nature de chaque population et évaluer la possibilité d'une détection précoce sur la base de données issues de la base hyperspectrale. Si on considère deux classes à comparer et un ensemble de descripteurs, il est possible de construire des courbes Receiver Operating Characteristic (ROC). La courbe ROC relie le taux de Vrai Positif (VP) au taux de Faux Positif (FP) dans une classification binaire, en faisant varier le seuil de discrimination entre les deux classes (voir Annexe ?? pour plus de détails théoriques). Cette courbe ROC peut ensuite être résumée numériquement en calculant l'Aire sous la courbe (AUC), quantification indirecte du potentiel de discrimination global entre deux classes (et portant une information très similaire à la performance d'un classifieur). Cette valeur permettra ainsi de déterminer le potentiel de discrimination de toutes les classes d'intérêt avec la classe de référence de façon standardisée.

8.1.2 *Le cas multiclassés : discrimination simultanée de plusieurs classes*

On se ramène ici à un cas similaire à la partie précédente sur l'imagerie visible. On s'intéressa à la classification de grandes familles qui sont ici les organes, les décolorations ou les deux en même temps. Le jeu de données sur la détection précoce ne sera pas abordé dans le cadre de la classification multi-classes car seules les différences à la classe feuille saine nous intéressent. On peut ainsi calculer des indicateurs de précision globale rendant compte de la bonne classification d'échantillons de test dans les différentes classes. On emploiera ici le même algorithme de classification (SVM) avec une méthodologie similaire à celle du [chapitre 5](#).

8.1.3 *Choix des indicateurs de comparaison*

Dans ces deux cas cependant, il est nécessaire de définir des métriques permettant de comparer deux échantillons en quantifiant leur similarité. Le choix de la métrique

est crucial car il dépend de la nature des données. Nous avons envisagé ici trois choix possibles d'indicateurs pouvant être appliqués à la donnée hyperspectrale.

- La distance euclidienne classique donnant plus d'importance aux variables avec la plus forte variance
- La distance de Mahalanobis permettant de décorrélérer les variables et proposer une nouvelle représentation des données
- Le Spectral Angle Mapper (SAM) mesurant l'angle entre les mesures, adapté aux spectres continus

La figure 8.1 présente un résumé sous forme de tableau des configurations possibles. Ici, le cas continu est particulier car il correspond à des données multidimensionnelles spécifiques (telles que les spectres issus du capteur hyperspectral).

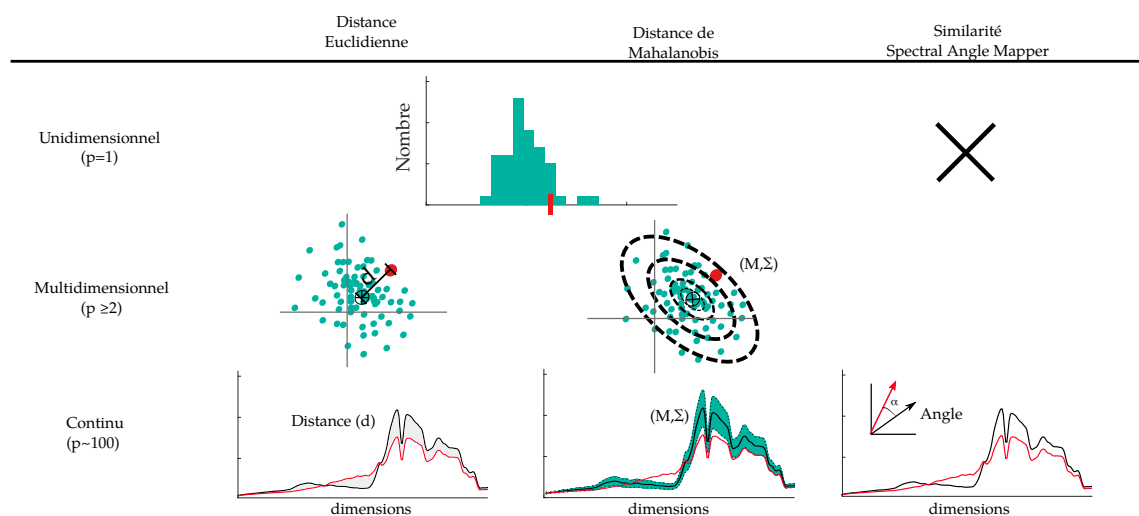


Figure 8.1 – Métriques mesurant la similarité d'un échantillon à la population d'une classe de référence. La population de référence est indiquée en vert et l'échantillon de test en rouge. Les formules des métriques sont présentées en détail en Annexe B

Quelques observations sont à apporter :

- La distance euclidienne est équivalente à la distance de Mahalanobis dans le cas unidimensionnel.
- La similarité SAM peut être appliquée dans n'importe quel cas multidimensionnel. Cependant elle n'a de sens que si les données sont "continues".

Quelle que soit la mesure de similarité utilisée, la moitié des échantillons de feuilles saines définis dans la notation terrain seront utilisés pour l'apprentissage. L'autre moitié sera comparée aux échantillons de la classe d'intérêt. Enfin, 100 répétitions seront utilisées afin de moyenniser les résultats et limiter les potentiels effets liés à la séparation apprentissage/test.

8.2 PERFORMANCES AVEC LE JEU DE DONNÉES ENTIER

Le premier jeu de données que l'on peut tester est le spectre entier de 368 bandes après prétraitements. Son utilisation n'est pas toujours recommandée en raison de sa haute

dimensionnalité et de l'extrême corrélation entre les variables. La distance euclidienne pourrait donc ne pas être adaptée et de mauvais résultats ont été obtenus avec la distance de Mahalanobis. On adoptera ici la métrique SAM pour comparer les spectres entre eux, mesurant un angle entre deux vecteurs ce qui est particulièrement adapté pour les spectres continus car ils portent une information de forme. La figure 8.2 présente les courbes Receiver Operating Characteristic (ROC) en considérant les spectres entiers.

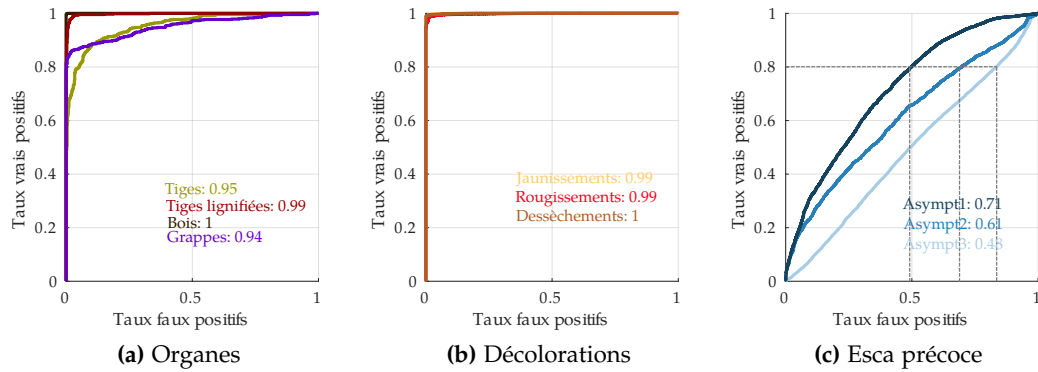


Figure 8.2 – Courbes ROC sur le jeu de données entier (cépage blanc) pour les 3 sous jeux de données (a)(b)(c) considérés en utilisant la métrique SAM. L'AUC est indiquée pour chaque courbe. Le taux de faux positifs pour 80% de vrais positifs est indiqué par les lignes en pointillés pour le troisième jeu de données.

Il est globalement assez facile de distinguer les classes pour les deux premiers jeux de données (décolorations et organes), certaines classes comme les tiges vertes étant un peu plus difficiles à discriminer du fait de leur similarité aux feuilles. Dans le cas des potentiels symptômes invisibles, de légères différences sont observées sur des pieds exprimant des symptômes (*asympt1* décrivant les zones vertes sur feuilles symptomatiques et *asympt2* décrivant les feuilles asymptomatiques sur un pied avec des symptômes), ce qui rejoint les observations précédentes sur les différences entre classes. Les performances sont cependant relativement mauvaises, un taux faible de faux positifs n'est pas accompagné par une bonne proportion de vrais positifs. Sur les pieds malades mais sans aucun symptôme visible (*asympt3*), les spectres n'ont pas l'air différents de ceux rencontrés sur les feuilles saines, un classifieur ne fait pas mieux qu'un tirage aléatoire.

8.3 PERFORMANCES AVEC BANDES INDIVIDUELLES

En opposition au spectre entier, il est possible de considérer individuellement les bandes. Cela veut donc dire qu'il faut tester toutes les possibilités pour évaluer l'entiereté du spectre. La similarité SAM ne peut pas être utilisée pour comparer ces données unidimensionnelles. On utilisera donc logiquement la distance euclidienne. La figure 8.3 présente l'Aire sous la courbe (AUC) obtenue pour la différenciation de la classe témoin avec chacune des autres classes, et ce, selon la longueur d'onde.




Figure 8.3 – Aire sous la courbe pour la discrimination des classes de la base de donnée à l’aide de longueurs d’onde individuelles. Résultats sur la base cépage blanc

Comme attendu, les performances sont inférieures à celles obtenues pour le spectre entier. Cependant le pouvoir discriminatif des bandes individuelles reste relativement intéressant. Tous les organes et décolorations peuvent être efficacement discriminés des feuilles saines avec une seule longueur d’onde. Ces longueurs ne sont cependant pas forcément les mêmes entre les classes. La surprise vient ici des performances pour les classes de détection précoce, les meilleures performances pour la classe *asympt1* dépassant celles pour le jeu entier, avec une AUC environ égale à 75%. On y retrouve des pics nets dans le visible, le red-edge ainsi que le proche infra-rouge. L’information dans le visible n’est pas si étonnante car les zones vertes près des symptômes présentent souvent à l’œil nu un vert légèrement plus "tendre" que sur des feuilles normales. Le pic observé entre 950 et 1000nm pourrait de même être lié au léger pic d’absorption de l’eau présent à cet endroit du spectre. D’autres pics d’absorption de l’eau plus prononcés existent mais ceux-ci sont présents plus loin dans le spectre, hors de la portée de notre capteur, dans le SWIR (aux alentours de 1450nm et 1950nm). L’amélioration avec le spectre entier pourrait être expliquée par la subtilité des différences entre les deux classes, que l’on retrouve mieux sur des longueurs spécifiques qu’en comparant la forme globale du spectre.

Les longueurs d’onde individuelles sont donc un candidat naturel pour la discrimination dans le cas binaire. On peut alors examiner leur apport dans le cas multi-classes et le comparer aux performances du jeu de données entier. Les résultats sont présentés dans la figure 8.4.

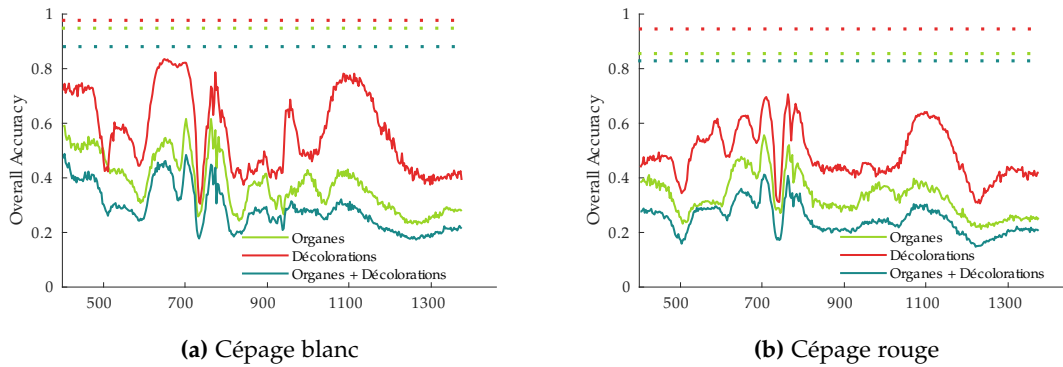


Figure 8.4 – Précision de test sur les 3 jeux de données multi-classes pour le spectre entier (pointillés) et les bandes individuelles selon la longueur d’onde.

Les conclusions mettent ici en avant les limitations naturelles de la donnée unidimensionnelle. L’écart entre bandes individuelles et le jeu entier varie ici de 15% dans le meilleur des cas à plus de 50% dans le pire. Cela corrobore le constat précédent sur les longueurs d’onde variées permettant de discriminer l’ensemble des classes mais cela montre aussi qu’une longueur d’onde informative pour plusieurs classes séparées ne l’est pas forcément lorsqu’elles sont considérées en même temps.

Sur la base de ces conclusions les enjeux par la suite seront multiples. On souhaite réduire l’écart entre les bandes individuelles et le spectre entier en trouvant un intermédiaire satisfaisant. Il est nécessaire pour cela de réduire la donnée de haute dimension en un ensemble plus interprétable et plus adapté aux métriques de type distance euclidienne. On souhaite aussi voir s’il est possible d’améliorer les performances, notamment pour les classes esca précoce. L’idéal serait un sous-espace permettant de bien discriminer les classes d’intérêt avec la plus faible dimensionnalité possible. La dimensionnalité seule peut être cependant trompeuse si on raisonne les applications possibles et leur coût associé. Par exemple un sous-ensemble unidimensionnel exploitant une combinaison de toutes les bandes de l’image hyperspectrale n’est pas forcément avantageux car il nécessite un capteur pouvant acquérir dans toutes ces longueurs d’onde. Au contraire un indice de végétation nécessite seulement l’acquisition dans deux ou trois longueurs d’onde ce qui peut faire l’objet d’un capteur spécifique meilleur marché contenant seulement ces bandes.

8.4 PANORAMA DES MÉTHODES DE RÉDUCTION DE LA DIMENSION

Les méthodes de réduction de la dimensionnalité définissent une transformation entre deux espaces. Plus formellement, on peut représenter un ensemble d’échantillons de spectres par la matrice $S = (s_{ij}) \in \mathbb{R}$ où i est le numéro d’échantillon et j le numéro de bande (longueur d’onde). I sera alors le nombre d’échantillons et J le nombre original de bandes ($J=368$ pour la donnée brute). La réduction consiste alors à trouver une transformation permettant de passer à une matrice $X = (x_{ik}) \in \mathbb{R}$ de taille $[I, K]$, avec $K < J$. Il

existe de nombreuses façons de passer de l'un à l'autre, cette opération peut être classée selon deux critères :

- La transformation des données ou la simple sélection de longueurs d'onde
- La définition au préalable de la transformation/sélection ou son apprentissage sur la base des données, l'apprentissage pouvant être supervisé ou non

Les méthodes non supervisées sont ici envisagées pour leur simplicité et leur application à tout type de jeu de données bien que les données collectées permettent d'utiliser des approches supervisées plus puissantes. La figure 8.5 présente sous forme d'arbre un panorama de ces techniques, les exemples fournis ne sont pas exhaustifs.

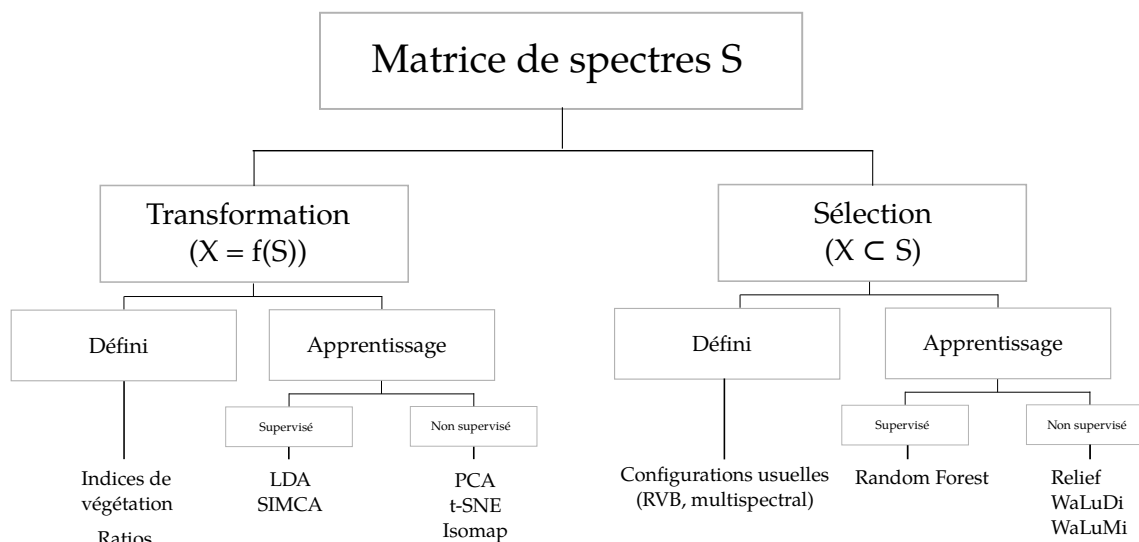


Figure 8.5 – Classification simple des méthodes de réduction de la dimensionnalité

Dans les sections suivantes on passera en revue ces techniques et leur utilisation possible dans le cas des jeux de données des Maladies du Bois de la Vigne (MBV).

8.5 TRANSFORMATION DANS UN NOUVEL ESPACE

Cette famille de méthodes considère une combinaison linéaire ou non linéaire de bandes déjà existantes. Bien que le produit final tienne compte d'une partie voire de la totalité de l'information du jeu de données, les attributs n'ont le plus souvent plus de signification physique simple.

8.5.1 Indices de végétation

Les indices de végétation sont des solutions *ad-hoc* pour résumer le statut d'un végétal à l'aide d'une combinaison de deux (ou plus) longueurs d'onde d'intérêt. L'indice le plus connu (NDVI) consiste à mesurer la pente entre une mesure dans le rouge et dans le Proche Infra-Rouge (PIR). La définition du NDVI reste assez approximative sur les longueurs d'onde à utiliser car l'indice a historiquement été développé pour des capteurs à bandes larges. Cependant d'autres indices de végétation contemporains plus adaptés

à la donnée hyperspectrale considèrent des longueurs d'onde précises dans leur formulation. Après avoir examiné de nombreux indices de végétation, nous avons retenu ici un ensemble de 10 indices de nature différentes afin de tester leurs performances sur nos jeux de données. Un résumé de ces indices de végétation et des longueurs d'ondes qu'elles utilisent est renseigné dans la figure 8.6.

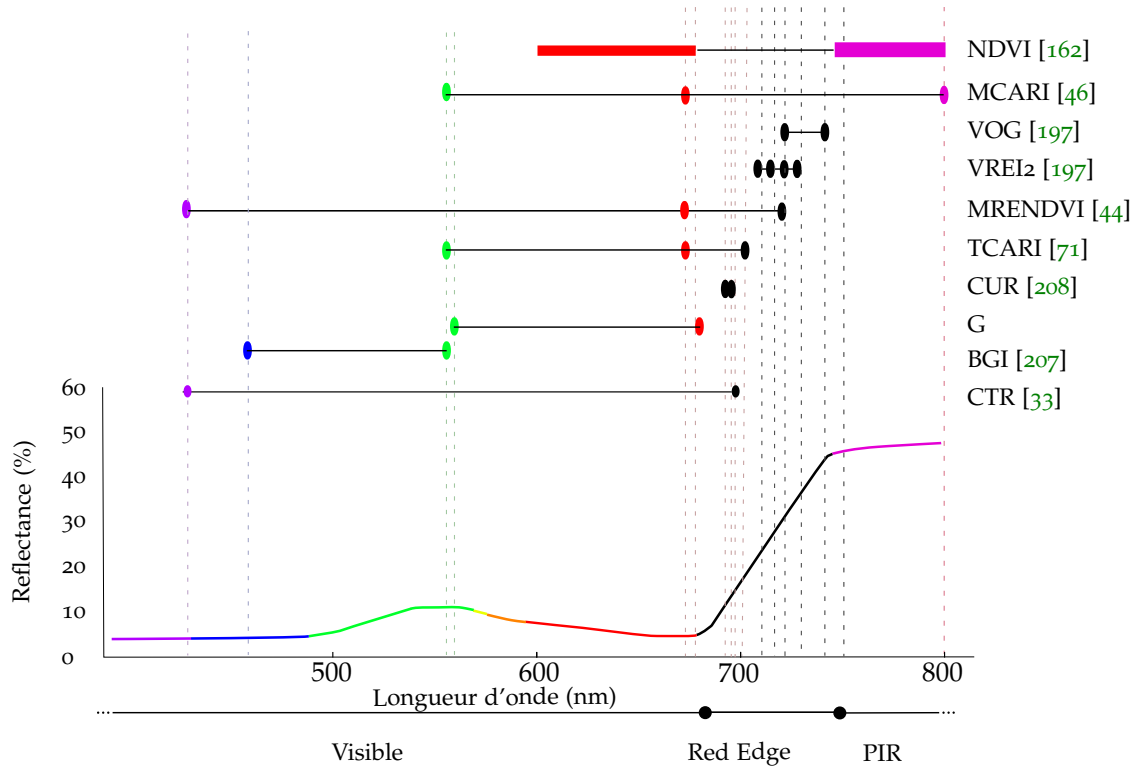


Figure 8.6 – Représentation synthétique des indices de végétation étudiés. Chaque ligne présente un indice de végétation et les longueurs d'onde utilisées reliées par un trait noir. Le détail des indices et de leur formule peut être consulté en Annexe D

Malgré quelques similarités, on remarque une grande variété de combinaisons, certaines utilisant parfois des mesures en dessous de 500nm. Le *red-edge* est utilisé pour de nombreux indices, certains indices comme le VOG ou le VREI utilisant exclusivement des valeurs sur la pente du *red-edge*. Une fois calculés, les indices unidimensionnels peuvent être simplement comparés à l'aide d'une distance euclidienne classique. La table 8.1 présente les aires sous la courbes obtenues pour la base cépage blanc à l'aide de ces indices.

Tableau 8.1 – Aire sous la courbe (AUC) obtenue pour les 10 indices de végétation étudiés sur le problème de séparation binaire entre feuille saines et d'autres classes. Prétraitement SNV et distance euclidienne. Les valeurs en gras correspondent aux meilleurs résultats par ligne.

| | NDVI | MCARI | VOG | VREI | MRENDVI | TCARI | CUR | G | BGI | CTR |
|----------------|-------------|-------------|-------------|------|-------------|-------------|------|-------------|-------------|-------------|
| Grappes | 0.98 | 0.94 | 0.91 | 0.86 | 1.00 | 0.98 | 0.94 | 1.00 | 0.51 | 1.00 |
| Bois | 0.93 | 0.56 | 0.88 | 0.85 | 0.97 | 0.83 | 0.82 | 0.69 | 0.53 | 0.91 |
| Tige lignifiée | 0.97 | 0.94 | 0.90 | 0.85 | 1.00 | 0.97 | 0.90 | 1.00 | 0.80 | 1.00 |
| Tige | 0.98 | 0.44 | 0.80 | 0.77 | 0.91 | 0.54 | 0.75 | 0.80 | 0.42 | 0.66 |
| Jaunissements | 1.00 | 0.96 | 0.93 | 0.90 | 1.00 | 0.97 | 0.97 | 0.99 | 1.00 | 1.0 |
| Rougissemments | 0.98 | 0.96 | 0.92 | 0.87 | 1.00 | 0.98 | 0.87 | 1.00 | 0.82 | 1.00 |
| Dessèchements | 0.99 | 0.97 | 0.93 | 0.89 | 1.00 | 0.99 | 0.86 | 1.00 | 0.59 | 1.00 |
| Asymp3 | 0.51 | 0.52 | 0.46 | 0.44 | 0.47 | 0.52 | 0.53 | 0.49 | 0.49 | 0.56 |
| Asymp2 | 0.51 | 0.61 | 0.58 | 0.57 | 0.54 | 0.60 | 0.58 | 0.53 | 0.48 | 0.54 |
| Asymp1 | 0.69 | 0.67 | 0.77 | 0.74 | 0.75 | 0.68 | 0.59 | 0.65 | 0.67 | 0.55 |

Toutes les classes liées aux organes ou aux décolorations sont relativement bien séparées à l'aide de ces indices. Parmi les meilleurs, on citera le NDVI, le MRENDVI et le CTR. Dans le cas des classes asymptomatiques, on retrouve une augmentation graduelle de l'aire sous la courbe avec les 3 classes. Celle-ci atteint respectivement pour les 3 classes un maximum de 0.56, 0.61 et 0.77. Dans ce cas, l'indice VOG considérant des mesures dans le reg-edge seulement se révèle l'un des plus efficaces. Ces résultats sont cependant comparables aux résultats obtenus à l'aide de longueurs d'onde individuelles.

8.5.2 Projection du jeu entier dans un nouvel espace

Les indices de végétation ont l'avantage et l'inconvénient d'être fixés par l'utilisateur. On peut avoir besoin de transformer la donnée en prenant en compte sa répartition, voire les classes associées aux échantillons. On veut de même pouvoir résumer l'information provenant de n'importe quel nombre de bandes, voire du spectre entier. Dans le cas d'une transformation linéaire, cela prendrait par exemple la forme d'une matrice de transfert de taille $[J, K]$ permettant de passer de l'espace de base à l'espace réduit. Certains algorithmes permettent de réaliser cette projection.

On présente ici les possibilités à des fins de visualisation pour deux algorithmes linéaires de réduction de la dimension vues au [chapitre 5](#), l'un étant non supervisé (Analyse en Composantes Principales (ACP)) et l'autre étant supervisé (Analyse Discriminante Linéaire (LDA)). Ceux-ci sont appliqués aux 3 types de jeux de données (cas multi-classes). L'utilisateur peut fixer le nombre de dimensions (axes factoriels) que l'on souhaite retenir dans le jeu de données final. La figure [8.7](#) présente ces exemples en deux dimensions permettant de visualiser facilement les classes et de voir si celles-ci forment des groupes séparés. La matrice de transfert est calculée à l'aide d'un jeu d'apprentissage représentant la moitié des données tandis que le jeu de test est utilisé pour représenter les résultats. Cette séparation est particulièrement importante dans le cas d'une approche supervisée.

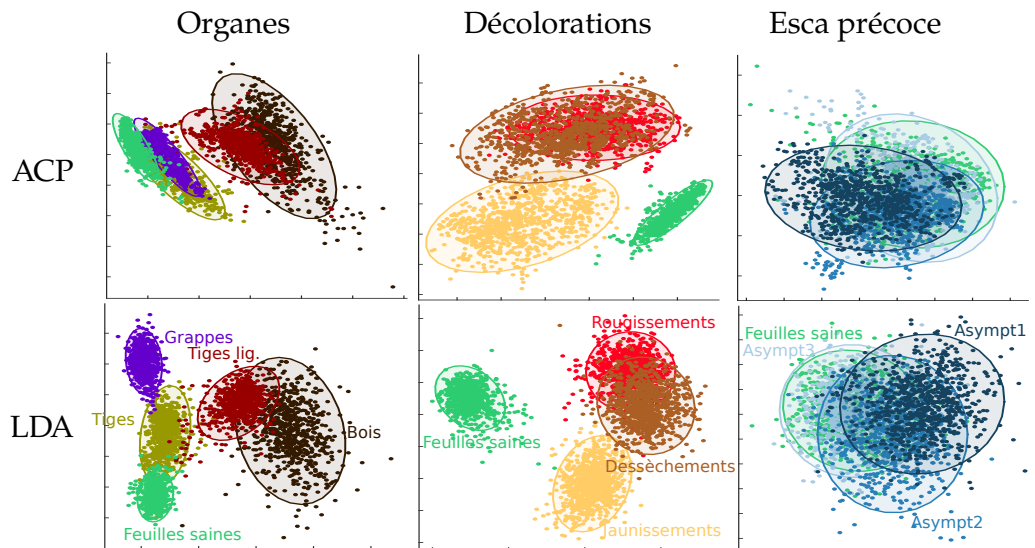


Figure 8.7 – Nuage de points des 3 jeux de données réduits sur les deux premiers axes factoriels.

Il est intéressant de décrire comment sont occupés les deux seuls axes utilisés pour résumer l'information du jeu entier. Des transitions entre classes peuvent être remarquées, comme le passage de tige à tige lignifiée puis à bois ou la transition entre feuille saine et respectivement les classes *asymp2* et *asymp1* (*asymp3* semble parfaitement confondu avec les feuilles saines). La différence entre réduction supervisée et non supervisée n'est pas spectaculaire ici, bien que la LDA fournisse logiquement une séparation plus nette.

La projection dans un nouvel espace pourrait aussi servir de base à des algorithmes de classification et de segmentation. La figure 8.8 présente un exemple de projection d'une image hyperspectrale dans un espace tri-dimensionnel déterminé par l'ACP. Cela permet notamment de représenter une partie de l'information hyperspectrale entière dans une image couleur.




Figure 8.8 – Utilisation de l'ACP pour la projection de l'image hyperspectrale dans un espace couleur à 3 dimensions.

8.6 SÉLECTION DE BANDES

Le principe de la sélection de bandes repose sur le constat qu'il existe un ensemble fini de combinaisons de K bandes parmi J qu'on ne peut pas toutes tester. Le but est donc de concevoir une méthode permettant de proposer un ensemble de bandes efficace pour un problème donné sans avoir à faire une recherche exhaustive. Le nombre de bandes retenues sera soit fixé par l'utilisateur soit fixé par l'algorithme selon un critère à définir. Ce domaine de recherche très riche a fait l'objet de nombreuses revues méthodologiques ou appliquées à l'agriculture [42]. Avant de définir les algorithmes testés dans notre étude, nous définirons d'abord les qualités attendues d'un tel algorithme.

8.6.1 Qualités recherchées dans un algorithme de sélection

On peut dégager deux principales qualités que l'on souhaite retrouver dans un algorithme de sélection de bandes :

- La **performance**, c'est à dire la meilleure précision de classification obtenue à l'aide d'un sous-ensemble généré par l'algorithme. La vitesse de convergence vers la précision maximale est aussi intéressante, on souhaite retenir un algorithme proposant de très bonnes performances pour un faible nombre de bandes.
- La **stabilité**, à savoir sa capacité à proposer des bandes similaires quel que soit le sous-ensemble d'échantillons considéré. La stabilité est particulièrement importante en conditions réelles où les spectres mesurés sont très divers, même après corrections. Un algorithme robuste à ces variations doit pouvoir récupérer l'information d'intérêt quel que soit le sous-ensemble.

La performance peut être simplement mesurée par des courbes représentant l'indicateur de test (Aire sous la courbe (AUC) ou précision de test) en fonction du nombre de bandes. La question de la stabilité est un peu plus complexe et a aussi fait l'objet de plusieurs études [7]. La stabilité sera ici mesurée de façon simple en considérant, pour une bande sélectionnée, la proximité ou non aux bandes sélectionnées dans les autres ensembles en considérant un paramètre de tolérance. La superposition ou non est calculée pour chaque bande de chaque sélection, l'ensemble étant alors moyenné pour fournir une mesure comprise entre 0 et 1, ce dernier correspondant à une superposition parfaite de tous les sous-ensembles (au seuil de tolérance près). Il est donc logique d'imaginer que la mesure de similarité aura tendance à augmenter avec le nombre de bandes sélectionnées, l'intérêt résidant ici dans la comparaison entre plusieurs algorithmes pour un nombre de bandes données. Le paramètre de tolérance sera ici fixé à 10nm de part et d'autre de chaque longueur d'onde sélectionnée, paramètre fixé arbitrairement après quelques tests préliminaires.

On retiendra pour les expérimentations un total de 4 méthodes :

- Choix aléatoire des longueurs d'onde
- Sous-échantillonnage régulier des longueurs d'onde
- Algorithme non supervisé WaLuDi
- Algorithme supervisé Random Forest

8.6.2 Choix aléatoire et sous-échantillonnage équilibré

L'algorithme de choix aléatoire réalise simplement un tirage aléatoire sans remise de J bandes parmi les K canaux d'origine. C'est donc par définition l'algorithme le moins stable de tous, particulièrement si le nombre de bandes retenues est faible. A l'opposé du choix aléatoire, le sous-échantillonnage équilibré considère des bandes équitablement réparties dans le jeu de données. C'est donc aussi l'algorithme le plus stable car il donnera toujours les mêmes sous-ensembles en sortie, quelque soit les échantillons considérés.

Ces deux méthodes ne considèrent cependant pas la répartition des données et/ou la classe de chaque échantillon et prennent leur décision "à l'aveugle". Les algorithmes qui suivent utilisent ces informations et leur résultat diffère donc avec la nature des échantillons.

8.6.3 Algorithme WaLuDi

WaLuDi [121] est une méthode non supervisée pour la sélection de bandes basée sur la théorie de l'information. L'enjeu principal pour la sélection de bandes est de repérer les corrélations entre bandes afin d'éliminer l'information redondante. L'utilisation de la divergence de Kullback-Leibler permet ici de comparer plusieurs distributions de probabilités entre elles. Soient p_l et p_k les histogrammes en fréquence associés à deux bandes l et k pour l'ensemble des échantillons, la version symétrique de la divergence est définie comme :

$$D(p_l, p_k) = \sum_i p_{l_i} \log\left(\frac{p_{l_i}}{p_{k_i}}\right) + \sum_i p_{k_i} \log\left(\frac{p_{k_i}}{p_{l_i}}\right) \quad (22)$$

Cette matrice de similarités peut ensuite être traitée en utilisant une classification ascendante hiérarchique avec la stratégie d'agrégation de Ward. L'ensemble des bandes est ainsi séparé en J groupes et la bande la plus proche du centroïde est retenue à l'intérieur de chaque groupe pour obtenir le sous-ensemble final. D'autres algorithmes peuvent être utilisés dans la même famille en remplaçant la divergence de Kullback-Leibler (KL) par une autre métrique, comme par exemple l'information mutuelle (WaLuMi). Ce type de méthode simple basée sur une matrice de similarité peut être facilement mobilisée.

8.6.4 Algorithme Random-Forest

L'algorithme *Random-Forest* est principalement connu pour son utilisation sur des tâches de classification supervisées et son adaptation à des problèmes où les variables sont très corrélées [26]. Il consiste simplement en un ensemble d'arbres de décision, où chaque nœud se réfère à une condition sur une variable. Un sous-ensemble des variables et des individus est sélectionné à chaque arbre. Les *Random-Forest* peuvent cependant être utilisés pour quantifier l'importance des variables de la donnée classifiée. L'importance des variables peut être mesurée en s'appuyant sur le coefficient de Gini, plus particu-

lièrement sa diminution moyenne lorsqu'un noeud emploie une variable. Le coefficient d'impureté de Gini est défini comme :

$$G = \sum_{i=1}^{n_c} p_i(1 - p_i) \quad (23)$$

où n_c est le nombre de classes et p_i la proportion d'échantillons de la classe i . L'importance sera alors calculée pour chaque noeud de chaque arbre, possédant un parent et deux enfants :

$$I = G_{\text{parent}} - G_{\text{enfant1}} - G_{\text{enfant2}} \quad (24)$$

Plus la somme des coefficients des deux enfants s'éloigne du coefficient du parent, plus le noeud et donc la variable liée est importante pour la discrimination des classes. L'importance globale sera enfin obtenue en considérant la moyenne pour chaque variable. On peut alors sélectionner le sous-ensemble final en classant les bandes par importances décroissantes. Cette famille de méthode où chaque bande est classée (*ranking*) est souvent opposée aux méthodes agrégeant les bandes (*clustering*) comme WaLuDi. Les méthodes de type *ranking* ont le désavantage de proposer des bandes redondantes en sortie, problème évité en groupant les bandes. Les approches *clustering* ont cependant le problème inverse : des bandes informatives pourraient être omises à l'intérieur des groupes. Certaines études tentent par conséquent d'allier les deux approches pour le traitement de la donnée hyperspectrale [45].

8.6.5 Performances dans le cas binaire

Les performances dans le cas binaire pour les 10 classes d'étude sont présentées dans la figure 8.9. On constate que la qualité de la représentation augmente logiquement avec le nombre de bandes bien qu'il existe des exceptions. La répartition à intervalles égaux des bandes donne de même des résultats corrects, voire meilleurs que pour la méthode WaLuDi. L'algorithme *Random-Forest* propose les meilleurs résultats ici en tirant partie de la connaissance des classes. Enfin, les performances obtenues en considérant des sous-ensembles aléatoires sont en moyenne relativement correctes pour un nombre de bandes suffisant, bien que logiquement extrêmement instables.

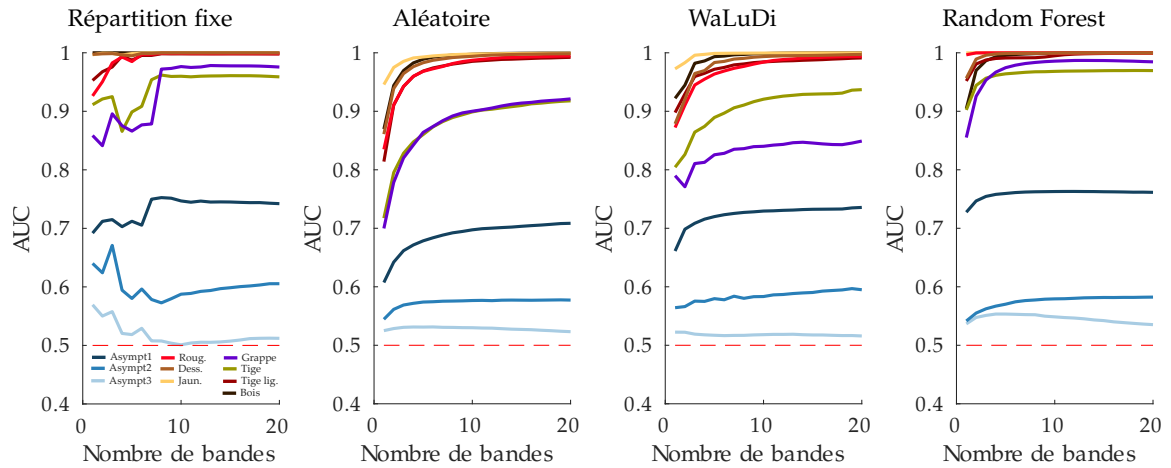


Figure 8.9 – Aire sous la courbe (AUC) moyenne en fonction du nombre de bandes sélectionnées (100 répétitions)

8.6.6 Stabilité des algorithmes

L'indice de similarité décrit précédemment peut être représenté en fonction du nombre de bandes extraites pour comparer la stabilité des algorithmes (figure 8.10). Les courbes pour la répartition fixe et la répartition aléatoire servent ici de référence car elles représentent les deux cas extrêmes, la courbe aléatoire étant représentée en pointillés pour les 2 autres algorithmes. Les résultats sont difficiles à analyser mais on remarque un effet classe pour l'algorithme *Random-Forest* moins prononcé pour *WaLuDi*, on peut supposer que cela est dû au caractère supervisé ou non supervisé. Il est intéressant de constater que les classes les plus difficiles sont ici les moins stables. Ce résultat est attendu car il n'existe pas de longueurs d'ondes qui s'imposent nettement lorsque l'on considère ces classes.

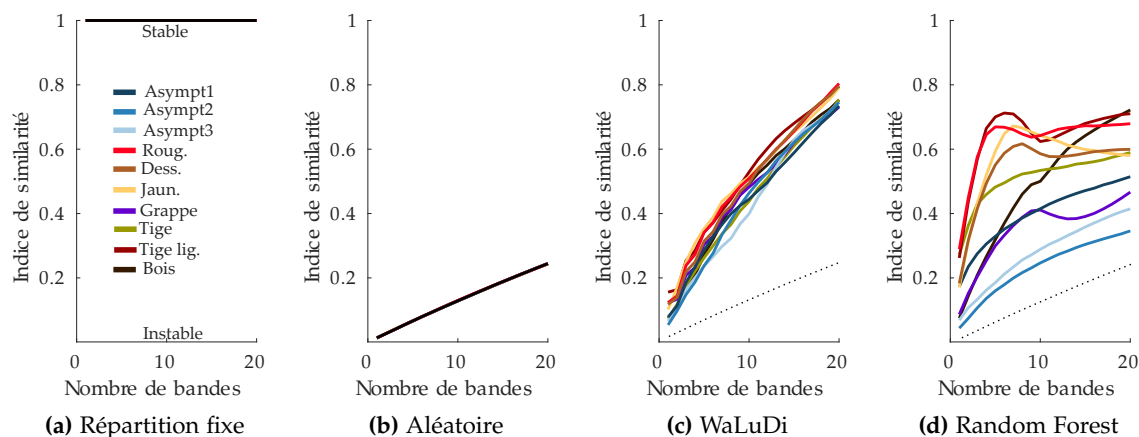


Figure 8.10 – Indice de similarité en fonction du nombre de bandes sur un ensemble de 500 simulations et 4 types d’algorithmes. A chaque simulation, 50 échantillons de chaque classe sont utilisés aléatoirement

8.6.7 Performances dans le cas multi-classes

On peut de même adapter ces algorithmes au cas multi-classes. Les résultats sont conduits dans la figure 8.11. Les différences entre algorithmes sont ici assez subtiles. La principale différence entre WaLuDi et le *Random-Forest* est la vitesse de convergence, bien que les performances maximales soient légèrement meilleures pour ce dernier.




Figure 8.11 – Précision de test en fonction du nombre de bandes sélectionnées pour les jeux de données "organes de la vigne" et "décolorations liées à l’esca" ainsi qu’une combinaison des deux

Afin d’avoir un meilleur regard d’ensemble, la figure 8.12 présente un résumé des performances dans le cas multi-classes. Elle inclut d’abord les performances avec la donnée brute de 368 bandes et celle où la résolution spectrale a été réduite d’un facteur 4. Elle

présente aussi deux sous-ensembles usuels sous la forme de la donnée RVB et multispectrale. Inspirée des capteurs multispectraux du commerce, le sous-ensemble multispectral contient des bandes à 480, 550, 670, 690, 710, 770, 900 et 1000nm, soit un total de 8 bandes. Les algorithmes de sélection WaLuDi et *Random-Forest* seront de même comparés sur la base d'un ensemble de 8 bandes. En plus des performances pour les 2 algorithmes de sélection comparés, on indiquera aussi celles obtenues pour 3 indices de végétation sélectionnés (NDVI, VOG et MRENDVI).

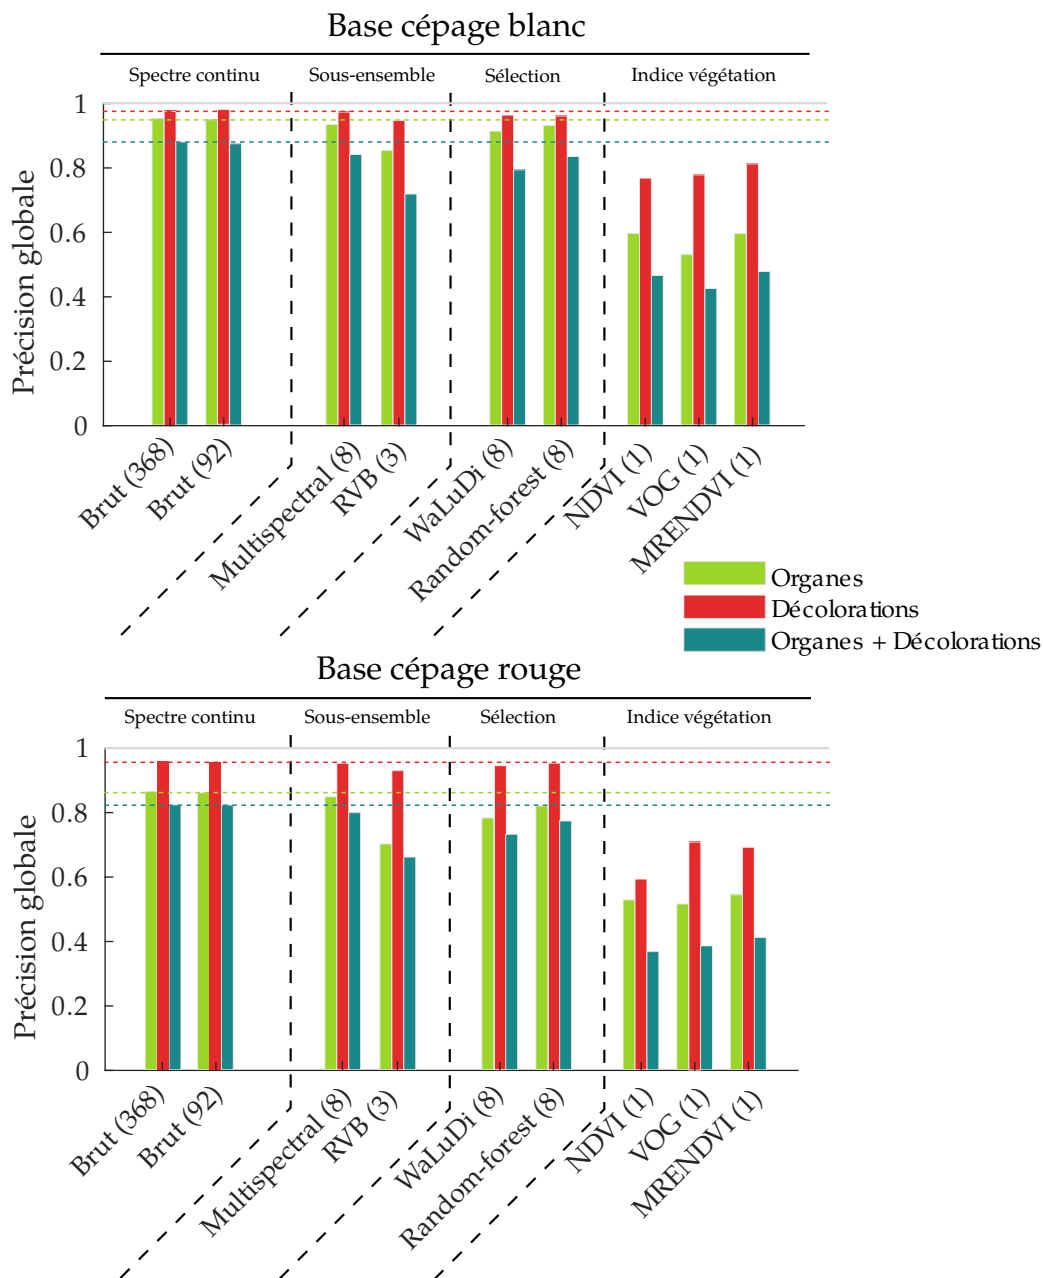


Figure 8.12 – Précision de test pour la classification des jeux de données "organes de la vignes" et "décolorations liées à l'esca" ainsi qu'une combinaison des deux. La dimensionnalité de chaque type de jeu de données (abscisse) est indiquée entre parenthèses

On remarque ainsi que pour 8 bandes, la configuration multispectrale fixée manuellement bat en moyenne les algorithmes de sélection si l'objectif n'est pas juste de différencier les décolorations. La différence entre RVB et multispectral est importante, notamment pour les organes de la vigne. La configuration multispectrale est de même compétitive avec la donnée brute, celle-ci inclut donc la majorité de l'information nécessaire. Les indices de végétation montrent quand à eux sans surprise des performances médiocres, même comparé à un simple ensemble RVB.

8.6.8 Amélioration de la méthode de sélection par random forest

Afin de proposer une liste de longueurs d'ondes retenues pour chaque classe, on sélectionne la méthode *Random-Forest*. On a vu que cette méthode permettait d'obtenir pour chaque attribut une estimation de l'importance. La méthode présente cependant deux défauts. Premièrement, l'estimation de l'importance est variable et dépend des échantillons d'apprentissage considérés, les résultats ne sont ainsi pas stables. Deuxièmement, les bandes sont sélectionnées en considérant les valeurs d'importance dans l'ordre décroissant, certaines bandes redondantes pourraient donc être sélectionnées. Pour pallier à ce problème, on considère l'accumulation des courbes d'importance calculées sur de très petits sous-ensembles de données (50 échantillons par classe seulement). En sommant ces valeurs discrètes sur de nombreuses répétitions, on obtient alors une courbe d'importance finale d'apparence continue présentant des pics pour certaines longueurs d'ondes.

On fera l'hypothèse que la présence d'un pic signifie d'une part que toutes les longueurs d'onde autour de ce pic portent la même information et d'autre part que la longueur d'onde la plus appropriée pour décrire cette information est celle du pic en lui-même. Afin de déterminer les longueurs d'onde les plus discriminantes, on utilisera l'algorithme de détection de pics sur un signal *scale-space* [112]. Cet algorithme utilise différents niveaux de lissages afin de déterminer les maxima locaux persistants. La figure 8.13 présente deux exemples de courbes d'importance agrégées et de détection de 8 pics dans le spectre, c'est à dire 8 bandes retenues. Selon la difficulté du problème de classification, ces pics peuvent apparaître plus ou moins clairement.




Figure 8.13 – Exemples d'importances cumulées sur 2000 répétitions avec 50 échantillons d'apprentissage par classe. L'exemple de gauche (a) présente une tâche simple où les bandes importantes apparaissent nettement sous forme de pics. L'exemple de droite (b) présente une tâche difficile (AUC faible) où peu de longueurs d'ondes se distinguent réellement.

Il est à noter ici que même en présence de pics d'importance marqués, le nombre de zones intéressantes reste relativement faible, comme illustré dans la figure (a). Cela signifie qu'il est sûrement inutile d'utiliser un trop grand nombre de bandes.

8.6.9 Longueurs d'onde retenues dans le cas binaire

Sur la base des expérimentations utilisant l'algorithme des *Random-Forest*, la figure 8.14 présente les ensembles de 8 bandes sélectionnées pour la différenciation des 10 classes d'intérêt le long du spectre (entre 500nm et 1150nm).

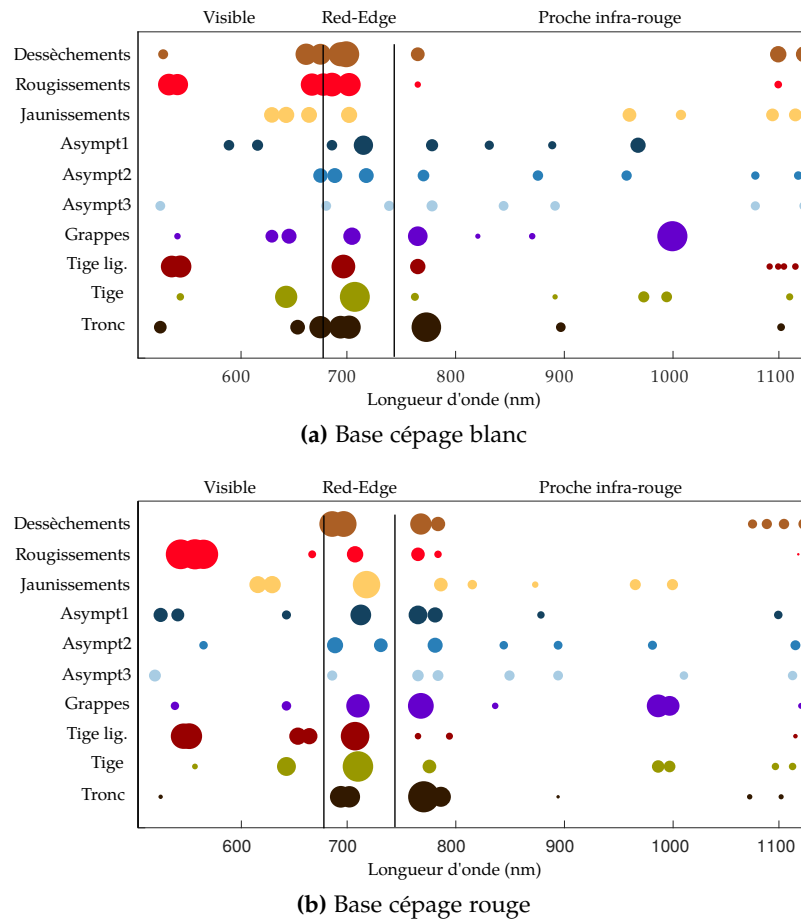


Figure 8.14 – Sélection de 8 bandes pour chaque classe avec la méthode Random Forest. Le rayon des cercles est ici proportionnel à l'importance cumulée avec 100 répétitions

Représenter la taille des cercles en fonction de l'importance cumulée permet de mieux mettre en relief les différences entre classes, avec des importances très faibles dans le cas de la détection précoce. On remarque que pour beaucoup de classes les bandes les plus discriminantes sont situées dans le visible, le *red-edge* et le début du plateau du proche infra-rouge, à l'exception des grappes de raisin pour lesquelles la zone autour de 1000nm semble importante. Cela confirme premièrement qu'un capteur adapté à la vigne pourrait contenir seulement le visible et le *red-edge* et deuxièmement que le proche infra-

rouge ne semble pas apporter de longueurs d'ondes marquées permettant de détecter précocement les symptômes.

8.7 CONCLUSIONS DE LA PARTIE

Dans cette partie nous avons mis en place un dispositif en proxidétection permettant d'obtenir des images hyperspectrales et une chaîne de traitement liée. On fait ici un tour d'horizon des enseignements tirés lors de ces expérimentations.

8.7.1 Difficultés méthodologiques liées aux conditions réelles

Le premier enseignement concerne les difficultés rencontrées pour le maniement de capteurs hyperspectraux en conditions réelles, conditions indispensables pour les applications au champ. On a ici fait le choix de corrections simples qui laissent cependant une part non négligeable de variabilité dans la donnée hyperspectrale. On notera ainsi la difficulté à allier méthodologie et applications pratiques rencontrée par de nombreux auteurs, barrière moins présente avec des capteurs plus limités mais plus simples tels que les caméras multispectrales et RVB simples.

8.7.2 Intérêt pour la discrimination d'organes et de symptômes visibles

Cet objectif était secondaire pour l'étude mais la constitution d'une base de données variée a permis de se pencher sur ces classes visibles à l'œil nu. L'apport de l'hyperspectral est ici cependant relatif, bien que l'information du *red-edge* permette de discriminer plus efficacement des éléments de couleurs similaires (tiges vertes). On a cependant vu que la donnée pouvait être résumée par des sous-ensembles très simples de taille inférieure, que ce soit des indices de végétation ou des configurations RVB/multispectral. Le choix de la réduction de dimensions dépend de la nature des classes et de leur nombre. Les données unidimensionnelles (bandes individuelles, indices de végétation) sont ainsi très adaptées pour les classifications binaires mais ne fournissent pas de bonnes performances lorsqu'il faut discriminer de nombreuses classes. L'absence d'information spatiale, ou du moins son exploitation difficile, empêche d'envisager des applications utilisant un capteur hyperspectral. Une question à laquelle cette étude ne permet pas de répondre est la possibilité de discriminer plusieurs maladies entre elles à l'aide de l'hyperspectral. Cette possibilité fait partie des perspectives, mais l'échantillonnage d'autres maladies est contraignant. Certains auteurs apportent déjà une réponse en comparant notamment la flavescence dorée et l'esca [6]. Cette étude montre ainsi que la variabilité rencontrée pour chaque maladie (entre les années, les cépages et les plantes) est très importante et rend quasi impossible une séparation efficace des deux maladies par la seule utilisation de données spectrales. Un rougissement foliaire reste ainsi globalement un rougissement, quelque soit son origine. L'information spectrale n'étant pas suffisante, l'information spatiale peut être utilisée comme nous l'avons montré dans la partie II.

8.7.3 *Obstacles à la détection précoce*

Le problème de la détection précoce est quant à lui plus intéressant mais en réalité difficile à poser. La principale limitation est ici la supposition de l'existence de tels symptômes (différences potentielles de réflectance dans le Proche Infra-Rouge (PIR)), problème aggravé par la limitation de l'échantillonnage sur une parcelle. Cette étude a ainsi supposé l'existence de symptômes non visibles, en les séparant en 3 classes selon l'état du pied et la position de l'échantillon. Le but a ensuite été de chercher un sous-ensemble permettant de les séparer des feuilles saines et de déterminer les longueurs d'onde d'intérêt permettant d'y parvenir. Les résultats sont mitigés et ne montrent des différences que sur les pieds exprimant déjà des symptômes sur certaines feuilles (limitant donc l'intérêt de l'imagerie hyperspectrale). Aucune différence significative n'est constatée sur les pieds malades n'exprimant pas de symptômes l'année en cours, ce qui rend impossible la détection précoce à l'aide de ce capteur. Les résultats sont bien sûr à interpréter en prenant en compte tout le lot d'incertitudes autour de ces mesures. Il est possible d'imaginer que de très légères différences existent mais que la différence n'est plus distinguable à cause des autres sources de variabilité (angle des feuilles, ombre du couvert) influant avec plus d'amplitude sur le signal. Les tests réalisés au spectroradiomètre n'ont cependant pas montré de différence notable non plus.

Le problème de la date d'acquisition se pose potentiellement aussi. On peut imaginer que si un signal était détectable 10 jours avant apparition des symptômes (exemple fictif inspiré des résultats sur d'autres maladies), il serait nécessaire de mesurer ce signal au bon moment durant l'été, la date d'apparition des symptômes étant inconnue. Cela imposerait donc une revisite régulière afin de ne pas "rater" le bon moment. Dans le cas où le signal précoce serait mesurable à tout moment durant l'été, le problème ne se poserait pas. En l'état il est cependant plus sage de considérer la non existence de ce signal. La détection quelques jours ou semaines à l'avance serait de même, en terme de protection du vignoble, beaucoup moins utile qu'une détection de la maladie une ou deux années avant l'apparition des premiers symptômes.

8.7.4 *Perspectives d'améliorations*

Ces conclusions pessimistes sont cependant à pondérer par les marges d'amélioration possibles et par l'intérêt de la recherche sur l'hyperspectral. La principale piste est l'utilisation d'un autre capteur hyperspectral. Le capteur actuel couvre le domaine du visible, du red-edge et une petite portion du proche infra-rouge jusqu'à 1300nm (en réalité jusqu'à 1100nm si on omet les bandes au rapport signal/bruit très faible). La littérature générale mentionne cependant que des zones très intéressantes se trouvent au delà, notamment les bandes d'absorption de l'eau, visible par de grands creux de réflectance. Lier la détection précoce à l'état hydrique de la feuille reviendrait à supposer la présence d'un stress avant apparition des symptômes, ce qui est une hypothèse plausible mais difficile à vérifier. Par ailleurs, ce stress pourrait ne pas être du aux Maladies du Bois de la Vigne (MBV).

Les autres pistes consistent à renforcer le dispositif hyperspectral et à adopter des méthodes plus poussées de récupération de la réflectance afin de corriger toutes les surfaces foliaire en réflectance véritable. Cela n'assurerait pas forcément de meilleurs résultats cependant. La solution la plus radicale pourrait être alors simplement de revenir à une approche *bottom-up* classique et de manier des spectres en conditions contrôlées. Cela prendrait soit la forme de mesures en laboratoire soit de mesures ou spectroradiomètre de terrain. Enfin les autres pistes poursuivies entre autres par l'INRA sur le flux de sève et la réserve utile de la plante pourraient ouvrir la voie à un autre type de détection précoce [137].

Quatrième partie

CONCLUSIONS ET PERSPECTIVES

CONCLUSIONS ET PERSPECTIVES

Cette thèse dédiée à l'étude et la détection des maladies du bois de la vigne (esca, Black Dead Arm) est liée au projet ADVANTAGE dont les objectifs sont la conception de moyens préventifs contre les maladies du bois de la vigne. L'utilisation de capteurs imageurs et d'algorithmes de traitement d'image a permis d'aboutir à plusieurs contributions distinctes. Les résultats de la thèse consistent ainsi principalement en ces applications, réparties entre un volet imagerie visible et un volet imagerie hyperspectrale, les deux en proxidtection le long des rangs de vigne.

9.1 CONCLUSIONS SUR LES RÉSULTATS

9.1.1 Imagerie RVB pour la détection des symptômes visibles

Les résultats les plus intéressants concernent l'imagerie visible, pouvant ici être utilisée pour la détection et donc pour la cartographie des symptômes des maladies du bois de la vigne. Une base de données d'images RVB de ceps de vigne a ainsi été constituée. Une particularité de ce travail vient ici de l'inclusion d'un ensemble de facteurs confondants comme classe séparée dans le problème de classification, le but étant de distinguer les symptômes d'esca des autres symptômes. Une comparaison entre deux méthodes récentes d'extraction de descripteurs, à savoir l'encodage de descripteur SIFT et les réseaux de neurones convolutifs, est alors réalisée dans le cadre de cette application. Ces expériences montrent la puissance et la flexibilité des approches de *transfer learning* utilisant un réseau convolutif déjà appris. Des résultats intéressants sont ainsi obtenus pour la classification de feuilles, ils montrent qu'une partie de ces échantillons d'esca peut être efficacement séparée malgré la variabilité de l'esca et l'existence de symptômes similaires comme les carences.

Ainsi l'esca est caractérisé par une très grande variabilité de symptômes, la gamme de symptômes observés dépend donc de nombreux paramètres. Ici, l'étude s'est concentrée sur deux cépages mesurés sur un été mais la variabilité réelle est sans doute bien plus importante. On citera notamment dans les sources de variabilité le cépage, le climat de l'année, le moment de l'été ou l'âge du pied. Bien que la forme particulière de l'esca soit une constante, il existe de nombreuses variations et surtout beaucoup de symptômes peu prononcés qu'il est difficile de caractériser sans contexte. Ici, la création de 3 sous-classes de sévérité a permis de quantifier les performances pour chaque type de symptôme. La présence de symptômes similaires dans d'autres maladies et troubles de la vigne est la seconde source d'erreur. Étant donné que de nombreux symptômes font l'objet de décolorations similaires mais aussi très variables, il est quasi impossible de les distinguer sur la seule base de la couleur ou du spectre. Ces similarités obligent donc à prendre en compte une information spatiale (points, grandes taches, décoloration des bords, décoloration internervaire avec ou sans gradients, décoloration intégrale ou même enroulement

de la feuille) en plus de l'information spectrale, comme ce fut le cas dans cette thèse.

Dans cette étude, l'adoption de descripteurs *off-the-shelf* extraits depuis un réseau pré-entraîné sur la base généraliste ImageNet marque un éloignement aux approches *ad-hoc* classiques (pour lesquelles la méthodologie est étroitement liée à l'application). Cette thèse a illustré que ce type d'approche spécifique à un problème tendait à s'effacer au profit d'algorithmes plus flexibles et généralisables que l'on peut appliquer à de nombreuses situations, souvent par le biais du *deep-learning*. Cette approche permet cependant de ne généraliser que la partie *machine learning*. Les autres parties dépendent toujours du terrain et de ses contraintes. De même, les approches *ad-hoc* spécifiques à un problème restent viables dans certaines circonstances.

Ce travail a ainsi permis d'évaluer la pertinence des descripteurs extraits sur des images de feuilles symptomatiques. Cette base servant à la classification a alors été étendue au problème de détection sur image de pied entier à l'aide d'un réseau de détection (RetinaNet). Il est à noter que la détection des symptômes visibles dépend de ce que le capteur peut "voir". Or, la réalité de la conduite viticole fait que l'on ne peut pas voir tout le feuillage avec un capteur visible, même si l'on acquiert des images des deux cotés du rang. Ce que l'on peut observer est limité par des phénomènes d'occultation. Cette limitation peut être négligeable si le diagnostic à réaliser ne doit pas être quantitatif et précis (problème rencontré pour le comptage du volume de bois de taille ou l'estimation du rendement par comptage des baies), ce qui est le cas pour la détection des symptômes de l'esca. On peut donc proposer une solution reposant sur des observations partielles tout en apportant une information essentielle sur l'état du vignoble. Sur les parcelles de l'étude, il est ainsi possible d'obtenir une estimation qualitative de l'atteinte par l'esca des pieds de vigne.

9.1.2 Imagerie hyperspectrale pour l'étude des symptômes visibles et précoces

L'objectif de l'imagerie hyperspectrale était double, à savoir d'isoler les longueurs d'onde liées aux symptômes des maladies du bois et de vérifier la faisabilité d'une détection précoce des pieds malades avant apparition des symptômes. Une autre base de données a été constituée dans ce but, contenant des échantillons de spectres répartis dans une centaine d'images hyperspectrales. La base a été séparée en de nombreuses classes d'intérêt (contenant des organes de la vigne, des symptômes visibles de l'esca et des symptômes précoces) comparées à la classe feuille saine de référence. La méthodologie consiste ici surtout en la correction des spectres, suivie d'une réduction de la dimensionnalité des données. La tentative de détection précoce à l'aide de l'hyperspectral terrestre n'a cependant pas donné de résultats concrets. De légères différences à certaines longueurs d'onde sont constatées pour les zones asymptotiques de pieds présentant des symptômes mais aucune différence de signal n'est constatée pour les pieds malades sans aucun symptôme exprimé l'année en cours. La détection de symptômes visible reste quant à elle redondante par rapport à l'utilisation d'un capteur visible classique. La donnée hyperspectrale pourrait ainsi être utilisée pour une classification des organes de la vignes et des symptômes visibles mais ce type d'application s'avère plus facile à mettre

en œuvre et moins coûteux à l'aide d'imagerie couleur dont on exploite l'information spatiale fine. Les longueurs d'onde d'intérêt liées à ces classes ont cependant pu être identifiées.

Bien que les capteurs soient différents, les développements de la thèse ont permis de faire de nombreux parallèles entre les deux applications. Dans les deux cas, on pose un problème de classification pour lequel on met en place une chaîne complète comprenant une base de données, une étape d'extraction de descripteurs et enfin un classifieur. L'étape de classification est la même pour les deux applications (algorithme supervisé Support Vector Machine (SVM)). La constitution de la base de données et l'extraction de descripteurs sont cependant différentes et adaptées à la nature respective des données.

9.1.3 *Autres contributions*

D'autres études annexes liées à la répartition de la flavescence dorée (projet FlavSat) ont par ailleurs été conduites et valorisées à l'occasion d'un article de revue (Annexe A). Un développement méthodologique sur la détermination du caractère aléatoire ou non de la répartition des symptômes y est ainsi proposé.

9.2 CONSIDÉRATIONS SUR UNE POTENTIELLE APPLICATION INDUSTRIELLE

Les études présentées dans cette thèse ne sont pas des cas isolés. En parallèle, d'autres études font état de ces progrès, qu'ils soient dus à des capteurs ou de nouvelles méthodes. Les capteurs deviennent plus simples et les méthodes plus perfectionnées et automatisées. Les progrès de la filière rendent possible l'utilisation commerciale des capteurs en imagerie, du moins pour les capteurs couleur ou multispectraux.

La question du coût est bien sûr la première interrogation. Le capteur RVB mobile présenté dans l'étude reste encore coûteux ($\approx 1000\text{€}$ pour le prototype industriel utilisé) bien qu'il puisse fonctionner en routine. Il ne serait cependant pas insensé d'utiliser des caméras moins onéreuses, à condition que les performances de détection de l'esca restent similaires. Bien évidemment, le capteur hyperspectral est beaucoup plus onéreux et son utilisation au champ est hors de question. L'idée en cas de succès pour le problème de détection précoce était cependant d'isoler les longueurs d'onde intéressantes pour concevoir un capteur dédié. Ce n'est pas le cas et la piste d'utilisation d'un capteur mesurant les bandes d'absorption de l'eau (environ 1400nm et 1900nm) augmenterait encore le coût du capteur. Notons enfin que des caméras hyperspectrales fondées sur le principe CTIS (Computed Tomographic Imaging Spectrometer) permettent d'envisager un accès plus facile à cette technique, mais au prix d'une dégradation de performances encore mal connue [57].

La question du vecteur d'acquisition est aussi très importante. Cette thèse s'est focalisée sur la proxidétection et donc sur le passage dans le rang mais il existe un intérêt aussi pour les applications par drone ou ULM. Dans le cas où les traitements sont automatiques, la proxidétection ne nécessite pas de matériel supplémentaire (possibilité

d'adapter le dispositif sur un engin agricole) et peut être utilisé sans mobiliser un expert droniste. Il est ainsi possible de cartographier exhaustivement des parcelles au moment de réaliser d'autres opérations culturales. Elle présente aussi l'avantage d'observer le passage de la vigne dans sa verticalité et non une vue oblique ou au zénith comme les vecteurs aériens.

9.3 PERSPECTIVES

Suite aux travaux de cette thèse, les perspectives et pistes d'amélioration sont nombreuses. Elles sont cependant toutes liées à un ou plusieurs de ces quatre axes :

- Le choix du capteur
- L'application visée
- Le choix de l'algorithme de traitement d'image
- La constitution de la base de données

Bien que les résultats penchent en faveur de l'imagerie RVB, le choix du capteur reste ouvert. On peut ainsi considérer l'utilisation de capteurs alternatifs tels que des capteurs non-imageurs ponctuels (spectroradiomètre) ou des capteurs imageurs fixes permettant de suivre l'évolution d'un pied (et des détections de l'esca associées) durant tout l'été. La substitution du capteur RVB par un capteur moins coûteux de plus faible résolution fait de même partie des perspectives pour une future application. La thèse n'a volontairement pas posé la question d'une utilisation conjointe entre le capteur RVB et le capteur hyperspectral, l'objectif étant d'abord de montrer leurs potentiels individuellement. On pourrait cependant aller plus loin et imaginer un dispositif unifié fusionnant l'information visible et l'information spectrale pour raffiner les résultats de détection. La simple utilisation d'une caméra multispectrale incluant les bandes Rouge Vert Bleu (RVB) et une bande dans le Proche Infra-Rouge (PIR) apporterait ainsi une information nouvelle sur la plante.

L'application visée était ici centrée sur détection de l'esca (en considérant tous les facteurs confondants dans une meta-classe). La prise en compte plus poussée d'autres classes de facteurs confondants rendrait logiquement l'application plus générale, la faisant évoluer de la détection de l'esca vers la détection précise des maladies de la vigne. On pourrait de même imaginer que les images acquises sur une parcelle puissent servir pour d'autres applications telles que le comptage de baies à une date donnée de l'été pour la prévision du rendement. Il serait intéressant de voir si faire accomplir simultanément deux tâches différentes à un réseau de détection lui permettrait d'améliorer ses performances individuelles.

Dans tous les cas, ce virage plus général doit s'accompagner d'une base de données adaptée et d'algorithmes de traitement d'image flexibles. L'adoption d'un cadre *deep learning* dans cette thèse était un premier pas dans ce sens, tout comme l'utilisation de la *data-augmentation* pour agrandir artificiellement la taille de la base de données. Cela ne se substitue cependant pas à une base variée étalée sur de nombreuses parcelles à différents moments de l'été afin d'augmenter sa diversité. L'inclusion d'images provenant d'autres capteurs observant la vigne avec un angle et à une distance différentes peut aussi être

envisagée. Il faut cependant garder à l'esprit que l'inclusion de nouvelles images doit s'accompagner d'un étiquetage chronophage et contraignant de la donnée.

De façon plus spécifique, l'architecture précise du réseau de détection des feuilles symptomatiques est encore débattue. L'enjeu sera ici de concevoir un réseau léger et performant pouvant réaliser, si possible, de la détection embarquée et donc en temps réel. Outre les approches utilisant des réseaux modulables comme MobileNet, on pourra aussi citer les stratégies de compression d'un réseau convolutif [155]. Les approches de détection par boîte pourraient aussi être remplacées par des approches de segmentation plus précises. Celles-ci nécessiteraient cependant d'adapter l'étiquetage des données en conséquence.

Ces perspectives laissent espérer une belle marge de progression sur la détection et la cartographie des maladies de la vigne par proxidétection.

REFERENCES

- [1] Helge AASEN, Andreas BURKART, Andreas BOLTEN et Georg BARETH. « Generating 3D hyperspectral information with lightweight UAV snapshot cameras for vegetation monitoring : From camera calibration to quality assurance ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 108 (2015), p. 245–259. ISSN : 09242716. DOI : [10.1016/j.isprsjprs.2015.08.002](https://doi.org/10.1016/j.isprsjprs.2015.08.002). URL : <http://dx.doi.org/10.1016/j.isprsjprs.2015.08.002> (cf. p. 134).
- [2] F ABDELGHAFOR, B KERESZTES et C GERMAIN. « Potential of on-board colour imaging for in- field detection and counting of grape bunches at early fruiting stages ». In : *ECPA*. 2017, p. 505–509. DOI : [10.1017/S2040470017001030](https://doi.org/10.1017/S2040470017001030) (cf. p. 26, 48).
- [3] Ahmed Ameen ABDULLAH. « Application of Thermal Imaging Sensor to Early Detect Powdery Mildew Disease in Wheat ». In : *The Journal of Middle East and North Africa Sciences* May (2016) (cf. p. 29).
- [4] Hania AL-SADDIK, Anthony LAYBROS, Bastien BILLIOT et Frederic COINTAULT. « Using Image Texture and Spectral Reflectance Analysis to Detect Yellowness and Esca in Grapevines at Leaf-Level ». In : *Remote Sensing* 10 (2018), p. 618. DOI : [10.3390/rs10040618](https://doi.org/10.3390/rs10040618) (cf. p. 26, 28, 33, 47).
- [5] Jose Luis ALBA-CASTRO et Jean-pierre Da COSTA. « Vine variety discrimination with airborne imaging spectroscopy ». In : March 2016 (2007). DOI : [10.1117/12.734177](https://doi.org/10.1117/12.734177) (cf. p. 134).
- [6] Johanna ALBETIS et M GOULARD. « On the potentiality of UAV multispectral imagery to detect Flavescence dorée and Grapevine trunk. » In : *RAQRS (Recent Advances in Quantitative Remote Sensing)*. 2017 (cf. p. 27, 28, 33, 173).
- [7] Salem ALELYANI, Huan LIU et Lei WANG. « The effect of the characteristics of the dataset on the selection stability ». In : *Proceedings - International Conference on Tools with Artificial Intelligence, ICTAI* (2011), p. 970–977. ISSN : 10823409. DOI : [10.1109/ICTAI.2011.167](https://doi.org/10.1109/ICTAI.2011.167) (cf. p. 165).
- [8] L. ANDREINI, R. CARDELLI, S. BARTOLINI, G. SCALABRELLI, R. VITI, L A NDREINI, R C ARDELLI, S B ARTOLINI, G S CALABRELLI et R V ITI. « Esca symptoms appearance in *Vitis vinifera* L. : influence of climate, pedo-climatic conditions and root-stock/cultivar combination ». In : *Vitis - Journal of Grapevine Research* 53.1 (2014), p. 33–38. ISSN : 00427500 (cf. p. 18).
- [9] Jesus ANGULO et Santiago VELASCO-FORERO. « Semi-supervised hyperspectral image segmentation using regionalized stochastic watershed ». In : *Proc. SPIE* 7695 (2010), 76951F–76951F–12. ISSN : 0277786X. DOI : [10.1117/12.850187](https://doi.org/10.1117/12.850187). URL : <http://dx.doi.org/10.1117/12.850187> (cf. p. 146).
- [10] Javier BALUJA, Maria P DIAGO, Pedro BALDA, Roberto ZORER, Franco MEGGIO, Fermín MORALES et Javier TARDAGUILA. « Assessment of vineyard water status variability by thermal and multispectral imagery using an unmanned aerial vehicle (UAV) ». In : *Irrigation science* 30 (2012), p. 511–522. DOI : [10.1007/s00271-012-0382-9](https://doi.org/10.1007/s00271-012-0382-9) (cf. p. 30).

- [11] Piotr BARANOWSKI, Anna SIEDLIKA, Joanna KACZMAREK, Piotr BARANOWSKI, Malgorzata JEDRYCZKA et Wojciech MAZUREK. « Hyperspectral and Thermal Imaging of Oilseed Rape (Brassica napus) Response to Fungal Species of the Genus Alternaria Hyperspectral and Thermal Imaging of Oilseed Rape (Brassica napus) Response to Fungal Species of the Genus Alternaria ». In : *PLoS* July 2016 (2015). DOI : [10.1371/journal.pone.0122913](https://doi.org/10.1371/journal.pone.0122913). URL : <http://dx.doi.org/10.1371/journal.pone.0122913> (cf. p. 133).
- [12] Jayme Garcia BARBEDO et Jayme Garcia ARNAL BARBEDO. « Digital image processing techniques for detecting, quantifying and classifying plant diseases ». In : *SpringerPlus* 2.1 (2013), p. 1–12. ISSN : 2193-1801. DOI : [10.1186/2193-1801-2-660](https://doi.org/10.1186/2193-1801-2-660). URL : <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3863396&tool=pmcentrez&rendertype=abstract> (cf. p. 33).
- [13] R.J. BARNES, M.S DHANOA et Susan. J. LISTER. « Standard Normal Variate Transformation and De-trending of Near-Infrared Diffuse Reflectance Spectra ». In : *Applied Spectroscopy* 43.5 (1989), p. 772–777 (cf. p. 152).
- [14] E BAURIEGEL, A GIEBEL, M GEYER, U SCHMIDT et W B HERPPICH. « Early detection of Fusarium infection in wheat using hyper-spectral imaging ». In : *Computers and Electronics in Agriculture* 75.2 (2011), p. 304–312. ISSN : 01681699. DOI : [10.1016/j.compag.2010.12.006](https://doi.org/10.1016/j.compag.2010.12.006). URL : <http://dx.doi.org/10.1016/j.compag.2010.12.006> (cf. p. 133).
- [15] Elke BAURIEGEL et Werner B HERPPICH. « Hyperspectral and Chlorophyll Fluorescence Imaging for Early Detection of Plant Diseases, with Special Reference to Fusarium spec. Infections on Wheat ». In : *Agriculture* 4.July 2014 (2014). DOI : [10.3390/agriculture4010032](https://doi.org/10.3390/agriculture4010032) (cf. p. 31).
- [16] Jan BEHMANN, Jörg STEINRÜCKEN et Lutz PLÜMER. « Detection of early plant stress responses in hyperspectral images ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 93 (2014), p. 98–111. ISSN : 09242716. DOI : [10.1016/j.isprsjprs.2014.03.016](https://doi.org/10.1016/j.isprsjprs.2014.03.016). URL : <http://dx.doi.org/10.1016/j.isprsjprs.2014.03.016> (cf. p. 134).
- [17] Jan BEHMANN, Anne-Katrin MAHLEIN, Stefan PAULUS, Heiner KUHLMANN, Erich-Christian OERKE et Lutz PLÜMER. « Calibration of hyperspectral close-range pushbroom cameras for plant phenotyping ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 106.August (2015), p. 172–182. ISSN : 09242716. DOI : [10.1016/j.isprsjprs.2015.05.010](https://doi.org/10.1016/j.isprsjprs.2015.05.010). URL : <http://www.sciencedirect.com/science/article/pii/S0924271615001471> (cf. p. 137).
- [18] M C BELANGER, J M ROGER, P CARTOLARO et A VIAU. « Detection of powdery mildew in grapevine using remotely-sensed UV-induced fluorescence ». In : *International Journal of Remote Sensing* (2011) (cf. p. 31).
- [19] Étienne BELIN, David ROUSSEAU, Tristan BOUREAU et Valérie CAFFIER. « Thermography versus chlorophyll fluorescence imaging for detection and quantification of apple scab ». In : *Computers and Electronics in Agriculture* 90 (2013), p. 159–163. ISSN : 0168-1699. DOI : <https://doi.org/10.1016/j.compag.2012.09.014>. URL : <http://www.sciencedirect.com/science/article/pii/S0168169912002360> (cf. p. 31).

- [20] Sergej BERGSTRÄSSER, Dimitrios FANOURAKIS, Simone SCHMITTGEN, Maria Pilar CENDRERO-MATEO, Marcus JANSEN, Hanno SCHARR et Uwe RASCHER. « Hyper-ART : Non-invasive quantification of leaf traits using hyperspectral absorption-reflectance-transmittance imaging ». In : *Plant Methods* 11.1 (2015), p. 1–17. ISSN : 17464811. DOI : [10.1186/s13007-015-0043-0](https://doi.org/10.1186/s13007-015-0043-0) (cf. p. 28, 134).
- [21] C BERTSCH, M RAMIREZ-SUERO, M MAGNIN-ROBERT, P LARIGNON, J CHONG, E ABOU-MANSOUR, A SPAGNOLO, C CLÉMENT et F FONTAINE. « Grapevine trunk diseases : complex and still poorly understood ». In : *Plant Pathology* June (2012). DOI : [10.1126/science.324](https://doi.org/10.1126/science.324) (cf. p. 17).
- [22] Karen L. BLOCK, Philippe E. ROLSHAUSEN et Dario CANTU. « In search of solutions to grapevine trunk diseases through “crowd-sourced” science ». In : *Frontiers in Plant Science* 4.October (2013), p. 2011–2014. ISSN : 1664-462X. DOI : [10.3389/fpls.2013.00394](https://doi.org/10.3389/fpls.2013.00394). URL : <http://journal.frontiersin.org/article/10.3389/fpls.2013.00394/abstract> (cf. p. 20).
- [23] Andrew BODKIN, Bodkin DESIGN, Andrew SHEINIS, Australian Astronomical OBSERVATORY, Jim DALY et Bodkin DESIGN. « Snapshot hyperspectral imaging : The hyperpixel array camera ». In : *Proceedings of SPIE* February 2015 (2009). DOI : [10.1117/12.818929](https://doi.org/10.1117/12.818929) (cf. p. 138).
- [24] Anna BOSCH, Computer Vision GROUP, Andrew ZISSERMAN et Computer Vision GROUP. « Image Classification using Random Forests and Ferns ». In : *IEEE 11th International Conference on Computer Vision*. 2007. ISBN : 9781424416318 (cf. p. 85).
- [25] M. A. BOURGEON, J. N. PAOLI, G. JONES, S. VILLETTE et C. GEE. « Mapping vineyard foliage density with multispectral proxidection imagery ». In : *Proceedings - 10th International Conference on Signal-Image Technology and Internet-Based Systems, SITIS 2014* (2015), p. 614–621. DOI : [10.1109/SITIS.2014.94](https://doi.org/10.1109/SITIS.2014.94) (cf. p. 27, 134).
- [26] Leo BREIMAN. *Bagging Predictors*. Rapp. tech. 421. 1994, p. 123–140. DOI : [10.1007/BF00058655](https://doi.org/10.1007/BF00058655). URL : <http://link.springer.com/10.1007/BF00058655> (cf. p. 166).
- [27] Emilie BRUEZ. « Etude comparative des communautés fongiques et bactériennes colonisant le bois de ceps de vigne ayant exprimé ou non des symptômes d’esca ». Thèse de doct. 2013, p. 261 (cf. p. 11).
- [28] Erik De BRUYNE, Roland VALCKE et Dominique Van Der STRAETEN. « Thermal and chlorophyll-fluorescence imaging distinguish plant-pathogen interactions at an early stage ». In : *Plant and Cell Physiology* August (2004). DOI : [10.1093/pcp/pch097](https://doi.org/10.1093/pcp/pch097) (cf. p. 31).
- [29] Claus BUSCHMANN et Hartmut K LICHTENTHALER. « Principles and characteristics of multi-colour fluorescence imaging of plants ». In : *Journal of Plant Physiology* 152.2 (1998), p. 297–314. ISSN : 0176-1617. DOI : [https://doi.org/10.1016/S0176-1617\(98\)80144-2](https://doi.org/10.1016/S0176-1617(98)80144-2). URL : <http://www.sciencedirect.com/science/article/pii/S0176161798801442> (cf. p. 30).
- [30] Lucas BUSEMEYER et al. « Breedvision - A multi-sensor platform for non-destructive field-based phenotyping in plant breeding ». In : *Sensors (Switzerland)* 13.3 (2013), p. 2830–2847. ISSN : 14248220. DOI : [10.3390/s130302830](https://doi.org/10.3390/s130302830) (cf. p. 134).

- [31] A CABELLO-PASINI et V MACIAS-CARRANZA. « Optical properties of grapevine leaves : reflectance, transmittance, absorptance and chlorophyll concentration ». In : *Agrociencia* 45.August (2011), p. 943–957 (cf. p. 134).
- [32] R. CALDERÓN, J. A. NAVAS-CORTÉS, C. LUCENA et P. J. ZARCO-TEJADA. « High-resolution airborne hyperspectral and thermal imagery for early detection of *Verticillium* wilt of olive using fluorescence, temperature and narrow-band spectral indices ». In : *Remote Sensing of Environment* 139.November 2016 (2013), p. 231–245. ISSN : 00344257. DOI : [10.1016/j.rse.2013.07.031](https://doi.org/10.1016/j.rse.2013.07.031) (cf. p. 134).
- [33] Gregory A CARTER. « Ratios of leaf reflectances in narrow wavebands as indicators of plant stress ». In : *International Journal of Remote Sensing* 15.3 (1994), p. 697–703. DOI : [10.1080/01431169408954109](https://doi.org/10.1080/01431169408954109). URL : <https://doi.org/10.1080/01431169408954109> (cf. p. 162).
- [34] Ana I de CASTRO, Francisco M JIMÉNEZ-BRENES, Jorge TORRES-SÁNCHEZ, José M PEÑA, Irene BORRA-SERRANO et Francisca LÓPEZ-GRANADOS. « 3-D Characterization of Vineyards Using a Novel UAV Imagery-Based OBIA Procedure for Precision Viticulture Applications ». In : *Remote Sensing* 10.4 (2018) (cf. p. 26).
- [35] Laury CHAERLE, Wim Van CAENEGHEM, Eric MESSENS, Hans LAMBERS, Marc VAN MONTAGU et Dominique VAN DER STRAETEN. « Presymptomatic visualization of plant–virus interactions by thermography ». In : *Nature Biotechnology* 17 (1999), p. 813. URL : <http://dx.doi.org/10.1038/11765><http://10.0.4.14/11765> (cf. p. 29).
- [36] M M CHAVES, O ZARROUK, R FRANCISCO, J M COSTA, T SANTOS, A P REGALADO, M L RODRIGUES et C M LOPES. « Grapevine under deficit irrigation : hints from physiological and molecular data ». In : *Annals of Botany* 105 (2010), p. 661–676. DOI : [10.1093/aob/mcq030](https://doi.org/10.1093/aob/mcq030) (cf. p. 22).
- [37] Corinna CORTES et Vladimir VAPNIK. « Support-Vector Networks ». In : *Machine Learning* 297 (1995), p. 273–297 (cf. p. 68).
- [38] J Miguel COSTA, O M GRANT et M M CHAVES. « Use of Thermal Imaging in Viticulture : Current Application and Future Prospects ». In : (2010). DOI : [10.1007/978-90-481-9283-0](https://doi.org/10.1007/978-90-481-9283-0) (cf. p. 29).
- [39] Miguel COSTA, Olga Mary GRANT et M Manuela CHAVES. « Thermography to explore plant-environment interactions ». In : *Journal of Experimental Botany* 64.April (2013). DOI : [10.1093/jxb/ert029](https://doi.org/10.1093/jxb/ert029) (cf. p. 29).
- [40] A C W CRAPARO, K STEPPE, P J A Van ASTEN, P LÄDERACH, L T P JASSOGNE et S W GRAB. « Application of thermography for monitoring stomatal conductance of *Coffea arabica* under different shading systems ». In : *Science of the Total Environment* 609 (2017), p. 755–763. ISSN : 0048-9697. DOI : [10.1016/j.scitotenv.2017.07.158](https://doi.org/10.1016/j.scitotenv.2017.07.158). URL : <http://dx.doi.org/10.1016/j.scitotenv.2017.07.158> (cf. p. 29).
- [41] Paul J. CURRAN. « Remote sensing of foliar chemistry ». In : *Remote Sensing of Environment* 30.3 (1989), p. 271–278. ISSN : 00344257. DOI : [10.1016/0034-4257\(89\)90069-2](https://doi.org/10.1016/0034-4257(89)90069-2) (cf. p. 22, 133).

- [42] Qiong DAI, Jun-Hu CHENG, Da-Wen SUN et Xin-An ZENG. « Advances in Feature Selection Methods for Hyperspectral Image Processing in Food Industry Applications : A Review ». In : *Critical Reviews in Food Science and Nutrition* 8398.November 2014 (2014), p. 140401090229001. ISSN : 1040-8398, 1549-7852. DOI : [10.1080/10408398.2013.871692](https://doi.org/10.1080/10408398.2013.871692). URL : <http://www.tandfonline.com/doi/abs/10.1080/10408398.2013.871692> (cf. p. 165).
- [43] Christen DANILO G. « Towards an integrative management of eutypa dieback and esca disease of grapevine ». Thèse de doct. 2006 (cf. p. 10, 31, 33).
- [44] Bisun DATT. « A New Reflectance Index for Remote Sensing of Chlorophyll Content in Higher Plants : Tests using Eucalyptus Leaves ». In : *Journal of Plant Physiology* 154.1 (1999), p. 30–36. ISSN : 0176-1617. DOI : [https://doi.org/10.1016/S0176-1617\(99\)80314-9](https://doi.org/10.1016/S0176-1617(99)80314-9). URL : <http://www.sciencedirect.com/science/article/pii/S0176161799803149> (cf. p. 162).
- [45] Alope DATTA, Susmita GHOSH et Ashish GHOSH. « Combination of Clustering and Ranking Techniques for Unsupervised Band Selection of Hyperspectral Images ». In : *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 8.6 (2015), p. 2814–2823 (cf. p. 167).
- [46] C S T DAUGHTRY, C L WALTHALL, M S KIM, E.Brown de COLSTOUN et J E McMURTRY. « Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance ». In : *Remote Sensing of Environment* 74.2 (2000), p. 229–239. ISSN : 0034-4257. DOI : [https://doi.org/10.1016/S0034-4257\(00\)00113-9](https://doi.org/10.1016/S0034-4257(00)00113-9). URL : <http://www.sciencedirect.com/science/article/pii/S0034425700001139> (cf. p. 162).
- [47] Salvatore DAVINO, Chiara NAPOLI, Mario DAVINO et Gian Paolo ACCOTTO. « Spread of Tomato yellow leaf curl virus in Sicily : Partial Displacement of Another Geminivirus Originally Present ». In : *European Journal of Plant Pathology* 114 (2006), p. 293–299 (cf. p. 22).
- [48] S DELALIEUX, B SOMERS, W W VERSTRAETEN, J A N van AARDT, W KEULEMANS et P COPPIN. « Hyperspectral indices to diagnose leaf biotic stress of apple plants, considering leaf phenology ». In : *International Journal of Remote Sensing* 30.8 (2009), p. 1887–1912. ISSN : 0143-1161. DOI : [10.1080/01431160802541556](https://doi.org/10.1080/01431160802541556) (cf. p. 133).
- [49] J DELEGIDO, J VERRELST, C M MEZA, J P RIVERA, L ALONSO et J MORENO. « A red-edge spectral index for remote sensing estimation of green LAI over agroecosystems ». In : *European Journal of Agronomy* 46 (2013), p. 42–52. ISSN : 11610301. DOI : [10.1016/j.eja.2012.12.001](https://doi.org/10.1016/j.eja.2012.12.001). URL : <http://dx.doi.org/10.1016/j.eja.2012.12.001> (cf. p. 24).
- [50] Tanvir H DEMETRIADES-SHAH, Michael D STEVEN et Jeremy A CLARK. « High resolution derivative spectra in remote sensing ». In : *Remote Sensing of Environment* 33.1 (1990), p. 55–64. ISSN : 00344257. DOI : [10.1016/0034-4257\(90\)90055-Q](https://doi.org/10.1016/0034-4257(90)90055-Q) (cf. p. 137).
- [51] Salvatore F. DI GENNARO, E BATTISTON, S DI MARCO, O FACINI et A MATESE. « Unmanned Aerial Vehicle (UAV)-based remote sensing to monitor grapevine leaf stripe disease within a vineyard affected by esca complex ». In : *Phytopathologia*

- Mediterranea* 48.1 (2009), p. 159–188. ISSN : 00319465. DOI : [10.14601/Phytopathol](https://doi.org/10.14601/Phytopathol) (cf. p. 33).
- [52] Jacqueline EDWARDS, Guido MARCHI et Ian G. PASCOE. « Young esca in Australia ». In : *Phytopathologia Mediterranea* 40.3 (2001), p. 303–310. ISSN : 00319465 (cf. p. 8, 17).
- [53] Gamal ELMASRY, Ning WANG, Clément VIGNEAULT, Jun QIAO et Adel ELSAYED. « Early detection of apple bruises on different background colors using hyper-spectral imaging ». In : *LWT - Food Science and Technology* 41.2 (2008), p. 337–345. ISSN : 00236438. DOI : [10.1016/j.lwt.2007.02.022](https://doi.org/10.1016/j.lwt.2007.02.022) (cf. p. 134).
- [54] Yi FANG et Ramaraja P RAMASAMY. « Current and prospective methods for plant disease detection ». In : *Biosensors* 5.3 (2015), p. 537–561. ISSN : 20796374. DOI : [10.3390/bios5030537](https://doi.org/10.3390/bios5030537) (cf. p. 33).
- [55] A.J. FELICIANO, Akif ESKALEN et W. Douglas GUBLER. « Differential susceptibility of three grapevine cultivars to *Phaeoacremonium aleophilum* and *Phaeomoniella chlamydospora* in California ». In : *Phytop* 4 (2004), p. 66–69 (cf. p. 9).
- [56] Konstantinos P. FERENTINOS. « Deep learning models for plant disease detection and diagnosis ». In : *Computers and Electronics in Agriculture* 145. February (2018), p. 311–318. ISSN : 01681699. DOI : [10.1016/j.compag.2018.01.009](https://doi.org/10.1016/j.compag.2018.01.009). URL : <https://doi.org/10.1016/j.compag.2018.01.009> (cf. p. 52).
- [57] James FRANCIS. « The Design and Analysis of Computed Tomographic Imaging Spectrometers (CTIS) Using Fourier and Wavelet Crosstalk Matrices ». Thèse de doct. University of Arizona, 2010 (cf. p. 179).
- [58] J FRONTERA-PONS, M MAHOT, J P OVARLEZ, F PASCAL, S K PANG et J CHANUSSOT. « A class of robust estimates for detection in hyperspectral images using elliptical distributions background ». In : *International Geoscience and Remote Sensing Symposium (IGARSS)* (2012), p. 4166–4169. DOI : [10.1109/IGARSS.2012.6350938](https://doi.org/10.1109/IGARSS.2012.6350938) (cf. p. 137).
- [59] Alvaro FUENTES, Sook YOON, Sang Cheol KIM et Dong Sun PARK. « A Robust Deep-Learning-Based Detector for Real-Time Tomato Plant Diseases and Pests Recognition ». In : *Sensors* 17 (2017). DOI : [10.3390/s17092022](https://doi.org/10.3390/s17092022) (cf. p. 52).
- [60] Sigfredo FUENTES, Roberta DE BEL, Joanne PECH et Stephen TYERMANN. « Computational water stress indices obtained from thermal image analysis of grapevine canopies ». In : *Irrigation science* (2012) (cf. p. 30).
- [61] L FUSSLER, N KOBES, F BERTRAND, M MAUMY, J GROSMAN et S SAVARY. « A Characterization of Grapevine Trunk Diseases in France from Data Generated by the National Grapevine Wood Diseases Survey ». In : *Ecology and Epidemiology* 98.5 (2008), p. 571–579 (cf. p. 17).
- [62] Gabriele Di GASPERO, Diana BELLIN et Benedetto RUPERTI. « Pre-symptomatic detection of *Plasmopara viticola* infection in grapevine leaves using chlorophyll fluorescence imaging ». In : *European Journal of Plant Pathology* 125 (2009), p. 291–302. DOI : [10.1007/s10658-009-9482-7](https://doi.org/10.1007/s10658-009-9482-7) (cf. p. 31).

- [63] David M GATES, Harry J KEEGAN, John C SCHLETER et Victor R WEIDNER. « Spectral Properties of Plants ». In : 4.1 (1965), p. 11–20. ISSN : 0003-6935. DOI : [10.1364/AO.4.000011](https://doi.org/10.1364/AO.4.000011) (cf. p. 22, 30, 133).
- [64] Aymeric GILLET, Ludovic MACAIRE, Claudine BOTTE-LECOCQ et J-G POSTAIRE. « Color image segmentation by fuzzy morphological transformation of the 3d color histogram ». In : *Fuzzy Systems, 2001. The 10th IEEE International Conference on*. T. 2. 2001, 824–vol. DOI : [10.1109/FUZZ.2001.1009082](https://doi.org/10.1109/FUZZ.2001.1009082). URL : <https://hal.archives-ouvertes.fr/hal-01937708> (cf. p. 74).
- [65] Ross GIRSHICK, Jeff DONAHUE, Trevor DARRELL et Jitendra MALIK. *Rich feature hierarchies for accurate object detection and semantic segmentation*. Rapp. tech. 2012. arXiv : [arXiv:1311.2524v5](https://arxiv.org/abs/1311.2524v5) (cf. p. 50, 107).
- [66] Olga M GRANT, Hamlyn G JONES et M Manuela CHAVES. « Exploring thermal imaging variables for the detection of stress responses in grapevine under different irrigation regimes ». In : *Journal of Experimental Botany* 58.4 (2018), p. 815–825. DOI : [10.1093/jxb/erl153](https://doi.org/10.1093/jxb/erl153) (cf. p. 30).
- [67] Jacques GROSMAN et Bruno DOUBLET. « Maladies du bois de la vigne Synthèse des dispositifs d’observation au vignoble, de l’observatoire 2003-2008 au réseau d’épidémiosurveillance actuel ». In : *Phytoma* (2012), p. 35 (cf. p. 17, 18).
- [68] Lucia GUÉRIN-DUBRANA, Amaury LABENNE, Jean Christophe LABROUSSE, Sylvie BASTIEN, Patrice REY et Anne GÉGOUT-PETIT. « Statistical analysis of grapevine mortality associated with esca or Eutypa dieback foliar expression ». In : *Phytopathologia Mediterranea* 52.2 (2013), p. 276–288. ISSN : 00319465 (cf. p. 11).
- [69] Wei GUO, Tokihiro FUKATSU et Seishi NINOMIYA. « Automated characterization of flowering dynamics in rice using field-acquired time-series RGB images ». In : *Plant Methods* 11.1 (2015). ISSN : 17464811. DOI : [10.1186/s13007-015-0047-9](https://doi.org/10.1186/s13007-015-0047-9) (cf. p. 49).
- [70] Salvador GUTIERREZ, Maria P. Dlago FERNANDEZ-NOVALES et Javier TARDAGUILA. « On-The-Go Hyperspectral Imaging Under Field Conditions and Machine Learning for the Classification of Grapevine Varieties ». In : *Frontiers in Plant Science* 9, July (2018), p. 1–11. DOI : [10.3389/fpls.2018.01102](https://doi.org/10.3389/fpls.2018.01102) (cf. p. 134).
- [71] Driss HABOUDANE, John R MILLER, Elizabeth PATTEY, Pablo J ZARCO-TEJADA et Ian B STRACHAN. « Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies : Modeling and validation in the context of precision agriculture ». In : *Remote Sensing of Environment* 90.3 (2004), p. 337–352. ISSN : 0034-4257. DOI : <https://doi.org/10.1016/j.rse.2003.12.013>. URL : <http://www.sciencedirect.com/science/article/pii/S0034425704000264> (cf. p. 162).
- [72] Robert M. HARALICK, K. SHAUNMUGAM et Its’hak DINSTEIN. « Textural features for image classification ». In : *IEEE Transactions on Systems, Man and Cybernetics Part C : Applications and Reviews* 6 (1973), p. 610–621 (cf. p. 47).
- [73] Kaiming HE, Xiangyu ZHANG, Shaoqing REN et Jian SUN. *Deep Residual Learning for Image Recognition*. Rapp. tech. 2015. arXiv : [arXiv:1512.03385v1](https://arxiv.org/abs/1512.03385v1) (cf. p. 51, 93).

- [74] Valérie HOFSTETTER, Bart BUYCK, Daniel CROLL, Olivier VIRET, Arnaud COULOUX et Katia GINDRO. « What if esca disease of grapevine were not a fungal disease ? » In : *Fungal Diversity* 54 (2012), p. 51–67. ISSN : 15602745. DOI : [10.1007/s13225-012-0171-z](https://doi.org/10.1007/s13225-012-0171-z) (cf. p. 9).
- [75] Andrew G. HOWARD, Menglong ZHU, Bo CHEN, Dmitry KALENICHENKO, Weijun WANG, Tobias WEYAND, Marco ANDREETTO et Hartwig ADAM. *MobileNets : Efficient Convolutional Neural Networks for Mobile Vision Applications*. Rapp. tech. Google Inc., 2017. DOI : [arXiv:1704.04861](https://arxiv.org/abs/1704.04861). arXiv : 1704.04861. URL : <http://arxiv.org/abs/1704.04861> (cf. p. 93).
- [76] Kuo-Yi HUANG. « Application of artificial neural network for detecting Phalaenopsis seedling diseases using color and texture features ». In : *Computers and Electronics in Agriculture* 57.1 (2007), p. 3–11. ISSN : 0168-1699. DOI : <https://doi.org/10.1016/j.compag.2007.01.015>. URL : <http://www.sciencedirect.com/science/article/pii/S0168169907000385> (cf. p. 47).
- [77] Lin-Sheng HUANG et Jin-ling ZHAO. « Identifying and Mapping Stripe Rust in Winter Wheat using Multi-temporal Airborne Hyperspectral Images ». In : *International Journal of Agriculture and Biology* 2005 (2012), p. 697–704 (cf. p. 28).
- [78] David HUGHES et MARCEL SALATHE. « An open access repository of images on plant health to enable the development of mobile disease diagnostics ». In : (2015), p. 1–13. DOI : [10.1111/1755-0998.12237](https://arxiv.org/abs/1511.08060). arXiv : 1511.08060 (cf. p. 52).
- [79] G HUGHES. « On the mean accuracy of statistical pattern recognizers ». In : *IEEE Transactions on Information Theory* 14.1 (1968), p. 55–63. ISSN : 0018-9448. DOI : [10.1109/TIT.1968.1054102](https://doi.org/10.1109/TIT.1968.1054102). arXiv : 0-387-31073-8. URL : <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1054102> (cf. p. 138).
- [80] IFV. *Institut Français de la vigne et du vin : fichiers pratiques*. URL : <https://www.vignevin-sudouest.com/publications/fiches-pratiques/fiches-{\%}0Apratiques.php> (cf. p. 15).
- [81] Forrest N. IANDOLA, Song HAN, Matthew W. MOSKEWICZ, Khalid ASHRAF, William J. DALLY et Kurt KEUTZER. « SqueezeNet : AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size ». In : *ICLR 2017*. 2016, p. 1–13. ISBN : 978-3-319-24552-2. DOI : [10.1007/978-3-319-24553-9](https://arxiv.org/abs/1602.07360). arXiv : 1602.07360. URL : <http://arxiv.org/abs/1602.07360> (cf. p. 93).
- [82] INTERNATIONAL ORGANISATION OF VINE AND WINE. *State of the Vitiviniculture World Market*. Rapp. tech. March. 2011. URL : http://www.indianwineacademy.com/2011{_}note{_}conj{_}mars{_}EN.pdf (cf. p. 18).
- [83] Roselyne ISHIMWE, K ABUTALEB et F AHMED. « Applications of Thermal Imaging in Agriculture—A Review ». In : *Advances in Remote Sensing* September (2014), p. 128–140 (cf. p. 33).
- [84] Konstantin IVUSHKIN, Harm BARTHOLOMEUS, Arnold K BREGT, Alim PULATOV, Elisabeth N BUI et John WILFORD. « Soil salinity assessment through satellite thermography for different irrigated and rainfed crops ». In : *Int J Appl Earth Obs Geoinformation* 68.March (2018), p. 230–237. ISSN : 0303-2434. DOI : [10.1016/j.jag.2018.02.004](https://doi.org/10.1016/j.jag.2018.02.004). URL : <https://doi.org/10.1016/j.jag.2018.02.004> (cf. p. 30).

- [85] Frédéric JACOB, Thomas SCHMUGGE, Albert OLIOSO, Andrew FRENCH, Dominique COURAULT, Kenta OGAWA, Francois PETITCOLIN, Ghani CHEHBOUNI, Ana PINHEIRO et Jeffrey PRIVETTE. « Modeling and Inversion in Thermal Infrared Remote Sensing over Vegetated Land Surfaces ». In : *Advances in Land Remote Sensing : System, Modeling, Inversion and Application*. Sous la dir. de Shunlin LIANG. Dordrecht : Springer Netherlands, 2008, p. 245–291. ISBN : 978-1-4020-6450-0. DOI : [10.1007/978-1-4020-6450-0_10](https://doi.org/10.1007/978-1-4020-6450-0_10). URL : [https://doi.org/10.1007/978-1-4020-6450-0{_}10](https://doi.org/10.1007/978-1-4020-6450-0_{_}10) (cf. p. 29).
- [86] Sylvain JAY, Ryad BENDOULA, Xavier HADOUX, Jean-Baptiste FÉRET et Nathalie GORRETTA. « A physically-based model for retrieving foliar biochemistry and leaf orientation using close-range imaging spectroscopy ». In : *Remote Sensing of Environment* 177 (2016), p. 220–236. ISSN : 0034-4257. DOI : <http://dx.doi.org/10.1016/j.rse.2016.02.029>. URL : <http://www.sciencedirect.com/science/article/pii/S0034425716300566> (cf. p. 137).
- [87] Hervé JÉGOU, Matthijs DOUZE, Cordelia SCHMID et Patrick PÉREZ. « Aggregating local descriptors into a compact image representation ». In : *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition* (2010), p. 3304–3311. ISSN : 10636919. DOI : [10.1109/CVPR.2010.5540039](https://doi.org/10.1109/CVPR.2010.5540039) (cf. p. 78).
- [88] Hamlyn G JONES, Rachid SERRAJ, A WHEATON et Adam PRICE. « Thermal infrared imaging of crop canopies for remote diagnosis and quantification of plant responses to water stress in the field ». In : *April* (2009). DOI : [10.1071/FP09123](https://doi.org/10.1071/FP09123) (cf. p. 29).
- [89] Belasque JR, Luis G MARCASSA et Emery C LINS. « Detection of citrus canker in citrus plants using laser induced fluorescence spectroscopy ». In : *Precision Agriculture* (2009), p. 319–330. DOI : [10.1007/s11119-009-9124-2](https://doi.org/10.1007/s11119-009-9124-2) (cf. p. 31).
- [90] Hanife KEBAPCI, Berrin YANIKOGLU et Gozde UNAL. « Plant image retrieval using color, shape and texture features ». In : *Computer Journal* 54.9 (2011), p. 1475–1490. ISSN : 00104620. DOI : [10.1093/comjnl/bxq037](https://doi.org/10.1093/comjnl/bxq037) (cf. p. 47, 49).
- [91] Dae Gwan KIM, Thomas F BURKS, Jianwei QIN et Duke M BULANON. « Classification of grapefruit peel diseases using color texture feature analysis ». In : *2.3* (2009), p. 41–50. DOI : [10.3965/j.issn.1934-6344.2009.03.041-050](https://doi.org/10.3965/j.issn.1934-6344.2009.03.041-050) (cf. p. 47).
- [92] D S KIMES, S B IDSO, P J PINTER, R J REGINATO et R D JACKSON. « View angle effects in the radiometric measurement of plant canopy temperatures ». In : *Remote Sensing of Environment* 10.4 (1980), p. 273–284. ISSN : 0034-4257. DOI : [https://doi.org/10.1016/0034-4257\(80\)90087-5](https://doi.org/10.1016/0034-4257(80)90087-5). URL : <http://www.sciencedirect.com/science/article/pii/0034425780900875> (cf. p. 30).
- [93] D KREZHOVA, D DIKOVA et D MANEVA. « Ground based hyperspectral remote sensing for disease detection of tobacco plants ». In : *Bulgarian journal of agricultural science* 20.5 (2014), p. 1142–1150. URL : <http://www.agrojournal.org/20/05-20.pdf> (cf. p. 133).
- [94] Alex KRIZHEVSKY, Ilya SUTSKEVER et Geoffrey E HINTON. « ImageNet Classification with Deep Convolutional Neural Networks ». In : *Advances In Neural Information Processing Systems* (2012), p. 1–9. ISSN : 10495258. DOI : <http://dx.doi.org/10.1016/j.protcy.2014.09.007>. arXiv : [1102.0183](https://arxiv.org/abs/1102.0183) (cf. p. 50).

- [95] P KUNTZMANN, S VILLAUME, Philippe LARIGNON et Christophe BERTSCH. « Esca, BDA and Eutypiosis : foliar symptoms, trunk lesions and fungi observed in diseased vinestocks in two vineyards in Alsace ». In : *Journal of Grapevine Research* 49.2 (2010), p. 71–76 (cf. p. 12, 16).
- [96] M T KUSKA, S THOMAS, D BOHNENKAMP, E ALISAAC, J BEHMANN, M WAHABZADA et K KERSTING. « Plant disease detection by hyperspectral imaging : from the lab to the field ». In : *Advances in animal Biosciences : Prevision Agriculture* (2017), p. 238–243. DOI : [10.1017/S2040470017001248](https://doi.org/10.1017/S2040470017001248) (cf. p. 28).
- [97] Carole LAMBERT. « Étude du rôle des stilbènes dans les défenses de la vigne contre les maladies du bois ». Thèse de doct. 2011 (cf. p. 11).
- [98] Philippe LARIGNON. « Maladies cryptogamiques du bois de la vigne : symptomatologie et agents pathogènes ». In : *Vignevin.Com* (2016), p. 168. URL : http://www.vignevin.com/fileadmin/users/ifv/actualites/MaladiesduBois/maladiesdubois21mars2012{_}Partir1.pdf (cf. p. 9).
- [99] Philippe LARIGNON et Bernadette DUBOS. « Le Black Dead Arm : maladie nouvelle à ne pas confondre avec l’esca ». In : *Phytoma-La Défense des végétaux* 538 (2001), p. 26–29. ISSN : 1164-6993. URL : <http://cat.inist.fr/?aModele=afficheN{\&}cpsidt=1088063> (cf. p. 8).
- [100] Philippe LARIGNON, G DARNÉ, E MENARD, F DESACHE et B DUDOS. « Comment agissait l’arsénite de sodium sur l’esca de la vigne ? » In : *Progrès Agricole et Viticole* 125 (2008), p. 642–651 (cf. p. 8).
- [101] Philippe LARIGNON, Florence FONTAINE, Sibylle FARINE, Christophe CLÉMENT et Christophe BERTSCH. « Esca et Black Dead Arm : deux acteurs majeurs des maladies du bois chez la Vigne ». In : *Comptes Rendus - Biologies* 332.9 (2009), p. 765–783. ISSN : 16310691. DOI : [10.1016/j.crvi.2009.05.005](https://doi.org/10.1016/j.crvi.2009.05.005). URL : <http://dx.doi.org/10.1016/j.crvi.2009.05.005> (cf. p. 11).
- [102] Yann LECUN, B BOSER, J.S. DENKER, D. HENDERSON, R.E. HOWARD, W. HUBBARD et L.D. JACKEL. « Backpropagation applied to handwritten zip code recognition ». In : *Neural Computation* 1 (1989), p. 541–555 (cf. p. 107).
- [103] Yann LECUN, Léon BOTTOU, Yoshua BENGIO et Patrick HAFFNER. « Gradient based learning applied to document recognition ». In : *Processing of the IEEE* (1998). ISSN : 00189219. DOI : [10.1109/5.726791](https://doi.org/10.1109/5.726791). arXiv : [1102.0183](https://arxiv.org/abs/1102.0183) (cf. p. 50).
- [104] P. LECOMTE, G. DARRIEUTORT, J.-M. LIMINANA, G. COMONT, A. MURUAMENDIARAZ, F.-J. LEGORBURU, E. CHOUËIRI, F. JREIJIRI, Roula EL AMIL et Marc FERMAUD. « New Insights into Esca of Grapevine : The Development of Foliar Symptoms and Their Association with Xylem Discoloration ». In : *Plant Disease* 96.7 (2012), p. 924–934. ISSN : 0191-2917. DOI : [10.1094/PDIS-09-11-0776-RE](https://doi.org/10.1094/PDIS-09-11-0776-RE). URL : <http://apsjournals.apsnet.org/doi/10.1094/PDIS-09-11-0776-RE> (cf. p. 14, 16, 41).
- [105] Audrey LEDOUX, Olivier LOSSON et Ludovic MACAIRE. « Color local binary patterns : Compact descriptors for texture classification ». In : *Journal of Electronic Imaging* 25 (2016), p. 61404. DOI : [10.1117/1.JEI.25.6.061404](https://doi.org/10.1117/1.JEI.25.6.061404) (cf. p. 49).

- [106] Cecile LEVASSEUR-GARCIA, Hugo MALAURIE et Nathalie MAILHAC. « An infrared diagnostic system to detect causal agents of grapevine trunk diseases ». In : *Journal of Microbiological Methods* 131 (2016), p. 1–6. ISSN : 18728359. DOI : [10.1016/j.mimet.2016.09.022](https://doi.org/10.1016/j.mimet.2016.09.022). URL : <http://dx.doi.org/10.1016/j.mimet.2016.09.022> (cf. p. 28).
- [107] Tsung Yi LIN, Priya GOYAL, Ross GIRSHICK, Kaiming HE et Piotr DOLLAR. « Focal Loss for Dense Object Detection ». In : *Proceedings of the IEEE International Conference on Computer Vision 2017-October* (2017), p. 2999–3007. ISSN : 15505499. DOI : [10.1109/ICCV.2017.324](https://doi.org/10.1109/ICCV.2017.324). arXiv : [1708.02002](https://arxiv.org/abs/1708.02002) (cf. p. 107, 108).
- [108] Tsung-yi LIN, Ross GIRSHICK, Kaiming HE, Bharath HARIHARAN, Serge BELONGIE et Cornell TECH. *Feature Pyramid Networks for Object Detection*. Rapp. tech. Facebook AI Reseach (FAIR). arXiv : [arXiv:1612.03144v2](https://arxiv.org/abs/1612.03144v2) (cf. p. 107).
- [109] Miriam LINDENTHAL et Ulrike STEINER. « Effect of Downy Mildew Development on Transpiration of Cucumber Leaves Visualized by Digital Infrared Thermography ». In : 95.3 (2005), p. 233–240 (cf. p. 29).
- [110] Wei LIU, Dragomir ANGUELOV, Dumitru ERHAN, Christian SZEGEDY, Scott REED, Cheng-yang FU et Alexander C BERG. *SSD : Single Shot MultiBox Detector*. Rapp. tech. 2016. arXiv : [arXiv:1512.02325v5](https://arxiv.org/abs/1512.02325v5) (cf. p. 107).
- [111] Yande LIU, Xudong SUN, Jianmin ZHOU, Hailiang ZHANG et Chao YANG. « Linear and nonlinear multivariate regressions for determination sugar content of intact Gannan navel orange by Vis–NIR diffuse reflectance spectroscopy ». In : *Mathematical and Computer Modelling* 51.11-12 (2010), p. 1438–1443. ISSN : 0895-7177. DOI : [10.1016/j.mcm.2009.10.003](https://doi.org/10.1016/j.mcm.2009.10.003). URL : <http://dx.doi.org/10.1016/j.mcm.2009.10.003> (cf. p. 152).
- [112] Antoine LIUTKUS. « Scale-Space Peak Picking ». In : (2015) (cf. p. 171).
- [113] David G LOWE. *Distinctive Image Features from Scale-Invariant Keypoints*. Rapp. tech. University of British Columbia, 2004, p. 1–28 (cf. p. 48).
- [114] Hao LU, Zhiguo CAO, Yang XIAO, Bohan ZHUANG et Chunhua SHEN. « TasselNet : counting maize tassels in the wild via local counts regression network ». In : *Plant Methods* (2017), p. 1–17. ISSN : 1746-4811. DOI : [10.1186/s13007-017-0224-0](https://doi.org/10.1186/s13007-017-0224-0) (cf. p. 52).
- [115] Laurens Van Der MAATEN et Geoffrey HINTON. « Visualizing Data using t-SNE ». In : *Journal of Machine Learning Research* 9 (2008), p. 2579–2605. ISSN : 02545330. DOI : [10.1007/s10479-011-0841-3](https://doi.org/10.1007/s10479-011-0841-3) (cf. p. 70).
- [116] Sarah L. MACDONALD, Matthew STAID, Melissa STAID et Monica L. COOPER. « Remote hyperspectral imaging of grapevine leafroll-associated virus 3 in cabernet sauvignon vineyards ». In : *Computers and Electronics in Agriculture* 130.October (2016), p. 109–117. ISSN : 01681699. DOI : [10.1016/j.compag.2016.10.003](https://doi.org/10.1016/j.compag.2016.10.003). URL : <http://linkinghub.elsevier.com/retrieve/pii/S016816991630237X> (cf. p. 28).
- [117] Aravindh MAHENDRAN et Andrea VEDALDI. « Understanding Deep Image Representations by Inverting Them ». In : *Cvpr* (2015). ISSN : 9781467369640. DOI : [10.1109/CVPR.2015.7299155](https://doi.org/10.1109/CVPR.2015.7299155). arXiv : [1412.0035](https://arxiv.org/abs/1412.0035). URL : <http://arxiv.org/abs/1412.0035> (cf. p. 103).

- [118] Anne-Katrin Katrin MAHLEIN et al. « Hyperspectral imaging for small-scale analysis of symptoms caused by different sugar beet diseases ». In : *Plant Methods* 8.1 (2012), p. 3. ISSN : 1746-4811. DOI : [10.1186/1746-4811-8-3](https://doi.org/10.1186/1746-4811-8-3). URL : <http://plantmethods.biomedcentral.com/articles/10.1186/1746-4811-8-3> (cf. p. 134).
- [119] Guido MARCHI, Francesca PEDUTO, Laura MUGNAI, Stefano di MARCO, Francesco CALZARANO et Giuseppe SURICO. « Some observations on the relationship of manifest and hidden esca to rainfall ». In : *Phytopathologia Mediterranea* 45.SUPPL. 1 (2006). ISSN : 00319465 (cf. p. 18).
- [120] Stefano Di MARCO, Italian NATIONAL, Fabio OSTI et Italian NATIONAL. « Experiments on the control of esca by Trichoderma ». In : *Phytopathologia Mediterranea* 43.May (2004) (cf. p. 20).
- [121] Adolfo MART. « Comparison of Unsupervised Band Selection Methods for Hyperspectral Imaging ». In : (2007), p. 30–38. ISSN : 03029743. DOI : [10.1007/978-3-540-72847-4_6](https://doi.org/10.1007/978-3-540-72847-4_6) (cf. p. 166).
- [122] Federico MARTINELLI et al. « Advanced methods of plant disease detection. A review ». In : *Agronomy for Sustainable Development* 35.1 (2015), p. 1–25. ISSN : 17730155. DOI : [10.1007/s13593-014-0246-1](https://doi.org/10.1007/s13593-014-0246-1) (cf. p. 21, 33).
- [123] A MEUNKAEWJINDA, P KUMSAWAT, K ATTAKITMONGCOL et A SRIKAEW. « Grape leaf disease detection from color imagery using hybrid intelligent system ». In : *2008 5th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology*. T. 1. 2008, p. 513–516. DOI : [10.1109/ECTICON.2008.4600483](https://doi.org/10.1109/ECTICON.2008.4600483) (cf. p. 26).
- [124] Mustafa MIRIK, J A PRICE, R James ANSLEY et C M RUSH. « Satellite Remote Sensing of Wheat Infected by Wheat streak mosaic virus ». In : *Plant Disease* March (2015). DOI : [10.1094/PDIS-04-10-0256](https://doi.org/10.1094/PDIS-04-10-0256) (cf. p. 27).
- [125] K Jagan MOHAN et M BALASUBRAMANIAN. « Recognition of Paddy Plant Diseases Based on Histogram Oriented Gradient Features ». In : *International Journal of Advanced Research in Computer and Communication Engineering* 5.3 (2016), p. 3–6. DOI : [10.17148/IJARCCCE.2016.53257](https://doi.org/10.17148/IJARCCCE.2016.53257) (cf. p. 49).
- [126] Sharada P MOHANTY et David P HUGHES. « Using Deep Learning for Image-Based Plant Disease Detection ». In : 7.September (2016), p. 1–10. DOI : [10.3389/fpls.2016.01419](https://doi.org/10.3389/fpls.2016.01419) (cf. p. 51).
- [127] Leire MOLINERO-RUIZ. « Use of Blue-Green Fluorescence and Thermal Imaging in the Early Detection of Sunflower Infection by the Root Parasitic Weed *Orobanche cumana* Wallr. ». In : *Frontiers in Plant Science* 8.May (2017), p. 1–10. DOI : [10.3389/fpls.2017.00833](https://doi.org/10.3389/fpls.2017.00833) (cf. p. 31).
- [128] Laura MUGNAI, A GRANITI et Giuseppe SURICO. « Esca (Black Measles) and Brown Wood-Streaking : Two Old and Elusive Diseases of Grapevines ». In : *Plant disease* 83.5 (1999) (cf. p. 9, 12).

- [129] Eduardo A MURILLO-BRACAMONTES, Miguel E MARTINEZ-ROSAS, Manuel M MIRANDA-VELASCO, Horacio L MARTINEZ-REYES, Jesus R MARTINEZ-SANDOVAL et Humberto Cervantes-de AVILA. « Implementation of Hough transform for fruit image segmentation ». In : *International Meeting of Electrical Engineering Research*. T. 35. 2012, p. 230–239. DOI : [10.1016/j.proeng.2012.04.185](https://doi.org/10.1016/j.proeng.2012.04.185). URL : <http://dx.doi.org/10.1016/j.proeng.2012.04.185> (cf. p. 47).
- [130] Andrew M. MUTKA et Rebecca S. BART. « Image-based phenotyping of plant disease symptoms ». In : *Frontiers in Plant Science* 5.January (2015), p. 734. ISSN : 1664-462X. DOI : [10.3389/fpls.2014.00734](https://doi.org/10.3389/fpls.2014.00734). URL : <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=4283508&tool=pmcentrez&rendertype=abstract> (cf. p. 33).
- [131] a N PETIT et al. « Alteration of photosynthesis in grapevines affected by esca. » In : *Phytopathology* 96.10 (2006), p. 1060–6. ISSN : 0031-949X. DOI : [10.1094/PHYTO-96-1060](https://doi.org/10.1094/PHYTO-96-1060). URL : <http://www.ncbi.nlm.nih.gov/pubmed/18943493> (cf. p. 10).
- [132] Rayapati A. NAIDU, Eileen M. PERRY, Francis J. PIERCE et Tefera MEKURIA. « The potential of spectral reflectance technique for the detection of Grapevine leafroll-associated virus-3 in two red-berried wine grape cultivars ». In : *Computers and Electronics in Agriculture* 66.1 (2009), p. 38–45. ISSN : 01681699. DOI : [10.1016/j.compag.2008.11.007](https://doi.org/10.1016/j.compag.2008.11.007) (cf. p. 28).
- [133] Marion NEUMANN et Christian BAUCKHAGE. *Erosion Band Features for Cell Phone Image Based Plant Disease Classification*. Rapp. tech. December. 2014. DOI : [10.1109/ICPR.2014.571](https://doi.org/10.1109/ICPR.2014.571) (cf. p. 26).
- [134] Fred NICODEMUS. « Directional reflectance and emissivity of an opaque surface ». In : *Applied optics* 4.7 (1965), p. 767–775 (cf. p. 136).
- [135] Maroua NOURI. « Détection précoce d'une maladie fongique « la tavelure du pommier » par imagerie hyperspectrale ». Thèse de doct. 2018 (cf. p. 133).
- [136] Roberto OBERTI, Massimo MARCHI, Paolo TIRELLI, Aldo CALCANTE, Marcello IRITI et Alberto N. BORGHESE. « Automatic detection of powdery mildew on grapevine leaves by image analysis : Optimal view-angle range to increase the sensitivity ». In : *Computers and Electronics in Agriculture* 104 (2014), p. 1–8. ISSN : 01681699. DOI : [10.1016/j.compag.2014.03.001](https://doi.org/10.1016/j.compag.2014.03.001). URL : <http://dx.doi.org/10.1016/j.compag.2014.03.001> (cf. p. 27).
- [137] L OUADI, E BRUEZ, S BASTIEN, J.C. DOMEQ et P REY. « Highlights on ecophysiological changes in Esca diseased grapevines in comparison to healthy plants ». In : *10th International Workshop on Grapevine Trunk Diseases*. 2017. URL : https://www.maladie-du-bois-vigne.fr/maladies-du-bois-vigne/_eng/Publications/2017/10th-IWGTD (cf. p. 22, 175).
- [138] Jun PANG, Zhong-Ying BAI, Jun-Chen LAI et Shao-Kun LI. « Automatic Segmentation of Crop Leaf Spot Disease Images by Integrating Local Threshold and Seeded Region Growing ». In : *2011 International Conference on Image Analysis and Signal Processing*. 2011, p. 1–5 (cf. p. 47).

- [139] Pornntiwa PAWARA, Emmanuel OKAFOR, Olarik SURINTA, Lambert SCHOMAKER et Marco WIERING. « Comparing Local Descriptors and Bags of Visual Words to Deep Convolutional Neural Networks for Plant Recognition ». In : *Pattern Recognition Applications and Methods (ICPRAM), 6th International Conference on March* (2017), p. 479–486. DOI : [10.5220/0006196204790486](https://doi.org/10.5220/0006196204790486) (cf. p. 53).
- [140] F PERRONNIN et C DANCE. « Fisher Kenrels on Visual Vocabularies for Image Categorization ». In : *Proc. {CVPR}* (2006) (cf. p. 79).
- [141] Florent PERRONNIN, S JORGE et Thomas MENSINK. *Improving the Fisher Kernel for Large-Scale Image Classification To cite this version : Improving the Fisher Kernel for Large-Scale Image Classification*. Rapp. tech. Xerox Research Centre Europe, 2010, p. 143–156 (cf. p. 80).
- [142] Richard B. PETERSON et Donald E. AYLOR. « Chlorophyll Fluorescence Induction in Leaves of Phaseolus Vulgaris infected with Bean Rust ». In : *Plant physiology* 108.1 995 (1995), p. 163–171 (cf. p. 31).
- [143] N.B PIERCE. *The California vine disease. A preliminary report of investigations*. Rapp. tech. 1892, p. 222 (cf. p. 7).
- [144] Romain PIERRON. « Esca et vigne : compréhension des mécanismes de défense précoces du bois de la vigne Vitis Vinifera L. suite à la maladie, colonisation des champignons in planta et proposition de moyens de lutte pour une viticulture durable ». Thèse de doct. 2012, p. 228 (cf. p. 11).
- [145] Francisco PINTO, Anke SCHICKLING, M Pilar CENDRERO-MATEO, Agim BALLVORA et Uwe RASCHER. « Multiangular Observation of Canopy Sun-Induced Chlorophyll Fluorescence by Combining Imaging Spectroscopy and Stereoscopy Francisco ». In : *Remote Sensing* 9 (2004). DOI : [10.3390/rs9050415](https://doi.org/10.3390/rs9050415) (cf. p. 31).
- [146] Rillian Diello Lucas PIRES, Diogo Nunes GONCALVES, Jonatan Patrick Margarido ORUE, Wesley Eiji Sanches KANASHIRO, Jose F. RODRIGUES, Bruno Brandoli MACHADO et Wesley Nunes GONCALVES. « Local descriptors for soybean disease recognition ». In : *Computers and Electronics in Agriculture* 125 (2016), p. 48–55. ISSN : 01681699. DOI : [10.1016/j.compag.2016.04.032](https://doi.org/10.1016/j.compag.2016.04.032). URL : <http://dx.doi.org/10.1016/j.compag.2016.04.032> (cf. p. 50).
- [147] Audrey PISSARD, Juan A Fernandez PIERNA, Vincent BAETEN, Georges SINNAEVE, Georges LOGNAY, Anne MOUTEAU, Pascal DUPONT, Alain RONDIA et Alain LATEUR. « Non-destructive measurement of vitamin C, total polyphenol and sugar content in apples using near-infrared spectroscopy ». In : *J Sci Food Agric* 93. July 2012 (2013), p. 238–244. DOI : [10.1002/jsfa.5779](https://doi.org/10.1002/jsfa.5779) (cf. p. 152).
- [148] J PLATT. « Probabilistic outputs for support vector machines and comparisons to regularized likelihood methods ». In : *Advances in large margin classifiers* 10.3 (1999), p. 61–74. ISSN : 0262194481. DOI : [10.1.1.41.1639](https://doi.org/10.1.1.41.1639) (cf. p. 69).
- [149] Stefania POLLASTRO, Crescenza DONGIOVANNI, Angela ABBATECOLA et Francesco FARETRA. « Observations on the fungi associated with esca and on spatial distribution of esca-symptomatic plants in Apulian (Italy) vineyards ». In : *Phytopathologia Mediterranea* 39.1 (2000), p. 206–210. ISSN : 00319465 (cf. p. 42).

- [150] Shitala PRASAD, Piyush KUMAR, Ranjay HAZRA et Ajay KUMAR. « Plant Leaf Disease Detection Using Gabor Wavelet Transform ». In : *International Conference on Swarm, Evolutionary and Memetic Computing*. 2012, p. 372–379 (cf. p. 48).
- [151] Jagadeesh D. PUJARI, Rajesh YAKKUNDIMATH et Abdulmunaf S. BYADGI. « Image processing Based Detection of Fungal Diseases in Plants ». In : *Procedia Computer Science* 46.Icict 2014 (2015), p. 1802–1808. ISSN : 18770509. DOI : [10.1016/j.procs.2015.02.137](https://doi.org/10.1016/j.procs.2015.02.137) (cf. p. 33).
- [152] Nicola PULETTI, Rita PERRIA et Paolo STORCHI. « Unsupervised classification of very high remotely sensed images for grapevine rows detection ». In : *European Journal of Remote Sensing* 47.1 (2014), p. 45–54. ISSN : 22797254. DOI : [10.5721/EuJRS20144704](https://doi.org/10.5721/EuJRS20144704) (cf. p. 26).
- [153] Nguyen QUANG_KHUE, Le THI-LAN et Pham NGOC-HAI. « Leaf based plant identification system for Android using SURF features in combination with Bag of Words model and supervised learning ». In : *ATC'2013*. 2013, p. 404–407. ISBN : 9781479910892 (cf. p. 49).
- [154] Amanda RAMCHARAN, Kelsee BARANOWSKI, P McCLOSKEY, Babuali AHMED et David P HUGHES. « Deep Learning for Image-Based Cassava Disease Detection ». In : *Frontiers in Plant Science* 8.October (2017), p. 1–7. DOI : [10.3389/fpls.2017.01852](https://doi.org/10.3389/fpls.2017.01852) (cf. p. 26).
- [155] Patricio Bulić RATKO PILIPOVIĆ et Vladimir RISOJEVIĆ. « Compression of convolutional neural networks ». In : *17th International Symposium INFOTEH-JAHORINA*, March. 2018, p. 21–23. ISBN : 9781538649077 (cf. p. 181).
- [156] Louis RAVAZ. « Le Folletage ». In : *Progrès Agricole et Viticole* 35 (1901), p. 633 (cf. p. 6, 7).
- [157] Ali Sharif RAZAVIAN, Hossein AZIZPOUR, Josephine SULLIVAN et Stefan CARLSSON. « CNN features off-the-shelf : An astounding baseline for recognition ». In : *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops* (2014), p. 512–519. ISSN : 21607516. DOI : [10.1109/CVPRW.2014.131](https://doi.org/10.1109/CVPRW.2014.131). arXiv : [1403.6382](https://arxiv.org/abs/1403.6382) (cf. p. 95).
- [158] Joseph REDMON, Santosh DIVVALA, Ross GIRSHICK et Ali FARHADI. *You Only Look Once : Unified, Real-Time Object Detection*. Rapp. tech. 2016. arXiv : [arXiv : 1506.02640v5](https://arxiv.org/abs/1506.02640v5) (cf. p. 107).
- [159] Olivier REGNIERS. « Méthodes d'analyse de texture pour la cartographie d'occupations du sol par télédétection très haute résolution : Application à la forêt, la vigne et les parcs ostréicoles. » Thèse de doct. 2014 (cf. p. 25, 48).
- [160] Helga REISENZEIN, Norbert BERGER et Gerald NIEDER. « Esca in Austria ». In : *Phytopathologia Mediterranea* 39 (2000), p. 26–34 (cf. p. 17).
- [161] Shaoqing REN, Kaiming HE, Ross GIRSHICK et Jian SUN. *Faster R-CNN : Towards Real-Time Object Detection with Region Proposal Networks*. Rapp. tech. 2016, p. 1–14. arXiv : [arXiv : 1506.01497v3](https://arxiv.org/abs/1506.01497v3) (cf. p. 107).
- [162] J W ROUSE, R H HAAS et J A SCHELL. *Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation*. English. College Station : Texas A et M University, 1974 (cf. p. 162).

- [163] Céline ROUSSEAU, Etienne BELIN, Edouard BOVE, David ROUSSEAU, Frédéric FABRE, Romain BERRUYER, Jacky GUILLAUMÈS, Charles MANCEAU, Marie-Agnès JACQUES et Tristan BOUREAU. « High throughput quantitative phenotyping of plant resistance using chlorophyll fluorescence image analysis ». In : *Plant Methods* 9.1 (2013), p. 17. ISSN : 1746-4811. DOI : [10.1186/1746-4811-9-17](https://doi.org/10.1186/1746-4811-9-17). URL : <https://doi.org/10.1186/1746-4811-9-17> (cf. p. 31).
- [164] Inkyu SA, Zongyuan GE, Feras DAYOUB, Ben UPCROFT, Tristan PEREZ et Chris MCCOOL. « Deepfruits : A fruit detection system using deep neural networks ». In : *Sensors (Switzerland)* 16.8 (2016). ISSN : 14248220. DOI : [10.3390/s16081222](https://doi.org/10.3390/s16081222) (cf. p. 52).
- [165] R. N. SAHOO, S. S. RAY et K. R. MANJUNATH. « Hyperspectral remote sensing of agriculture ». In : *Current Science* 108.5 (2015), p. 848–859. ISSN : 00113891 (cf. p. 33).
- [166] Martin SANDMANN, Rita GROSCHE et Jan GRAEFE. « The Use of Features from Fluorescence, Thermography, and NDVI Imaging to Detect Biotic Stress in Lettuce ». In : *Plant Disease* 102.June (2018), p. 1101–1107. DOI : [10.1094/PDIS-10-17-1536-RE](https://doi.org/10.1094/PDIS-10-17-1536-RE) (cf. p. 31).
- [167] Sindhuja SANKARAN, Ashish MISHRA, Reza EHSANI et Cristina DAVIS. « A review of advanced techniques for detecting plant diseases ». In : *Computers and Electronics in Agriculture* 72.1 (2010), p. 1–13. ISSN : 01681699. DOI : [10.1016/j.compag.2010.02.007](https://doi.org/10.1016/j.compag.2010.02.007). URL : <http://dx.doi.org/10.1016/j.compag.2010.02.007> (cf. p. 33).
- [168] Abraham SAVITZKY et Marcel J. E. GOLAY. « Smoothing and Differentiation of Data by Simplified Least Squares Procedures ». In : *Analytical Chemistry* 36.8 (1964), p. 1627–1639. ISSN : 00032700. DOI : [10.1021/ac60214a047](https://doi.org/10.1021/ac60214a047) (cf. p. 137, 149).
- [169] Frédéric SCHMIDT, Albrecht SCHMIDT, Erwan TRÉGUIER, Maël GUIHENEUF, Saïd MOUSSAOUI et Nicolas DOBIGEON. « Implementation strategies for hyperspectral unmixing using Bayesian source separation ». In : *IEEE Transactions on Geoscience and Remote Sensing* 48.11 (2010), p. 4003–4013. ISSN : 01962892. DOI : [10.1109/TGRS.2010.2062190](https://doi.org/10.1109/TGRS.2010.2062190). arXiv : [1001.0499](https://arxiv.org/abs/1001.0499) (cf. p. 138).
- [170] Hans Reiner SCHULTZ. « Exploring the sensitivity of thermal imaging for *Plasmopara viticola* pathogen detection in grapevines under different water status ». In : *Functional Plant Biology* February (2015). DOI : [10.1071/FP07204](https://doi.org/10.1071/FP07204) (cf. p. 30).
- [171] Marco SEELAND, Michael RZANNY, Nedal ALAQRAA et Jana WA. « Plant species classification using flower images—A comparative study of local feature representations ». In : *PLoS ONE* (2017), p. 1–29. DOI : [10.7910/DVN/QDHYST](https://doi.org/10.7910/DVN/QDHYST) (cf. p. 49).
- [172] Ramprasaath R. SELVARAJU, Michael COGSWELL, Abhishek DAS, Ramakrishna VEDANTAM, Devi PARIKH et Dhruv BATRA. « Grad-CAM : Visual Explanations from Deep Networks via Gradient-Based Localization ». In : *Proceedings of the IEEE International Conference on Computer Vision 2017-October* (2017), p. 618–626. ISSN : 15505499. DOI : [10.1109/ICCV.2017.74](https://doi.org/10.1109/ICCV.2017.74). arXiv : [1610.02391](https://arxiv.org/abs/1610.02391) (cf. p. 103).
- [173] Sourabh SHRIVASTAVA, Satish Kumar SINGH et D S HOODA. « Soybean plant foliar disease detection using image retrieval approaches ». In : *Multimedia Tools and Applications* (2017), p. 26647–26674. DOI : [10.1007/s11042-016-4191-7](https://doi.org/10.1007/s11042-016-4191-7) (cf. p. 49).

- [174] Li SHUXIAN. « Modélisation spatio-temporelle pour l'esca de la vigne à l'échelle de la parcelle ». Thèse de doct. 2015 (cf. p. 42).
- [175] Karen SIMONYAN, A VEDALDI et A ZISSERMAN. *Deep Fisher Networks for Large-Scale Image Classification*. Rapp. tech. iii. 2013, p. 1–9. URL : <http://papers.nips.cc/paper/4926-deep-fisher-networks-for-large-scale-image-classification> (cf. p. 53).
- [176] Karen SIMONYAN, Andrea VEDALDI et Andrew ZISSERMAN. « Deep Inside Convolutional Networks : Visualising Image Classification Models and Saliency Maps ». In : (2013), p. 1–8. arXiv : 1312.6034. URL : <http://arxiv.org/abs/1312.6034> (cf. p. 103).
- [177] Karen SIMONYAN et Andrew ZISSERMAN. « Very deep convolutional network for large-scale image recognition ». In : *ICLR 2015*. 2015, p. 1–14. arXiv : arXiv:1409.1556v6 (cf. p. 93).
- [178] Josef SIVIC, Andrew ZISSERMAN et United KINGDOM. « Video Google : A Text Retrieval Approach to Object Matching in Videos ». In : *Proceedings of the Ninth IEEE International Conference on Computer Vision (ICCV'03)*. 2003. ISBN : 0769519504 (cf. p. 49, 77).
- [179] Srdjan SLADOJEVIC, Marko ARSENOVIC, Andras ANDERLA, Dubravko CULIBRK et Darko STEFANOVIC. « Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification ». In : *Computational Intelligence and Neuroscience 2016*. June (2016), p. 1–11. ISSN : 16875273. DOI : 10.1155/2016/3289801. URL : <http://www.hindawi.com/journals/cin/2016/3289801/> (cf. p. 51).
- [180] Jorge SOFIA, Maria Teresa GONÇALVES et Helena OLIVEIRA. « Spatial distribution of esca symptomatic plants in Dão vineyards (Centre Portugal) and isolation of associated fungi ». In : *Phytopathologia Mediterranea* 45.SUPPL. 1 (2006). ISSN : 00319465 (cf. p. 42).
- [181] Lorenzo SPARAPANO, Giovanni BRUNO et Antonio GRANITI. « Three-year observation of grapevines cross-inoculated with esca-associated fungi ». In : *Phytopathologia Mediterranea* 40 (2001), p. 376–386 (cf. p. 9).
- [182] J SPINOSI, J FEVOTTE et G VIAL. *Éléments techniques sur l'exposition professionnelle aux pesticides arsenicaux*. Rapp. tech. Institut de veille sanitaire Saint-Maurice (Fra), 2009, p. 19 (cf. p. 8).
- [183] Ethan L STEWART et Bruce A MCDONALD. « Measuring Quantitative Virulence in the Wheat Pathogen ». In : *Plant Pathology* 104.9 (2014), p. 985–992 (cf. p. 46).
- [184] Yu SUN, Yuan LIU, Guan WANG et Haiyan ZHANG. « Deep Learning for Plant Identification in Natural Environment ». In : *Computational Intelligence and Neuroscience 2017* (2017). DOI : 10.1155/2017/7361042 (cf. p. 51).
- [185] G SURICO. « Epidemiology of esca in some vineyards in Tuscany (Italy) ». In : (2000), p. 190–205 (cf. p. 18).
- [186] Giuseppe SURICO. « Towards a redefinition of the diseases within the esca complex of grapevine ». In : *Phytopathologia Mediterranea* 48 (2009), p. 5–10 (cf. p. 8, 17).

- [187] Giuseppe SURICO, Laura MUGNAI et Guido MARCHI. « Older and more recent observations on esca : a critical overview ». In : *Phytopathologia Mediterranea* 45 (2006), p. 68–86 (cf. p. 17, 18).
- [188] JingLei TANG, Dong WANG, ZhiGuang ZHANG, LiJun HE, Jing XIN et Yang XU. « Weed identification based on K-means feature learning combined with convolutional neural network ». In : *Computers and Electronics in Agriculture* 135 (2017), p. 63–70. ISSN : 0168-1699. DOI : <https://doi.org/10.1016/j.compag.2017.01.001>. URL : <http://www.sciencedirect.com/science/article/pii/S016816991630641X> (cf. p. 52).
- [189] E Castelão TETILA, B Brandoli MACHADO, N A D. S. BELETE, D A GUIMARÃES et H PISTORI. « Identification of Soybean Foliar Diseases Using Unmanned Aerial Vehicle Images ». In : *IEEE Geoscience and Remote Sensing Letters* 14.12 (2017), p. 2190–2194. ISSN : 1545-598X. DOI : [10.1109/LGRS.2017.2743715](https://doi.org/10.1109/LGRS.2017.2743715) (cf. p. 26).
- [190] Edna Chebet TOO, Li YUJIAN, Sam NJUKI et Liu YINGCHUN. « A comparative study of fine-tuning deep learning models for plant disease identification ». In : *Computers and Electronics in Agriculture* (2018), p. –. ISSN : 0168-1699. DOI : <https://doi.org/10.1016/j.compag.2018.03.032>. URL : <https://www.sciencedirect.com/science/article/pii/S0168169917313303> (cf. p. 52).
- [191] Jorge TORRES-SANCHEZ, Francisca LOPEZ-GRANADOS, Ana Isabel DE CASTRO et José Manuel PENA-BARRAGAN. « Configuration and Specifications of an Unmanned Aerial Vehicle (UAV) for Early Site Specific Weed Management ». In : *PLoS ONE* 8.March (2013). DOI : [10.1371/journal.pone.0058210](https://doi.org/10.1371/journal.pone.0058210) (cf. p. 27).
- [192] Fuan TSAI et William PHILPOT. « Derivative analysis of hyperspectral data ». In : *Remote Sensing of Environment* 66.1 (1998), p. 41–51. ISSN : 00344257. DOI : [10.1016/S0034-4257\(98\)00032-7](https://doi.org/10.1016/S0034-4257(98)00032-7) (cf. p. 152).
- [193] Nicolas VANDENBROUCKE, Ludovic MACAIRE et Jack-Gérard POSTAIRE. « Color image segmentation by pixel classification in an adapted hybrid color space. Application to soccer image analysis ». In : *Computer Vision and Image Understanding* 90.2 (2003), p. 190–216. ISSN : 1077-3142. DOI : [https://doi.org/10.1016/S1077-3142\(03\)00025-0](https://doi.org/10.1016/S1077-3142(03)00025-0). URL : <http://www.sciencedirect.com/science/article/pii/S1077314203000250> (cf. p. 71).
- [194] Andrea VEDALDI et Stefano SOATTO. « Quick Shift and Kernel Methods for Mode Seeking ». In : *Proc. ECCV*. 2008 (cf. p. 146).
- [195] Pierre VIALA. *Esca*. 1926, p. 180 (cf. p. 8, 11).
- [196] Paul VIOLA, Mitsubishi ELECTRIC et Michael JONES. « Rapid Object Detection using a Boosted Cascade of Simple Features ». In : *Conference on computer vision and pattern recognition*. 2001 (cf. p. 107).
- [197] Jim VOGELMANN, B N. ROCK et D M Moss. « Red edge spectral measurements from sugar maple leaves ». In : *Int. J. Remote Sens.* 14 (1993) (cf. p. 162).
- [198] Moller W.J., Kasimatis A.N. et Kissler J.J. *A dying arm disease of grape in California [Eutypa armeniacae]*. English. 1974 (cf. p. 8).

- [199] Jana WÄLDCHEN et Patrick MADER. *Plant Species Identification Using Computer Vision Techniques : A Systematic Literature Review*. T. o. o. Springer Netherlands, 2017, p. o. ISBN : 0123456789. DOI : [10.1007/s11831-016-9206-z](https://doi.org/10.1007/s11831-016-9206-z) (cf. p. 47).
- [200] Alexander WENDEL et James UNDERWOOD. « Illumination compensation in ground based hyperspectral imaging ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 129 (2017), p. 162–178. ISSN : 0924-2716. DOI : [10.1016/j.isprsjprs.2017.04.010](https://doi.org/10.1016/j.isprsjprs.2017.04.010). URL : <http://dx.doi.org/10.1016/j.isprsjprs.2017.04.010> (cf. p. 137).
- [201] Jon WEST, Roberto OBERTI et Dimitrios MOSHOU. « The Potential of Optical Canopy Measurement for Targeted Control of Field Crop Diseases ». In : *Annual Review of Phytopathology* 41. February (2003). DOI : [10.1146/annurev.phyto.41.121702.103726](https://doi.org/10.1146/annurev.phyto.41.121702.103726) (cf. p. 23).
- [202] Peter WILF, Shengping ZHANG, Sharat CHIKKERUR, Stefan A. LITTLE, Scott L. WING et Thomas SERRE. « Computer vision cracks the leaf code ». In : *Proceedings of the National Academy of Sciences* 113.12 (2016), p. 3305–3310. ISSN : 0027-8424. DOI : [10.1073/pnas.1524473113](https://doi.org/10.1073/pnas.1524473113). URL : <http://www.pnas.org/lookup/doi/10.1073/pnas.1524473113> (cf. p. 49).
- [203] Patrick WSPANIALY et Medhat MOUSSA. « Early powdery mildew detection system for application in greenhouse automation ». In : *Computers and Electronics in Agriculture* 127 (2016), p. 487–494. ISSN : 01681699. DOI : [10.1016/j.compag.2016.06.027](https://doi.org/10.1016/j.compag.2016.06.027). URL : <http://dx.doi.org/10.1016/j.compag.2016.06.027> (cf. p. 47).
- [204] Chuanqi XIE et Yong HE. « Spectrum and Image Texture Features Analysis for Early Blight Disease Detection on Eggplant Leaves ». In : *Sensors* 16.5 (2016), p. 676. ISSN : 1424-8220. DOI : [10.3390/s16050676](https://doi.org/10.3390/s16050676). URL : <http://www.mdpi.com/1424-8220/16/5/676> (cf. p. 26).
- [205] A YACCOUB, J GERBORE, N MAGNIN, P CHAMBON, M.-C. DUFOUR, M.-F. CORIO-COSTET, R GUYONEAUD et P REY. « Ability of *Pythium oligandrum* strains to protect *Vitis vinifera* L., by inducing plant resistance against *Phaeomoniella chlamydospora*, a pathogen involved in Esca, a grapevine trunk disease ». In : *Biol. Control* 92 (2016), p. 7–16. DOI : [10.1016/j.biocontrol.2015.08.005](https://doi.org/10.1016/j.biocontrol.2015.08.005). URL : <https://hal.archives-ouvertes.fr/hal-01495810> (cf. p. 20).
- [206] A. ZANZOTTO, M. GARDIMAN, S. SERRA, D. BELLOTTO, F. BRUNO, F. GRECO et C. TRIVISANO. « The spatiotemporal spread of esca disease in a Cabernet Sauvignon vineyard : A statistical analysis of field data ». In : *Plant Pathology* 62.6 (2013), p. 1205–1213. ISSN : 00320862. DOI : [10.1111/ppa.12034](https://doi.org/10.1111/ppa.12034) (cf. p. 42).
- [207] P. J. ZARCO-TEJADA, A. BERJÓN, R. LÓPEZ-LOZANO, J. R. MILLER, P. MARTÍN, V. CACHORRO, M. R. GONZÁLEZ et A. DE FRUTOS. « Assessing vineyard condition with hyperspectral indices : Leaf and canopy reflectance simulation in a row-structured discontinuous canopy ». In : *Remote Sensing of Environment* 99.3 (2005), p. 271–287. ISSN : 00344257. DOI : [10.1016/j.rse.2005.09.002](https://doi.org/10.1016/j.rse.2005.09.002) (cf. p. 162).
- [208] Pablo J ZARCO-TEJADA, John R MILLER, Gina H MOHAMMED et Thomas L NOLAND. « Chlorophyll Fluorescence Effects on Vegetation Apparent Reflectance : I. Leaf-Level Measurements and Model Simulation ». In : *Remote Sensing of Environment* 74.3 (2000), p. 582–595. ISSN : 0034-4257. DOI : <https://doi.org/10.1016/S0034->

4257(00)00148-6. URL : <http://www.sciencedirect.com/science/article/pii/S0034425700001486> (cf. p. 162).

- [209] Liang ZHENG, Yi YANG et Qi TIAN. « SIFT Meets CNN : A Decade Survey of Instance Retrieval ». In : *IEEE Transactions on pattern analysis and machine intelligence* 40.5 (2018), p. 1224–1244 (cf. p. 53).

Cinquième partie

ANNEXES



PUBLICATION ANALYSE DE LA RÉPARTITION DE LA FLAVESCENCE DORÉE

Journal of Agricultural Informatics (ISSN 2061-862X) 2017 Vol. 8, No. 2:1-11

Hungarian Association of Agricultural Informatics
European Federation for Information Technology in Agriculture,
Food and the Environment

Journal of Agricultural Informatics, Vol. 8, No. 2
journal.magisz.org

Spatial pattern analysis of flavescence dorée repartition in vineyards from the Bordeaux region

Florian Rançon¹, Lionel Bombrun², Barna Keresztes³, Christian Germain⁴

INFO

Received 26 May 2017
Accepted 2 Aug 2017
Available on-line 14 Aug 2017
Responsible Editor: M. Herdon

Keywords:

Flavescence dorée, Vine-growing, Epidemics, Geostatistics

ABSTRACT

The devastating incidence of flavescence dorée on vineyards throughout the world motivates for a better comprehension of this epidemic disease. In this study, we highlight the characteristic spatial non-random distribution of flavescence dorée diseased plants on a set of 7 vineyards from the Bordeaux region. First, we propose a simple statistical framework using Monte-Carlo simulations in order to assess the randomness of the disease repartition. Several statistics are considered such as the mean distance to the nearest diseased neighbor or divergence (using Kullback-Leibler dissimilarity symmetric variant) of the distance histogram to the average distance histogram of random simulations. The performance of these statistics is first evaluated on a set of generated repartitions at different randomness levels using ROC curves as a visual representation of the risks associated with the test. Histogram comparison was found to be more effective and robust for the detection of non-random configurations. The proposed algorithm is then used on real data, showing significant aggregations patterns and edge effect on some of the plots for flavescence dorée diseased plants but also uprooted plants.

1. Introduction

First reported in the French vineyards in the second half of the twentieth century (Caudwell 1957), Flavescence dorée (FD) is a quarantine disease with huge consequences on the vine-growing economy, including yield loss and degraded grape quality. It is caused by a phytoplasma vectored by the leafhopper species *Scaphoideus titanus*, making it an epidemiologic disease whose threat stems from fast propagation in the vineyard. Thus, insecticide treatment is mandatory in grapegrowing areas where the disease is widespread. Vineyards contaminated at a rate superior than 20% are rogued to stop the disease spreads. Affected vines show summer foliar symptoms depending on the cultivar, including yellowing and leaf curving (in a similar fashion as Bois noir disease) but also delayed or absent august hardening. Depending on the case, a short growth can also be observed during spring. Susceptibility to the disease seems to be highly cultivar-dependent and symptoms may not be shown with equal intensity (Caudwell 1990). FD was reported in most of the vinegrowing countries, including Italia (Vidano 1964), Switzerland (Schaerer et al. 2007) and Spain (Rahola et al. 1997). In France, FD is present in most vinegrowing areas, including the Bordeaux region (Bonfils & Schvester 1960), menacing vineyard durability. Knowledge and forecasting of the disease spread are closely related to its spatio-temporal repartition. Thus, a regional surveillance system may include the analysis of repartition data (collected from ground survey or from remotely-sensed data) to check for potential small aggregated structures that might be problematic for the vineyard over the next years.

¹ Florian Rançon

Bordeaux Sciences Agro Laboratoire IMS université de Bordeaux, France
florian.rancon@u-bordeaux.fr

² Lionel Bombrun

Bordeaux Sciences Agro Laboratoire IMS université de Bordeaux, France
lionel.bombrun@agro-bordeaux.fr

³ Barna Keresztes

Bordeaux Sciences Agro Laboratoire IMS université de Bordeaux
barna.keresztes@u-bordeaux.fr

⁴ Christian Germain

Bordeaux Sciences Agro Laboratoire IMS université de Bordeaux
christian.germain@agro-bordeaux.fr

In this work, we study the patterns associated with the FD presence in vineyards located in La Brède, France, presenting various infection levels and various cultivar combinations, focusing here on the spatial analysis of FD repartition in the end of summer 2016. For this purpose, expert ground survey indicating the precise locations of symptomatic plants is considered as a basis for repartition analysis. Another approach may be the use of Unmanned Aerial Vehicle (UAV) or satellite based technologies coupled with image processing techniques, such as in (Albetis et al. 2017). However, an automatic detection of symptomatic plants based on reddening or yellowing spots may lead to a large amount of unreliable detections (false positives), due to the complex diversity of grapevine diseases. Thus, in the following, we do not focus on this detection step and decide to use the expert map of symptomatic plants to study the spatial pattern analysis of FD repartition in vineyards.

Usually, the goal of spatial and temporal analysis is to exhibit the presence of spatial structures in the occurrences and propagation of symptomatic plants in a 2D space, which means the presence of non-random patterns. These popular methods in ecology fields (Velazquez et al. 2016) can also be applied to epidemics studies (Gatrell et al. 2009), due to the availability of field labeled data (position of symptomatic plants) spatialized on a lattice grid or in a GIS system. Examples include the study of disease patterns in tomato (Kawaguchi & Suenaga-Kanetani 2014) or mint (Johnson et al. 2006) fields. More specifically, pattern analysis applied on FD datasets was conducted in previous studies.

A first description of FD incidence was reported in (Pearson et al. 1985). More recently, (Morone et al. 2007) gathered 5 years of FD incidence in 7 severely affected vineyards in Piemonte, Italia, describing the temporal infectivity and recovery rates of the disease. (Beanland et al. 2006) used spatial analysis over an 8-year period and surveyed the abundance of leafhoppers using traps. Inspired by the works of (Gray et al. 1986) and (Nelson 1995), their proposed methodology consists in a statistical test based on the distance between two symptomatic plants, using random simulations in order to empirically estimate the distribution of the statistic under the null hypothesis. Significant clustering and nonrandom repartitions were reported in that study. Similarly, (Pavan et al. 2012) observed on 4 vineyards monitored over a 5-year period a significant border effect in the occurrences of the symptoms on some of the plots, using the nearest distance to an edge of the vineyard. On one vineyard and 5 years of data, (Maggi et al. 2017) used nearest-neighbor but also quadrat based statistics to show clustering behaviors on a multiscale level. The latter shows some similarity with Ripley's K function describing the spatial occurrences of a phenomenon in a given neighborhood (Besag 1977). A measure of the year-to-year isotropicity was also achieved but symptomatic plants seemed to progress in a non-isotropic way.

The first contribution of this paper is to adapt the nearest neighbor method, in a similar fashion as Ripley's K function, by considering the mean distance (rather than the number of occurrences) between an infected plant and its neighbors at a specific scale. The second contribution is the proposal of an empirical nonparametric method to detect non-random patterns. This latter is based on a hypothesis test whose statistic is computed as the Kullback-Leibler divergence between distance histograms. In the following, this statistic will be compared to two other ones based on distance histograms. The paper is structured as follows. Section 2 presents the methodology and the different statistics used. Section 3 presents the evaluation of the methods on generated non-random datasets. Section 4 and 5 present the results on real FD data acquired during summer 2016. Finally some conclusions and future works are drawn in Section 6.

2. Methodology

2.1. Principle of the randomness test

Similarly to the approach of (Beanland et al. 2006), randomness of the symptoms repartition is constructed as a simple statistical test. The test hypothesis can then be written as:

- H0: the spatial occurrences of the plants can be considered random.
- H1: the spatial occurrences aren't random.

To test this hypothesis, nonparametric statistics are often used in order to highlight significant clustering or dispersion patterns in the vineyard at different scales. In this paper, we follow a similar approach. In the case of FD, clustering is the most probable expected phenomenon. H_0 hypothesis means symptom presence at a given spot is uniformly probable. Thus in order to simulate random repartitions, we model each plant location in the vineyard as a random variable X with a Bernoulli distribution. Given the proportion f of observed symptomatic plants in the real data, the distribution of this random variable is given as:

$$\Pr(X = 1) = f, \Pr(X = 0) = 1 - f \text{ (equation 1)}$$

where 1 corresponds to the values of symptomatic locations and 0 to the values of non-symptomatic ones. It can be noted that, while the mean proportion of observed symptomatic plants per simulation tends towards f for a large number of repetitions, the individual proportion varies for each experiment (binomial distribution). In order to take into account the massive presence of missing plants in some of the plots, random simulations were conducted only on non-missing plants when considering the FD repartition.

Once the test statistic distribution has been estimated under the null hypothesis, the p-value of the test can be computed. If the p-value is lower than the significance level α (e.g. 5%), the H_0 hypothesis is rejected, meaning the spatial repartition is likely to be not random. However, there is a risk of an incorrect rejection of the null hypothesis (type I error or false positive) or an incorrect validation of the null hypothesis (type II error or false negative), meaning every decision comes with a risk.

The proposed test statistics must account for the natural variability of random configurations in a given scale and be sensitive to non-random patterns in the vineyards. Spatial structure is related to the distance between diseased plants at different scales. This means computing the whole distance matrix (full neighborhood) or only considering distances within a fixed radius (local neighborhood). This distance matrix allows the construction of a distance histogram which can then be summarized using two different statistics.

2.2. Statistic based on the mean distance to nearest-neighbor

The nearest-neighbor method (as used in (Maggi et al. 2017) and (Beanland et al. 2006)) reduces the search radius to the nearest observed symptomatic plants. This is an indicator of small scale spatial relationships between plants. Aggregated patterns (or positive spatial autocorrelation) will be characterized by low nearest-neighbor distance while negative spatial autocorrelation means high nearest-neighbor distance. Note that there is no radius for the nearest-neighbor method. To summarize, this approach extracts the shortest pairwise distances between symptomatic plants and uses the mean distance as a statistic, whose simple form can be written as:

$$S = \frac{\sum \text{shortest pairwise distances}}{n} \text{ (equation 2)}$$

where n is the number of observed symptomatic plants.

2.3. Statistic based on the mean distance to the neighbors in a radius

In order to obtain a better description, the mean distance to neighbors method uses a fixed radius to threshold the distance histogram and thus is a generalization of the nearest-neighbor statistic by considering a scale parameter. It can also be viewed as a variant of the Ripley's K function as used in (Maggi et al. 2017). Trends at larger scales (larger radius) can be encapsulated using the mean of that thresholded histogram. Similarly, small mean distance in a neighborhood may indicate a clustered structure in the dataset. Depending on the scale (radius), the significance of the test may vary, indicating aggregation patterns at specific scales. In that case, the statistic can be written in a simple form as:

$$S = \frac{\sum(\text{distances} < \text{radius})}{m} \text{ (equation 3)}$$

where m is the number of pairs separated by a distance lower than the radius threshold.

If we do not consider any threshold (i.e. infinite radius), m is equal to $\frac{n(n-1)}{2}$ since all the unique pairwise distances are used for the computation. For all the other cases, m depends on the threshold and on the actual symptom repartition. It is worth noting that Ripley's K at a given radius is proportional to m (Besag 1977).

2.4. Proposed histogram divergence statistic

However, when considering a mean distance value, information about the underlying distribution is lost. For that reason, we propose a statistic which takes into account the whole distance histogram. A measure of how far a given distance histogram is from an empirically estimated (again, using Monte-Carlo runs) distance histogram is thus needed. This is achieved using the Kullback-Leibler (KL) divergence (Kullback 1951) variant called Jensen-Shannon divergence (JSD) (Endres & Schindelin 2003). Given two continuous probability distribution p and q , the KL dissimilarity is computed as:

$$D_{KL}(q||p) = \int q(x) \log \frac{q(x)}{p(x)} dx \quad (\text{equation 4})$$

By working with discrete probability distributions P and Q , the KL divergence can then naturally be defined as:

$$D_{KL}(Q||P) = \sum_i Q(i) \log \frac{Q(i)}{P(i)} \quad (\text{equation 5})$$

Switching from continuous probability law to discrete histogram induces problematic cases where histogram count may be null, meaning potential division by zero. To overcome this issue, we remove zero values in the KL divergence computing. Using average distribution $M = \frac{P+Q}{2}$ allows us to compute the Jensen-Shannon divergence as:

$$JSD(Q, P) = \frac{D_{KL}(Q||M) + D_{KL}(P||M)}{2} \quad (\text{equation 4})$$

The JSD is similar to the standard KL but bears the advantage of being symmetric. Higher divergence values indicate high departure from the random histogram, meaning a one-tailed test can be set up using divergence histogram as the distribution under the null hypothesis. Similarly to the Ripley's function, results allow to check the CSR hypothesis at different sampling scales as illustrated in Figure 1, in which the radius corresponds to the maximal distances for which two infected plants are considered neighbors and thus are used to compute the statistic. Here, grey zone corresponds to the acceptance zone of the H_0 hypothesis (CSR).

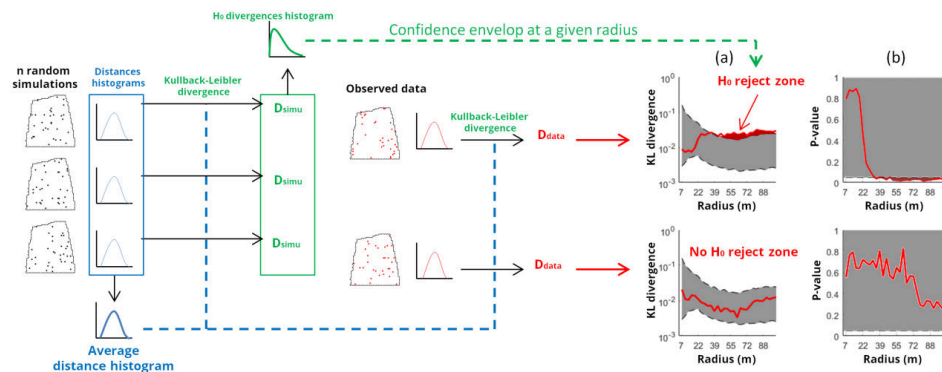


Figure 1. Schematic explanation of the repartition analysis at several distances using the JSD between histograms as test statistic. (a) - Observed statistic (red curve) at a given radius can be compared to its distribution (grey confidence envelop, 5% and 95% quantiles) under the null hypothesis in order to confirm or reject it. (b) – Evolution of the related p-value, the dashed line represents the significance level (here $\alpha = 5\%$).

In this paper, we use the euclidean distance as a measure of the distance between two plants. In the following sections, the above mentioned methods will be compared to simulated non-random datasets, then the one with the best performance will be applied on real datasets. All the experiments are conducted using the programming language MATLAB (R2015b, The MathWorks Inc.).

3. Results

3.1. Results on generated datasets

In this section, we wish to evaluate how well each method performs on datasets with different properties. An accurate method must be able to discriminate random repartitions from nonrandom ones with minimal risk. The proposed methods are first applied on simple datasets with for example distinctive aggregation (maximal positive autocorrelation on set 1 of Figure 2.a) and dispersion patterns (maximum negative autocorrelation on set 2). The aim of this experiment is to evaluate the potential of the proposed models to identify 10 non-random repartitions. Figure 2 presents the evolution of the three test statistics on 10 user-created sets (Figure 2.a) for different radiuses. Using the mean-distance (Figure 2.c) and the divergence statistic (Figure 2.d), all the datasets lead to the reject of the H0 hypothesis for most radiuses using an alpha risk of 1%. The only exception here is set number 2 with its uniform repartition. In that case, while the distribution can't be considered random, the mean-distance appears nearly identical as the ones computed for random datasets. Departure from random sets can be clearly seen using the nearest-neighbor statistic (Figure 2.b, very high mean distance to nearest neighbor) but also with the proposed histogram divergence statistic.

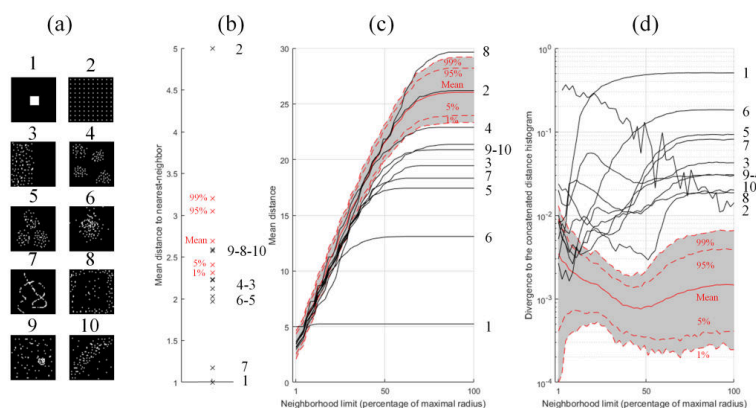


Figure 2. (a) 10 simulated dataset with non CSR property ($f=0.04$, 50×50 grid) (b) - Mean nearest-neighbor distance (unitless), (c) – Mean neighbors distance (unitless) and (d) - mean divergence (unitless) observed on the 10 datasets. Red lines correspond to the empirical quantities observed for random repartitions and different quantiles (potential H_0 reject values for a corresponding α risk), black lines correspond to the observed distances on the 10 datasets. For clarity, divergence axis is presented on a log-scale.

Methods are then applied to generated datasets with different properties. The symptom frequency f is considered here as the first critical parameter to take into account, the other one being the 'randomness level' (called r) of the repartition. Randomness is however hard to quantify. To obtain a quasi-continuous randomness level, we alter the uniformly equal random probability field under the H_0 hypothesis to generate intermediate states between total randomness and a fully determined state. This is done by adding another random field using 2D Gaussian negative and positive spots of random sizes and orientations. Examples of generated repartitions using this method are shown in Figure 3. Symptom frequency f was chosen to fit the naturally observed disease and missing plants frequencies (e.g. from 1% to 32% as illustrated in Figure 5). The r values were chosen using linearly sampled values ranging from 0 (deterministic field) to 1 (unaltered uniform random field).




Figure 3. Examples of generated symptom repartitions for 2 frequencies (f) and 6 randomness levels (r)

This approach can be used for different symptom frequencies and repeated (here, we use 500 repetitions per (f, r) couple to generate a wide array of repartitions) in order to obtain a set of simulated nonrandom repartitions. We can now compare totally random sets with non-random sets in order to assess the efficiency of the previously described methods.

In order to evaluate the discriminative ability of each method, we use ROC curves (Fawcett 2006), a popular machine-learning visualization tool, applied on the p-value of the statistical test. In that case, ROC curves serve as a visual illustration of the first and second order risks. For a given false alarm rate (proportion of false decisions induced by the test reject), ROC curves allow to determine the expected true alarm rate (proportion of true positives). The area under the curve (AUC) is also an indicator (ranging from 0 to 1) of how well random repartitions are separated from non-random ones. Figure 4 gives an illustration on the process behind the creation of ROC curves. Here values in red indicate the p-values obtained from random datasets while p-values in blue correspond to the ones obtained on non-random datasets. The best case means that it is possible to set a threshold to perfectly

separate random repartitions from non-random ones based on the computed p-values. In that case, the AUC is equal to 1.

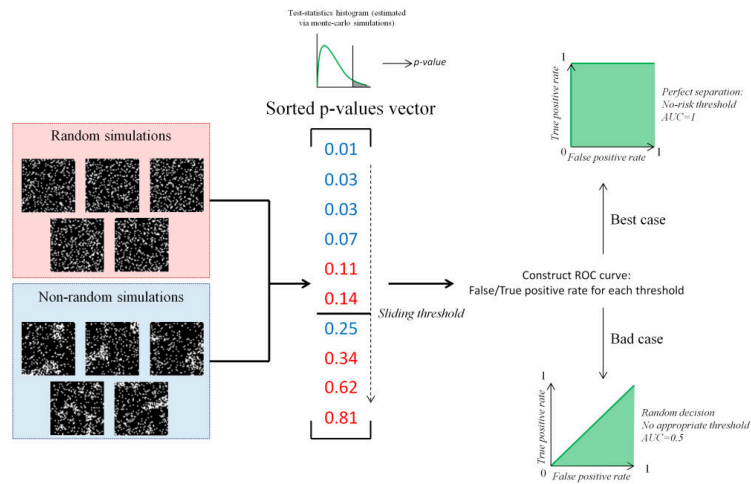


Figure 4. ROC curves generation methodology. AUC indicates how well non-random disease repartitions can be separated from random repartitions when fixing a critical p-value threshold to the test

Results on the generated datasets (f ranging from 0.01 to 0.32, $r=10$ randomness levels) can be consulted in Figure 5. Total randomness column compares random repartitions with random repartitions, thus all the ROC curves follow the $y=x$ line. For almost every set of parameters, the divergence statistic yields to the best AUC, meaning better ability to set apart random repartitions from non-random ones and more sets with close-to-zero risk ($AUC=1$) when rejecting the H_0 hypothesis. It also shows less sensitivity to the f parameter than the other two methods. As expected, the nearest-neighbor method tends to perform poorly on repartitions with high disease occurrences. In such case, the mean distance to the nearest diseased neighbor may be very low, and may lead in some cases to random decision ($AUC=0.5$). The nearest-neighbor method seems to be nearly as effective as the other methods if the local density of infected plants is not too high.

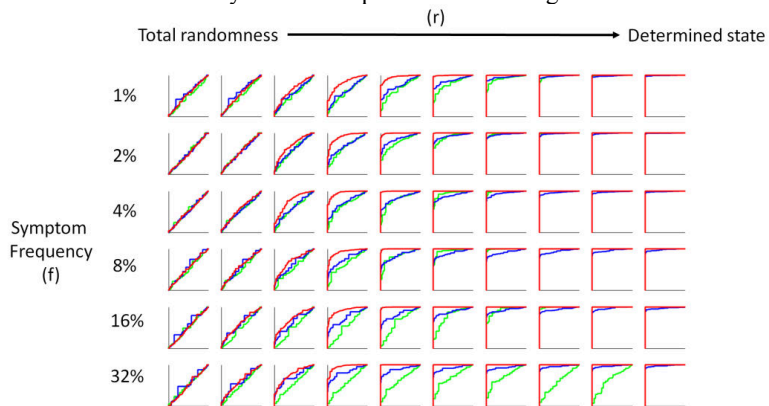


Figure 5. ROC curves computed for different (frequency, randomness) couples using nearest-neighbor distance statistics (green curves), local mean-distance statistics (blue curves) and local divergence statistics (red curves). Maximal radius was considered for this experiment

Since the proposed statistic based on the histogram divergence has shown the best performance on these datasets, this method will be used in the following on real FD dataset acquired on La Brède test site.

4. Results on real flavescence dorée data

4.1. Studied vineyards and field campaign

Experiments were conducted in 7 vineyard plots near La Brède in the Bordeaux region (Figure 6). In this region, FD occurrence was diminishing from 2012 to 2015 but it seemed on the rise since then. Average plant density in the vineyards is about 2000ha⁻¹. The vineyards exhibit various sizes, orientations and cultivar combinations combined with FD outbreaks.




Figure 6. Geographic location of the 7 study (L1 to L7) vineyards in the La Brède municipality (WGS 84 coordinates: -0° 31' 58.58", 44° 41' 29.87"), Nouvelle Aquitaine region, France. Satellite image: Google Earth.

The monitoring of FD symptoms was conducted during summer 2016, on September 8. The presence of FD was evaluated using a protocolar grid indicating FD severity on a 4 levels scale (from faint foliar symptoms to full foliar symptoms) and possible confusion risks with other diseases. Photographs of the symptomatic plants were also taken in order to check later on for these confusions. Figure 7 presents the result of the field campaign in a grid representation of the symptomatic and missing plants in the 7 vineyards. Using aerial imagery, gridded symptomatic plants positions were also georeferenced (relatively to the position of rows extrema observed on the aerial image) and included in a GIS software (QGIS 2.16), allowing a more precise distance measurements between symptomatic plants.




Figure 7. Grid view of the field notation campaign data. Gray pixels: Healthy Plants. Black pixels: Missing plants, Pink pixels: FD symptomatic plants.

Most missing plants in the vineyards likely come from former uprooted FD symptomatic plants. Vineyard L1 particularly bears the trace of previous epidemics, with a missing plant proportion superior to 50%. On the other vineyards, it ranges from 20% to 40%. FD symptom occurrences vary from one vineyard to another, ranging from 1% to 4% of the total sampled plants. Observed proportions are summarized in Table 1, as well as a list of the cultivars present in the vineyard.

Table 1 - Description of the 7 studied vineyards

| Vineyard | L1 | L2 | L3 | L4 | L5 | L6 | L7 |
|------------------------|---------------------------|-------------------------|--------------------------------|-----------------------------------|-------------------------|---------------------------|---------------------------|
| Cultivars | <i>Cabernet-Sauvignon</i> | <i>Merlot, Sémillon</i> | <i>Merlot, Sauvignon Blanc</i> | <i>Cabernet-Sauvignon, Merlot</i> | <i>Merlot, Sémillon</i> | <i>Cabernet-Sauvignon</i> | <i>Cabernet-Sauvignon</i> |
| Number of plants | 3084 | 1222 | 1688 | 1448 | 1103 | 1652 | 1603 |
| Number of rows | 25 | 15 | 22 | 12 | 17 | 43 | 26 |
| <i>Frequencies (f)</i> | | | | | | | |
| Healthy plants | 25.3% | 65.7% | 57.7% | 52.7% | 73.7% | 57.8% | 61.9% |
| Missing plants | 62.5% | 30.8% | 37.5% | 39.6% | 19.9% | 38.3% | 25.4% |
| Flavescence dorée | 2.4% | 2.8% | 1% | 2% | 4.1% | 2% | 1.6% |
| Other diseases | 9.8% | 0.7% | 3.8% | 5.7% | 2.3% | 1.9% | 11.1% |

Figure 8 summarizes the main results obtained on this dataset. Several tests are performed on the 7 studied vineyards using the best-performing methods previously described. The first test involves simple random hypothesis. It aims to determine if according to the spatial occurrences, the repartition can be considered as random. It is applied to FD plants (Figure 8.a), but also on missing plants (Figure 8.b). The second test aims at determining if a border effect is present in the vineyard (Figure 8.d), i.e. FD/missing plants are closer to the edges than in random repartitions. This is achieved using the nearest-neighbor statistic method, which is preferred here since only the distance to the nearest border is of interest. Eventually, we wish to know if a spatial relationship between FD symptoms locations and missing-plants location exists. For that purpose, we construct a test based on the divergence method, using the distance from FD affecting plants to missing plants, simulating both random repartitions (using respective *f* values) for each Monte-Carlo run (Figure 8.c).




Figure 8. Test statistics (red curves and points) obtained on the La Brède dataset. Values falling outside the grey confidence envelope (5% confidence) indicate H_0 reject and non-random behaviors. (a) to (c) test based on JSD (for varying threshold distances) while (d) considers the nearest-neighbor distance and thus is conducted without any distance threshold.

When setting the significance risk α to 5%, all the vineyards reject the null hypothesis for the missing plants repartition for small maximum distance (radius) indicating a nonrandom repartition, the reject was however not significant at large scale for plots 1 and 4. FD repartition was found to be nonrandom on plots 4 to 7, while plots 1 to 3 never reject the H_0 hypothesis. Similar interpretations

can be made for the edge effect test, featuring reject on 4 plots for FD repartition and all the 7 plots for the missing plants repartition, which supports the results of (Pavan et al. 2012) and (Maggi et al. 2017) on the observed edge effect in vineyards affected by FD. Tests considering the proximity of diseased plants with missing plants (Figure 8.c) yield reject on most vineyards at small scale except for plots 2 and 3, leading to the confirmation that missing plants and FD diseased plants are spatially linked, showing significant attraction patterns. The proximity with missing plants seems especially significant on vineyard 4 and 5 in which nonrandom patterns can be observed at small and large scales, which corroborates the visual observation of FD affected plants located nearby clusters of rogued out plants.

5. Discussion

While statistical non-parametric methods using Monte-Carlo simulations provide a flexible framework for the repartition analysis, several potential pitfalls remain. Important missing plants proportions are still an issue because they limit the potential number of possible locations for simulated symptoms, meaning fewer combinations and blurrier frontier between random and non-random patterns. This is the case for vineyards with more than half of missing plants such as vineyard number 1. Similarly, the joint presence of several cultivars in the vineyards calls for prudent interpretations. This doesn't apply to pure *Cabernet Sauvignon* plots such as 1, 6 and 7 but the other exhibit mixed cultivars, whose susceptibility to the disease may be different. The presence of a different cultivar on the border of the plot, such as in vineyard 5, may lead to the hypothesis reject because symptomatic plants are more frequent near this border and thus the repartition may not appear random. This study provides a repartition analysis tool which can be embedded into an epidemics surveillance system. Prior steps to the analysis may include ground field notation or more innovative tools such as satellite or UAV imagery, both used to obtain spatialized information about the disease repartition. Symptomatic plants positions can then be analyzed in order to check for potential threatening aggregations patterns, even for low FD prevalence.

6. Perspectives and conclusion

In this study, we have proposed a simple nonparametric statistical framework using a divergence histogram statistic taking into account the distance histogram in a given radius. Results on generated datasets indicate better separation between random repartitions and non-random ones using the divergence method. Better generation of simulated repartitions may include the control over specific aggregation patterns such as outbreak size or edge-effect. Applications on real FD data indicate significant non-random aggregation patterns on some of the studied plots, as well as an edge effect and a possible spatial correlation between missing plants and FD symptoms. This method could be applied to the temporal study of FD propagation, using yearly datasets. Spatial pattern studies could also be coupled with other exogenous variables such as spatial leafhopper abundance in the vineyard as in (Pavan et al. 2012).

7. Acknowledgement

This study has been carried out with financial support from the Région Nouvelle Aquitaine and the French State, managed by the French National Research Agency (ANR) in the frame of the "Investments for the future" Programme IdEx Bordeaux-CPU (ANR-10-IDEX-03-02). First author is financed by Fonds Unique Interministériel (FUI) ADVANTAGE driven by Vegepolys/ Agri Sud-Ouest Innovation and with support from Région Nouvelle Aquitaine/Bpifrance.

References

- Albetis, J. et al., 2017. Detection of Flavescence dorée Grapevine Disease Using Unmanned Aerial Vehicle (UAV) Multispectral Imagery. *Remote Sensing*, 9(4), p.308. <https://doi.org/10.3390/rs9040308>
- Beanland, L., Noble, R. & Wolf, T.K., 2006. Spatial and Temporal Distribution of North American Grapevine Yellows Disease and of Potential Vectors of the Causal Phytoplasmas in Virginia. *Environmental Entomology*, 35(2), pp.332–344. <https://doi.org/10.1603/0046-225X-35.2.332>

- Besag, J., 1977. Contribution to the discussion of Dr Ripley's paper. *Journal of the Royal Statistical Society*, 39(2), pp.193–195.
- Bonfils, J. & Schvester, D., 1960. Les cicadelles (Homoptera Auchenorrhyncha) dans leurs rapports avec la vigne dans le sud-ouest de la France. *Ann Epiphyt*, 3, pp.325–336.
- Caudwell, A., 1957. Deux années d'études sur la flavescence dorée nouvelle maladie grave de la vigne, Paris: Institut National de la Recherche agronomique.
- Caudwell, A., 1990. Epidemiology and characterization of flavescence dorée (FD) and other grapevine yellows. *Agronomie*, 10(8), pp.655–663. <https://doi.org/10.1051/agro:19900806>
- Endres, D.M. & Schindelin, J.E., 2003. A new metric for probability distributions. *IEEE Transactions on Information Theory*, 49(7), pp.1858–1860. <https://doi.org/10.1109/TIT.2003.813506>
- Fawcett, T., 2006. An introduction to ROC analysis. , 27, pp.861–874.
- Gatrell, A.C. et al., 2009. Spatial point analysis and its application in geographical epidemiology. *Transactions of the Institute of British Geographer*, 21(1), pp.256–274. <https://doi.org/10.2307/622936>
- Gray, S.M., Moyer, J.W. & Bloomfield, P., 1986. Two-dimensional distance class model for quantitative description of virus-infected plant distribution lattices. *Phytopathology*, 76(2), pp.243–248. <https://doi.org/10.1094/Phyto-76-243>
- Johnson, D., Zhang, H. & Alldredge, J.R., 2006. Spatial pattern of verticillium wilt in commercial mint fields. *Plant disease*, 789-797(June). <https://doi.org/10.1094/PD-90-0789>
- Kawaguchi, A. & Suenaga-Kanetani, H., 2014. Spatiotemporal distribution of tomato plants naturally infected with leaf mold in commercial greenhouses. *Journal of General Plant Pathology*, 80(5), pp.430–434. <https://doi.org/10.1007/s10327-014-0539-x>
- Kullback, S., 1951. on Information and Sufficiency. *The Annals of Mathematical Statistics*, 22(1), pp.79–86. <https://doi.org/10.1214/aoms/1177729694>
- Maggi, F. et al., 2017. Space-Time Point Pattern Analysis of Flavescence Dorée Epidemic in a Grapevine Field: Disease Progression and Recovery. *Frontiers in Plant Science*, 7(January). <https://doi.org/10.3389/fpls.2016.01987>
- Morone, C. et al., 2007. Epidemiology of flavescence dorée in vineyards in northwestern Italy. *Phytopathology*, 97, pp.1422–1427. <https://doi.org/10.1094/PHYTO-97-11-1422>
- Nelson, S.C., 1995. Spatiotemporal distance class analysis of plant disease epidemics. *Phytopathology*, 85(1), pp.37–43. <https://doi.org/10.1094/Phyto-85-37>
- Pavan, F. et al., 2012. Border effect in spatial distribution of flavescence dorée affected grapevines and outside source of *Scaphoideus titanus* vectors. *Bulletin of Insectology*, 65(2), pp.281–290.
- Pearson, R.C. et al., 1985. Occurrence of flavescence dorée-like symptoms on “White Riesling” grapevines in New York, U.S.A. *Phytopathologia Mediterranea*, 24(1/2), pp.82–87.
- Rahola, J. et al., 1997. La flavescencia dorada en los viñedos del Alt Empordà (Girona). *Bol Sanid Veg Plagas*, 23(403), p.416.
- Schaerer, S. et al., 2007. Flavescence dorée : la maladie et son extension. *Revue suisse Vitic. Arboric. Hortic.*, 39, pp.107–110.
- Velazquez, E. et al., 2016. An evaluation of the state of spatial point pattern analysis in ecology. *Ecography*, 39(11), pp.1042–1055. <https://doi.org/10.1111/ecog.01579>
- Vidano, C., 1964. Scoperta in Italia dello *Scaphoideus littoralis* Ball cicalina americana collegata alla Flavescence dorée della vite. *Ital Agric*, 101, pp.1031–1049.

DISTANCES ET SIMILARITÉS UTILISÉES

| Notes | Entrée | Formule |
|---|---------------------|---|
| <i>Distance Euclidienne</i> | u, v | $\sqrt{\sum_{i=1}^n (u_i - v_i)^2}$ |
| <i>Distance du χ^2</i> | u, v | $\sum_{i=1}^n \frac{(u_i - v_i)^2}{v_i}$ |
| <i>Similarité Spectral Angle Mapper</i> | u, v | $\arccos \left(\frac{\sum_{i=1}^n u_i v_i}{\sqrt{\sum_{i=1}^n u_i^2} \cdot \sqrt{\sum_{i=1}^n v_i^2}} \right)$ |
| <i>Distance de Mahalanobis</i> | $u, N(\mu, \Sigma)$ | $\sqrt{(u - \mu)^t \Sigma^{-1} (u - \mu)}$ |
| <i>Divergence de Kullback-Leibler</i> | P, Q | $\sum_i \log(p_i/q_i) p_i$ |

C.1 MATRICE DE CONFUSION

Pour un problème de classification, parmi les échantillons dont on prédit la classe, on rencontrera vraisemblablement de bonnes et de mauvaises classifications. Si on se concentre sur une classe donnée, 4 scénarios sont possibles :

- Vrai Positif (VP) : Échantillon appartenant à la classe donnée et **bien prédit**
- Vrai Négatif (VN) : Échantillon n'appartenant pas à la classe donnée et **bien prédit**
- Faux Positif (FP) : Échantillon n'appartenant pas à la classe donnée et **mal prédit**
- Faux Négatif (FN) : Échantillon appartenant à la classe donnée et **mal prédit**

Ces mesures sont souvent représentées dans ce qu'on appelle la matrice de confusion (figure C.1). La diagonale y représente les bonnes détections. La matrice de confusion peut aussi être généralisée au problème multi-classes, les éléments sur la diagonale représentent alors le nombre d'échantillons d'une classe ayant été correctement prédits.

| | | Prédiction | |
|--------------|---|--------------|--------------|
| | | 0 | 1 |
| Vraie classe | 0 | Vrai Négatif | Faux Positif |
| | 1 | Faux Négatif | Vrai Positif |

Figure C.1 – Matrice de confusion pour un problème de classification binaire entre la classe 0 (classe de référence) et la classe 1 (classe d'intérêt)

La différence entre un FP et un FN est importante car, selon l'application, on peut vouloir limiter le nombre de fausses détections ou au contraire détecter tout, quitte à provoquer des faux positifs. On peut simplifier la situation en considérant le nombre de bonnes détections $V = VP + VN$ et de mauvaises détections $F = FP + FN$.

Les courbes *Caractéristiques Opérationnelles de Réception* (ROC) et *Rappel/Précision* (RP) sont deux outils complémentaires permettant de mesurer les performances d'un classifieur pour une classe donnée selon la variation d'un paramètre (le plus souvent le score de détection). Dans les deux cas, elles permettent de rendre compte d'un compromis entre deux qualités recherchées et de comparer plusieurs expériences selon ce critère.

C.2 COURBES ROC

Considérons un cas unidimensionnel (utilisation d'un capteur fournissant une mesure scalaire par exemple). On modélise ici la répartition des valeurs mesurées par deux gaussiennes de même écart type mais de moyennes différentes. Selon la différence entre les deux moyennes, les deux densités de probabilités peuvent être quasi confondues ou au contraire quasidisjointes. C'est ce que présente la figure C.2 en présentant une mauvaise et une bonne séparation entre les deux distributions.




Figure C.2 – Séparabilité de deux gaussiennes

Les courbes ROC (utilisées dans le chapitre [chapitre 8](#) sur la donnée hyperspectrale) illustrent alors le compromis entre les taux de faux positifs et les taux de vrais positifs. Les points de la courbe sont ainsi formés en faisant varier le seuil de classification. Le graphique résultant permet d'estimer visuellement la qualité de la classification et le lien entre taux de vrais positifs et taux de faux positifs (figure C.3). La mesure d'Aire sous la Courbe (AUC) nous donne alors un résumé quantitatif de la discrimination entre les deux classes (50% pour un choix aléatoire, 100% pour un classifieur parfait).

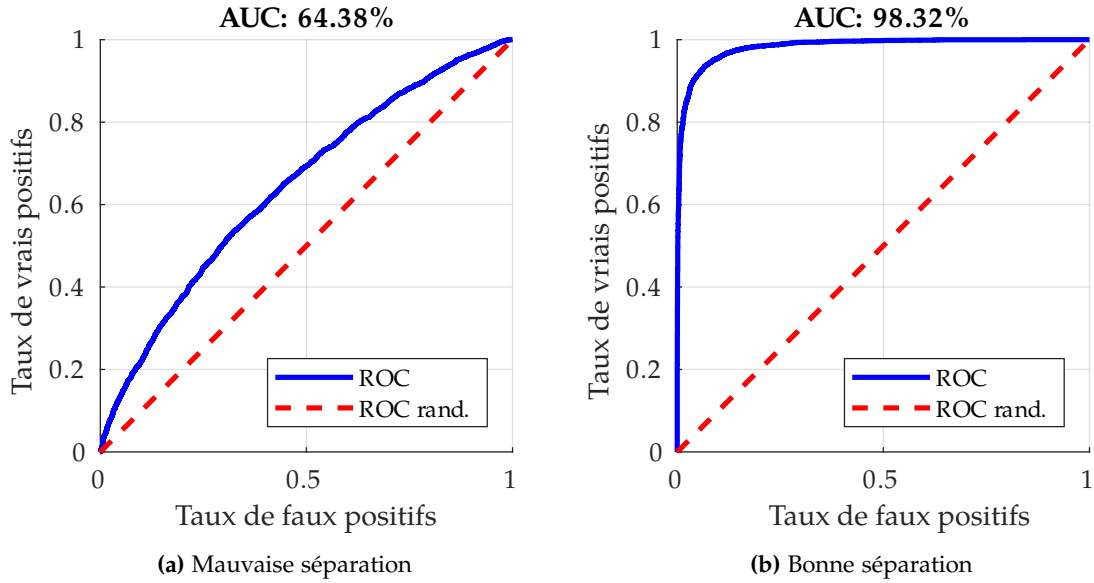


Figure C.3 – Courbes ROC dans le cas d’une bonne et une mauvaise séparation entre les distributions gaussiennes

Afin de fixer un seuil optimal pour la classification, on peut soit fixer un taux minimal de vrais positifs soit un taux maximal de faux positifs puis récupérer le meilleur seuil correspondant.

C.3 COURBES RP

La courbe RP (utilisée dans la partie détection de symptômes visibles au [chapitre 6](#)) illustre quant à elle le compromis entre la proportion des échantillons d’une classe détectés et la proportion de bonnes classifications liée. Ainsi, détecter la totalité des échantillons d’une classe risque de se faire au détriment de nombreux faux positifs. De la même manière que pour la courbe ROC, la courbe est construite en faisant varier le seuil sur le score de classification. Le graphique résultant montre ainsi l’évolution de la précision avec le rappel (figure C.4). La précision diminue le plus souvent à mesure que l’on augmente le rappel mais la courbe n’est cependant pas strictement décroissante. Une moyenne pondérée de la précision (AP) peut alors être proposée pour résumer la courbe. Un AP égal à 100% signifierait ainsi que tous les échantillons peuvent être rappelés sans qu’un seul faux positif ne soit constaté.

$$AP = \sum_{i=1}^n (R_i - R_{i-1})P_i \quad (25)$$

où n est le nombre d’échantillons rappelables (le nombre d’échantillons annotés qui ont une détection associée, quelque soit son score).

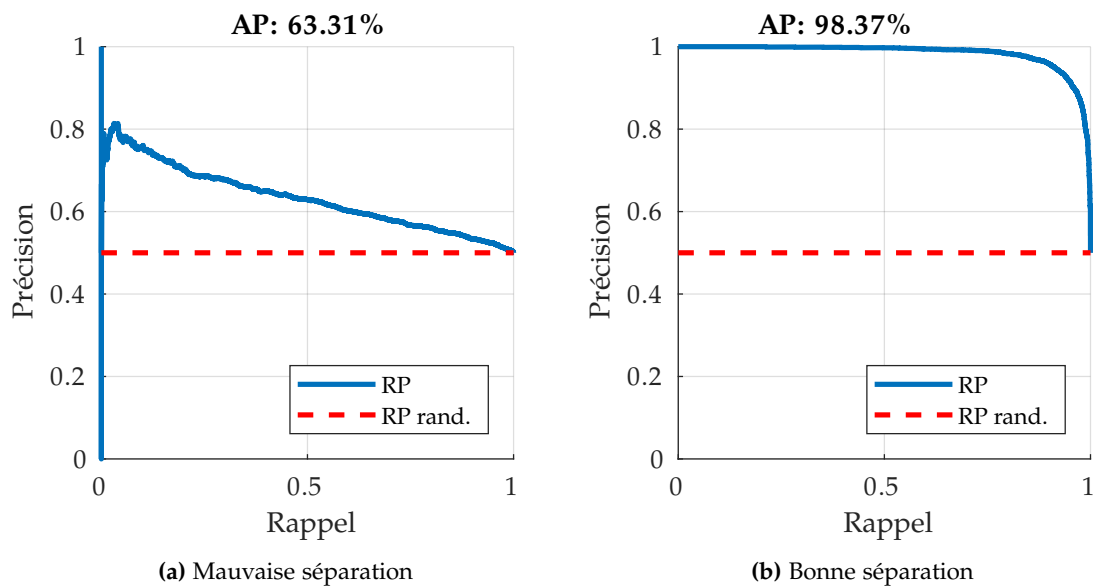


Figure C.4 – Courbes RP dans le cas d’une bonne et une mauvaise séparation entre les distributions gaussiennes

De la même façon que pour les courbes ROC, il est possible de fixer un seuil optimal respectant les exigences du problème sur la proportion d’échantillons à rappeler ou la précision liée.

Cette annexe détaille les formules des 10 indices de végétation utilisés dans le [chapitre 8](#).

Tableau D.1 – Détail des indices de végétation utilisés dans le manuscrit. R₇₅₀ signifie par exemple la valeur mesurée à 750nm.

| Nom | Formule |
|---|--|
| NDVI (Normalized Difference Vegetation Index) | $\frac{R_{IR} - R}{R_{IR} + R}$ |
| MCARI (Modified Chlorophyll Absorption in Reflectance Index) | $1.2(2.5(R_{800} - R_{670}) - 1.3(R_{800} - R_{550}))$ |
| VOG (Vogelmann index) | $\frac{R_{740}}{R_{720}}$ |
| VREI₂ (Vogelmann Red Edge Index 2) | $\frac{R_{734} - R_{747}}{R_{715} + R_{726}}$ |
| MRENDVI (Modified Red Edge Normalized Difference Vegetation Index) | $\frac{R_{750} \cdot R_{705}}{R_{750} + R_{705} - 2 \cdot R_{745}}$ |
| TCARI (Transformed Chlorophyll Absorption Reflectance Index) | $3 * (R_{700} - R_{670}) - 0.2 * (R_{700} - R_{550}) * \left(\frac{R_{700}}{R_{670}}\right)$ |
| CUR (Curvature Index) | $\frac{R_{675} * R_{690}}{R_{683}^2}$ |
| G (Greenness) | $\frac{R_{544}}{R_{677}}$ |
| BGI (Blue green pigment index) | $\frac{R_{405}}{R_{550}}$ |
| CTR (Carter Index) | $\frac{R_{695}}{R_{420}}$ |

