



**HAL**  
open science

# Potentialités de l'imagerie couleur embarquée pour la détection et la cartographie des maladies fongiques de la vigne

Florent Abdelghafour

► **To cite this version:**

Florent Abdelghafour. Potentialités de l'imagerie couleur embarquée pour la détection et la cartographie des maladies fongiques de la vigne. Physique [physics]. Université de Bordeaux, 2019. Français. NNT : 2019BORD0430 . tel-02499420

**HAL Id: tel-02499420**

**<https://theses.hal.science/tel-02499420>**

Submitted on 5 Mar 2020

**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 PHYSIQUE ET DE L'INGÉNIEUR

SPÉCIALITÉ: AUTOMATIQUE, PRODUCTIQUE, SIGNAL ET IMAGE, INGÉNIERIE  
COGNITIVE

Par **Florent ABDELGHAFOR**

**Potentialités de l'imagerie couleur embarquée pour la  
détection et la cartographie des maladies fongiques de la  
vigne**

Sous la direction de : **Jean-Pierre DA COSTA**

Co-directeur : **Christian GERMAIN**

Soutenue le 20 Décembre 2020

Membres du jury:

M. <b>BARET, Frédéric</b>	Directeur de Recherche, INRA Avignon	Président
M. <b>RABATEL, Gilles</b>	Directeur de Recherche, IRSTEA Montpellier	Rapporteur
M. <b>CARRÉ, Philippe</b>	Professeur, Université de Poitiers	Rapporteur
M. <b>DA COSTA, Jean-Pierre</b>	Professeur, Bordeaux Sciences Agro	Directeur
M. <b>GERMAIN, Christian</b>	Professeur, Bordeaux Sciences Agro	Co-directeur
M. <b>RAYNAL, Marc</b>	Ingénieur, Institut Français de la Vigne	Membre invité



---

## Unité de recherche

IMS - Laboratoire de l'Intégration du Matériau au Système, UMR 5218

351 Cours de la Libération, 33405 Talence cedex, France.





---

## Remerciements

---

Mes premiers remerciements s'adressent à mes deux directeurs de thèse, Jean-Pierre Da Costa et Christian Germain, qui ont fait en sorte que cette thèse soit une expérience à la fois enrichissante et agréable. Merci d'avoir montré de la patience, de l'enthousiasme et de la sympathie. Je ne peux me soustraire à remercier également ma famille, pour son soutien inconditionnel, ainsi que pour les nombreuses victuailles d'outre méditerranée.

Un grand merci à tous les collègues du groupe Signal et Image de l'IMS pour les nombreuses discussions scientifiques et d'autres plus légères. Merci Barna, Roxana, Jean-Marie, Florian, Lionel, Romain, Quentin, Isabel, Ming-Ming, John, Cyril, Issam, Loris ou encore Jean-Michel Bayanis.

« Le soleil, avec toutes ces planètes qui gravitent sous sa gouverne, prend encore le temps de mûrir une grappe de raisin, comme s'il n'y avait rien de plus important. »

Galileo Galilei



---

# Table des matières

---

<b>Introduction</b>	<b>1</b>
<b>1 Etat de l'art</b>	<b>5</b>
1.1 La vigne : botanique, physiologie et pratiques culturales . . . . .	5
1.2 Les pathologies de la vigne . . . . .	7
1.3 Le mildiou de la vigne : biologie, symptômes et moyens de lutte . . . . .	9
1.4 L'épidémiosurveillance dans le contexte viticole : enjeux et méthodes actuelles	14
1.5 Potentialités des méthodes optiques pour le suivi des phytopathologies . . . .	16
1.6 L'analyse d'images couleurs : des méthodes exploitant les motifs spatiaux distinctifs des symptômes visibles . . . . .	24
<b>2 Dispositif expérimental : matériel végétal, instrumentation et protocole de suivi</b>	<b>29</b>
2.1 Les parcelles d'études . . . . .	29
2.2 Instrumentation : un capteur embarqué autonome pour la cartographie sani- taire des vignobles . . . . .	34
2.3 Les images obtenues pour l'analyse de l'état sanitaire . . . . .	37
<b>3 Modéliser conjointement la texture et la couleur dans les images de proxi- détection</b>	<b>41</b>
3.1 La texture et ses méthodes d'analyse . . . . .	41
3.2 Le tenseur de structure local : un outil pour extraire et représenter l'informa- tion de texture . . . . .	44
3.3 Représentation et modélisation des LST . . . . .	46
3.4 Caractérisation de textures végétales par le tenseur de structure . . . . .	48
3.5 Modélisation paramétrique des tenseurs de structure . . . . .	54
3.6 Extraire et représenter l'information colorimétrique conjointement à l'infor- mation de structure . . . . .	61
3.7 Conclusion du chapitre : bilan de l'approche structure-couleur . . . . .	79

<b>4</b>	<b>Reconnaissance des organes de la vigne</b>	<b>81</b>
4.1	Introduction et objectifs du chapitre . . . . .	81
4.2	Pré-traitement : suppression de l'arrière plan par seuillage colorimétrique . .	82
4.3	Classification pixellaire : décision probabiliste . . . . .	85
4.4	Régularisation spatiale . . . . .	87
4.5	Analyse de la chaîne de traitement . . . . .	88
4.6	Conclusion du chapitre . . . . .	103
<b>5</b>	<b>Détection des symptômes du mildiou de la vigne et estimation de l'inten-</b>	
	<b>sité de l'infection</b>	<b>105</b>
5.1	Introduction . . . . .	105
5.2	Données d'apprentissage et de validation . . . . .	106
5.3	Limites de la classification par MAP pour la détection des symptômes du mildiou . . . . .	108
5.4	Reconstruction des symptômes du mildiou par hystérésis . . . . .	115
5.5	Conclusion du chapitre . . . . .	129
	<b>Conclusion et Perspectives</b>	<b>131</b>
	<b>Annexes</b>	<b>137</b>
	<b>Bibliographie</b>	<b>147</b>
	<b>Publications et actes de communication</b>	<b>163</b>

---

## Introduction

---

La surveillance épidémiologique est un enjeu central du développement durable de la production agricole et de la transition agroécologique. Elle est au cœur des problématiques de sécurité alimentaire, de sûreté sanitaire et de protection de l'environnement. Ces problématiques sont exacerbées dans le domaine viticole où l'usage de produits phytopharmaceutiques est particulièrement important, où l'exposition des opérateurs est fréquente et où la proximité des riverains avec les vignobles est source d'inquiétudes voire de conflits.

Aujourd'hui, la protection sanitaire des vignobles repose principalement sur une stratégie de lutte chimique préventive respectant un principe de précaution relatif aux conditions climatiques et à l'historique des parcelles de vigne. Ainsi les applications de produits phytosanitaires par pulvérisation couvrent souvent la majorité des surfaces cultivées et sont renouvelées à chaque événement météorologique pouvant présenter un risque pour les cultures. Les plans de pulvérisation sont raisonnés par parcelle en fonction d'un risque global de développement des pathologies. Ce risque est estimé grâce à des observations « à dire d'expert » et parfois grâce à des mesures quantitatives ponctuelles, échantillonnées souvent aléatoirement dans le vignoble. Ainsi un volume et une concentration de fongicides sont calculés en fonction de trois indicateurs globaux : la fréquence et l'intensité observées de la maladie ainsi que la Surface Foliaire Totale (SFT). La fréquence désigne la proportion de plants atteints dans une parcelle, l'intensité représente la proportion moyenne de surface foliaire atteinte par pied, la SFT représente la somme des surface unitaires de feuilles dans la parcelle. Or au sein d'une parcelle de vigne, les risques sanitaires sont très disparates. Ils dépendent du sol, des microclimats, de la structure de la plante et de la répartition des souches primaires du pathogène.

Les technologies agricoles actuelles permettent de gérer les variabilités intra-parcellaire. Dans ce but, la pulvérisation de précision (PP) consiste à moduler localement l'application d'intrants phytopharmaceutiques en fonction des besoins ponctuels en protection chimique. Cette pratique se développe pour répondre aux objectifs de la politique agri-environnementale du plan « Ecophyto II » (consistant à réduire de 50% l'usage des pesticides à l'horizon 2025.). La PP figure dans les axes de recherche du plan « agriculture innovation 2025 ». En effet, Tona *et al.* (2018) estiment par leurs essais que la PP permet de réduire l'usage de pesticides dans les vignobles et les vergers de 25% à 45% selon les conditions saisonnières. La mise en place de telles pratiques nécessite donc une connaissance beaucoup plus détaillée de la physiologie, de la structure et de l'état sanitaire des vignobles.

L'objectif de ce travail est de proposer des outils permettant de caractériser à l'échelle intra-parcellaire l'état physiologique et sanitaire d'un vignoble. Pour répondre à cet objectif, il faut définir les phénomènes observables sur la vigne qui permettent de rendre compte de ces états. En particulier, il s'agit de détecter des symptômes de maladies et d'estimer leur abondance et leur état de prolifération ainsi que d'estimer la sensibilité des pieds en fonction de l'architecture du feuillage et de la zone fructifère.

Afin de systématiser et d'objectiver le diagnostic et la quantification de la maladie à la parcelle, l'imagerie, notamment en proxidtection, se révèle être une technique très prometteuse. Facilement automatisable et non intrusive, l'imagerie permet, avec de faibles coûts en instrumentation et en main-d'œuvre, de rendre compte de nombreuses priorités agronomiques locales sur de grandes surfaces de production. Les travaux présentés dans ce mémoire s'inscrivent dans une étude du potentiel de l'imagerie couleur embarquée à haute-résolution pour caractériser la structure de la canopée viticole ainsi que son état sanitaire. Ces travaux s'appuient sur l'analyse d'images acquises dans les vignes dans les conditions réelles que rencontre un engin agricole en cours de travail. Pour cela, il faut être en mesure d'acquérir des données qui permettent d'estimer ces paramètres sur les images, c'est à dire de définir et de mettre en place un dispositif et un protocole de suivi approprié. Enfin, il convient de développer une stratégie d'analyse d'images qui permette d'extraire des indicateurs basés sur les propriétés de l'image pouvant être transcrits en paramètres d'intérêt agronomique. La problématique traitée dans ce mémoire se résume donc à définir quelles informations l'on peut extraire sur de telles images et comment les interpréter pour caractériser avec fidélité l'état physiologique et sanitaire de la vigne.

---

Les contributions de ce travail concernent à la fois la définition d'une méthodologie d'analyse d'images et le développement de chaînes de traitement au service de la viticulture de précision. La première contribution, d'ordre méthodologique, consiste en une stratégie algorithmique pour la classification pixellaire de petits objets en fonction d'informations locales de couleur et de texture. L'accent est porté sur les méthodes d'extractions d'informations de texture, de structure et de couleur dans les images pour former des attributs statistiques ainsi que sur la représentation de ces attributs et la génération de modèles probabilistes et de fonctions de décision. Les attributs sont extraits grâce à des adaptations d'un outil d'analyse de texture bien connu, le Tenseur Local de Structure (LST), qui est étendu pour former des descripteurs combinant structure et couleur et utilisables dans un cadre bayésien. Le sujet est considéré sous l'angle d'un problème de classification / segmentation sémantique : il s'agit de définir des régions d'intérêt dans les images. C'est la partition de ces images qui permet *in fine* de transcrire l'image en propriétés relatives à l'architecture du feuillage ou l'état sanitaire des pieds de vigne. Deux chaînes de traitement ont été développées à partir de cette stratégie.

La première chaîne de traitement est dédiée à la segmentation des organes de la vigne et fournit une carte décrivant la proportion, la répartition et l'agencement des organes. Elle repose sur des décisions issues de l'estimateur MAP (Maximum *a posteriori*) et une régularisation spatiale basée sur une relaxation probabiliste markovienne.

La seconde chaîne de traitement est dédiée à la détection des taches des symptômes foliaires du mildiou, l'estimation de la surface de tissus symptomatiques par pied et dans une certaine mesure, au dénombrement des taches élémentaires des symptômes. Elle repose sur une reconstruction des symptômes par hystérésis.

Le premier chapitre de ce manuscrit constitue une mise en contexte des enjeux, des méthodes et des applications de l'épidémiologie en viticulture. Le chapitre 2 définit le contexte expérimental de l'étude. Le chapitre 3 présente les outils méthodologiques permettant d'extraire, de représenter et de modéliser conjointement et de manière synthétique des informations de structure et de couleur. Les chapitres 4 et 5 présentent les chaînes de traitement développées spécifiquement pour la segmentation des organes de la vigne et pour la détection et la quantification des symptômes foliaires du mildiou.





# CHAPITRE 1

---

## Etat de l'art

---

### 1.1 La vigne : botanique, physiologie et pratiques culturelles

*Vitis vinifera* est l'unique espèce de vigne cultivée en Europe pour la production de vin. C'est aussi l'espèce largement prédominante dans les vignobles du monde. C'est une culture pérenne, ligneuse et grimpante de type arbuste, généralement structurée en « haie foliaire » (ou « palissée » dans le vocabulaire viticole). Il existe plus de 6000 cépages (variétés) de *Vitis vinifera* dans le monde, dont 210 provenant des appellations françaises. La vigne est une plante greffée, *i.e.* une chimère issue de l'implantation de tissus bourgeonnants d'un individu dît « greffon », sur une autre plante, le porte-greffe (appartenant souvent à une autre variété de l'espèce). Le porte-greffe est souterrain, il produit le système racinaire qui colonise le sol et absorbe l'eau et les éléments minéraux. Le greffon est la partie aérienne de la vigne qui est constituée d'un tronc et des rameaux qui portent le feuillage puis les inflorescences et enfin les fruits. Historiquement, le greffage de la vigne a été introduit pour répondre à l'épidémie de phylloxéra (*Daktulosphaira vitifoliae*) du *XIX<sup>ième</sup>* siècle. Cette pathologie importée des États-Unis est causée par un puceron qui affecte le système racinaire et mène au dépérissement des pieds. Cette grave épidémie a conduit à l'utilisation de porte-greffes d'origine américaine naturellement résistants à cette pathologie pour mettre un terme au dépérissement des vignobles européens. Depuis, même si le phylloxera reste une menace, le greffage est avant tout une pratique qui permet de faciliter la sélection de systèmes racinaires adaptés aux terroirs tout en produisant les cépages de raisins conformes à l'identité souhaitée des vins.

La vigne est cultivée pour une durée variant de 50 à 100 ans. Cependant trois ans séparent généralement la plantation des jeunes plants greffés et la première production de raisins. Les premières années de production sont les plus abondantes. Par la suite, les rendements s'amointrissent mais avec une forte tendance à produire des raisins de meilleure qualité œnologique. En vieillissant la vigne s'affaiblit et les pieds dépérissent progressivement, ne permettant plus une production suffisamment rentable. La vigne est alors arrachée pour laisser place à une nouvelle génération. La gestion de l'âge des populations de pieds est un paramètre important de l'équilibre productivité-qualité d'un vignoble.

La vie de la vigne est une succession de cycles annuels interdépendants. Les conditions de vie au cours d'un cycle ont des influences sur les cycles suivants. Le cycle annuel de développement de la vigne est constitué de trois phases : la croissance végétative, la croissance reproductive et le repos hivernal (Reynier, 2011). La croissance végétative concerne le développement des rameaux et du feuillage tandis que la croissance reproductive concerne le développement des fleurs puis des fruits ainsi que la maturation du raisin. La phase de repos hivernal est une période durant laquelle, la vigne ne possède plus de feuilles et n'a plus d'activité photosynthétique. C'est une phase de dormance où le métabolisme est ralenti, la circulation de la sève est faible et la vigne vit sur ses réserves énergétiques stockées dans le bois qui ont été accumulées durant la phase dite « d'aoûtement ». Les phases végétative et reproductive se recouvrent et sont donc en concurrence pour la consommation de nutriments et d'eau. Cette concurrence se manifeste par une distribution variable des flux de sève. Pendant la période de croissance, les flux de sèves circulent prioritairement vers les feuilles et les jeunes rameaux grandissants qui produisent des bourgeons, parfois au détriment des organes reproducteurs. Pendant la période d'accumulation des sucres, les flux de sèves circulent prioritairement vers les fruits, parfois au détriment du feuillage.

Les événements physiologiques marquants aux cours des cycles de développement sont décrits par la « phénologie ». Pour la vigne, les stades phénologiques sont établis pour la première fois par Baggiolini en 1952 . Il définit 16 stades de « bourgeons d'hiver »( structures qui protègent et maintiennent en vie un embryon de rameau et une ébauche de feuille pendant l'hiver) à la chute des feuilles. En 1994, Lorenz *et al.* complètent cette échelle, notamment pour les étapes de floraison, de façon à obtenir une échelle universelle pour toutes les plantes à fleurs (*Magnoliophytæ* ou Angiospermes). C'est l'échelle d'usage dans le milieu académique comme dans la profession, appelée échelle BBCH (Biologische Bundesanstalt Bunderssortenamt and CHemical industry). Pour *Vitis vinifera*, l'échelle comprend 47 stades d'intérêts (*cf.* figure 1).



FIGURE 1: Stades phénologiques de *Vitis vinifera* selon l'échelle BBCH (©Institut Français de la Vigne et du Vin : A-M. Denizot Photos IFV : P. Mackiewicz, A.M. Denizot - Janvier 2009)

## 1.2 Les pathologies de la vigne

La vigne est une culture rustique et robuste. Elle s'adapte à de nombreux climats, peut survivre et croître dans des sols pauvres et faiblement abondants en eau. Elle résiste également au gel et aux fortes températures. C'est d'ailleurs en particulier lorsqu'elle est soumise à de légers stress environnementaux que la vigne produit des raisins de grande qualité œnologique. Cependant, *Vitis vinifera* est une espèce particulièrement sensible à certains phytopathogènes. En effet, la vigne fait partie des cultures qui nécessitent le plus de protection et qui consomment le plus de produits phytosanitaires, avec un IFT<sub>(h-h)</sub><sup>1</sup> moyen de 12 contre 3,5 pour les « grandes cultures » (Agreste, 2013). Cette sensibilité exacerbée peut s'expliquer à la fois par le stress cultural, par la sélection intense des cépages pour leurs propriétés orga-

1. L'IFT, l'Indicateur de Fréquence de Traitements phytosanitaires, comptabilise le nombre de doses de référence utilisées par hectare au cours d'une campagne culturale pour protéger la culture de ses bio-agresseurs. Dans le cas de l'IFT<sub>(h-h)</sub> « hors herbicides », on ne tient pas compte des opérations de désherbage.

noleptiques et par la pérennité de la culture. En effet, l'absence de rotations sur les parcelles ne permet pas de ruptures naturelles dans les cycles de développement des phytopathogènes. Dans ces conditions, la vigne constitue alors un habitat naturel pour ses pathogènes, qui parviennent à survivre entre deux saisons. Ainsi, *Vitis vinifera* est sujette à de nombreuses pathologies, conséquences d'interactions avec des agents pathogènes biotiques de natures variées, principalement des virus, des bactéries et des champignons. Les plus répandus et les plus dommageables sont : les pathologies du bois de la vigne (MBV), la flavescence dorée (FD) et les pathologies cryptogamiques.

Les MBV, notamment l'esca et l'eutypiose, sont causées par des complexes de champignons endémiques, qui infectent les vaisseaux conducteurs de sèves. Ces infections provoquent des occlusions puis des nécroses. A terme elles mènent au dépérissement des pieds. Si les symptômes de ces pathologies sont connus depuis l'antiquité, ce n'est que depuis ces deux dernières décennies que l'ampleur des MBV est devenue inquiétante avec près de 13% du vignoble français atteint. En l'absence de traitement<sup>2</sup>, la lutte contre les MBV est prophylactique : elle consiste en l'arrachement des pieds atteints. Le manque à gagner en production de vin s'évalue à près d'un milliard d'euros par an en France seulement (Rey *et al.*, 2016.)

La flavescence dorée (FD) est une pathologie dite « vectée ». Elle est transmise entre pieds de vigne par la cicadelle dorée (*Scaphoideus Titanus*) qui acquiert un pathogène bactérien (phytoplasme) (*Candidatus phytoplasma vitis*) dans la sève d'un hôte déjà infecté. La FD entraîne une diminution de la photosynthèse, le flétrissement des baies et empêche la lignification des rameaux qui se courbent donnant un port « pleureur » aux pieds atteints, qui finissent par dépérir (Chuche et Thiery, 2014). La FD est une pathologie de « quarantaine », les zones infectées font l'objet d'un Plan de Lutte Obligatoire (PLO). Le PLO consiste à empêcher la propagation de la pathologie en traitant la cicadelle et ses œufs ainsi qu'en arrachant les pieds symptomatiques pour assainir les parcelles. Chaque année entre 35% et 60% du vignoble français est concerné par la quarantaine (Jeger *et al.*, 2016).

---

2. il existe des traitements efficaces à base d'arsénite, mais ils ont été interdit en 2003

Les pathologies cryptogamiques sont causées par des champignons microscopiques. L'ensemble du vignoble européen est concerné par ces pathologies qui représentent la plus grande menace économique pour ces vignobles, tant en termes de dégâts potentiels pour la production que de coûts engendrés par la protection chimique qu'elles impliquent (Bois *et al.*, 2015). Par ailleurs, les produits anti-fongiques représentent la première source de pollution chimique en viticulture. Parmi ces pathologies on trouve notamment le **mildiou** (*Plasmopara viticola*), l'**oïdium** (*Erysiphe necator*), le **botrytis** (*Botrytis cinerea*) et le **blackrot** (*Guignardia bidwelli*). Dans le cadre de ce travail, on s'intéresse tout particulièrement au cas du Mildiou, la pathologie la plus récurrente et affectant le plus de surfaces viticoles en Europe (Pedneault et Provost, 2016).


## 1.3 Le mildiou de la vigne : biologie, symptômes et moyens de lutte

Le mildiou de la vigne est originaire des États-Unis. Il a été introduit lors de l'importation de portes-greffes américains résistants au phylloxera dans les années 1880. *Plasmopara viticola* appartient à la classe des Oomycètes, des pseudo-champignons proches des algues brunes. C'est un endoparasite obligatoire, *i.e.* il ne peut se développer, se nourrir et se reproduire que dans les tissus vivant de son hôte. Il peut coloniser tous les tissus herbacés riches en eau (feuilles, vrilles, bourgeons, fleurs et grappes) par le développement de filaments ramifiés, les mycéliums, puis forme des *haustoria*, des structure globulaires qui absorbent l'eau et les nutriments dans les cellules de l'hôte.

### 1.3.1 Physiologie et écologie du mildiou de la vigne

*Plasmopara viticola* a la particularité d'être rémanent dans les parcelles ; il se conserve et survit à l'hiver entre deux cycles de production sous forme d'oospores. Les oospores sont des structures quiescentes responsables de la reproduction sexuée. Ils sont formés en fin de saison dans les tissus infectés. Ils possèdent une triple paroi épaisse qui assure une protection des gamètes (*i.e.* le matériel génétique) contre le froid et la déshydratation. Les oospores peuvent survivre à des températures allant jusqu'à  $-20^{\circ}\text{C}$ , parfois durant deux hivers successifs. Latents dans les débris végétaux restés au sol, les oospores peuvent germer au printemps quand les conditions de température (entre  $11^{\circ}\text{C}$  et  $30^{\circ}\text{C}$ ) et d'humidité sont favorables. La germination peut durer de deux jours à une semaine. Elle produit un long filament au bout duquel se forme un macrosporange. Les macrosporanges sont responsables de la formation de zoospores (phase asexuée du cycle de développement), des organes unicellulaires munis de

flagelles. Ils peuvent se déplacer dans l'eau à la surface de la végétation et se fixent à proximité de stomates sur la face inférieure des feuilles en sécrétant une matrice glycoprotéique. Les zoospores produisent ensuite les mycéliums qui pénètrent les feuilles par les stomates et croissent jusqu'au dépérissement de la feuille ; c'est le mécanisme d'infection primaire. Par la suite les mycéliums sont capables de produire de nouveaux macrospores et zoospores qui vont coloniser d'autres parties de la végétation, les zoospores peuvent notamment être transporté par phénomènes « d'éclaboussure » lors de fortes pluies ; c'est le mécanisme d'infection secondaire. Pendant la saison, lorsque les conditions ne sont plus favorables à la croissance de l'organisme, le mécanisme de survie entre en jeu. Les mycéliums peuvent produire de façon sexuée de nouveaux oospores. C'est notamment le cas en conditions de sécheresse, de températures supérieures à  $35^{\circ}C$  prolongées et en particulier lorsque le feuillage dépérit en fin de saison. A chaque nouvelle phase de reproduction sexuée, le pathogène peut produire de nouvelles souches génétiquement différentes qui peuvent développer des résistances aux fongicides déjà appliqués. Ainsi, à partir d'un seul inoculum primaire, plusieurs contaminations primaires et secondaires impliquant des souches différentes peuvent avoir lieu au cours d'une saison viticole (pathologie polycyclique). C'est ce qui fait du mildiou une pathologie si tenace (Dubos, 2002).


 FIGURE 2: cycle de développement de *Plasmopara viticola* (Jackson, 2008)

### 1.3.2 Les symptômes visibles du Mildiou

Les symptômes du Mildiou de la vigne ont été décrits pour la première fois au *XIX<sup>ime</sup>* siècle par Farlow (1882). Ces symptômes se manifestent principalement sur les feuilles et sont dus à des lésions causées par la croissance des mycéliums et à l'absorption du contenu des cellules. Deux types de lésions peuvent être observées selon l'avancement de la saison et l'état de développement des tissus foliaires. Le faciès le plus courant, dit « taches d'huiles » produit sur la face supérieure des tâches circulaires d'abord translucides puis d'aspect « huileux ». Ces taches jaunissent rapidement : c'est le résultat d'une perte de chlorophylle et d'une photosynthèse déficiente. À terme ces lésions causent des nécroses. En parallèle, ces taches grandissent et peuvent confluer jusqu'à recouvrir tout le limbe. Sur la face inférieure des feuilles, on observe un duvet blanc qui se densifie. Il est constitué de filaments mycéliens sporulants. Le faciès tache d'huile est surtout observable pour les infections précoces et affecte principalement les jeunes feuilles. Il existe un faciès qui apparaît plus tardivement et qui affecte plutôt les feuilles âgées, c'est le faciès « points de tapisserie » ou « mildiou mosaïque ». Il apparaît comme un ensemble de taches polygonaux nécrotiques limitées par



les nervures de la feuille.

Le mildiou peut aussi affecter les grappes, elles produisent de nombreux filaments qui sporulent à la surface des baies quand l'infection est précoce. Plus tardivement elles produisent des taches violacées ou brunes sur les baies non mûres qui finissent par se dessécher : c'est le faciès « rot brun ». Les baies sont sensibles au mildiou jusqu'à la véraison, où leur peau s'épaissit empêchant les mycéliums de les pénétrer. Par ailleurs, les composés phénoliques des baies mûres, notamment les tanins, entravent l'activité trophique du mildiou. Dans des cas beaucoup plus sévères lors d'infections très précoces, le mildiou peut aussi infecter les inflorescences. Le tapis de mycélium empêche alors la floraison, c'est le faciès « rot gris » .

Beaucoup plus rarement, le mildiou peut fructifier sur de très jeunes rameaux, notamment à la faveur de plaies causées par la grêle ou par des coupures mécaniques. On observe alors quelques lésions superficielles et des nécroses. Lorsque les rameaux se lignifient, ils ne sont plus sensibles à la pathologie (Ash, 2000).

### 1.3.3 Méthodes de lutttes

La protection des vignobles contre le Mildiou repose principalement sur la lutte chimique *i.e.* la pulvérisation de fongicides spécifiques. Cette opération de protection est utilisée de manière préventive pour empêcher le développement des mycéliums ou la sporulation. En effet, le pathogène est trop tenace et rémanent pour être éradiqué au cours d'une saison, en particulier lors de conditions climatiques favorables à son développement. Il existe un grand nombre de familles moléculaires ayant des propriétés fongicides, leurs modes d'action se divisant en six catégories :

- les perturbateurs de la respiration mitochondriale,
- les inhibiteurs de la synthèse des stérols (les lipides qui maintiennent l'intégrité structurale et fonctionnelle des membranes cellulaires),
- les inhibiteurs de la synthèse des acides aminés,
- les perturbateurs de la division cellulaire,
- les « multisites » agissant via plusieurs modes d'action à la fois.




FIGURE 3: Les symptômes courants du mildiou : faciès présents sur feuilles et sur grappes. [source : ©INRA (Dominique Blancard, Yvon Bugaret)]

L'efficacité de la lutte chimique est fortement dépendante des conditions météorologiques ainsi que de la structure du feuillage. En effet pour restreindre la prolifération et affaiblir le pathogène, il faut conjointement perturber son métabolisme et son environnement. La vigne est la plante hôte du pathogène. Elle constitue donc son habitat écologique naturel. C'est à la fois une source d'alimentation et de protection. La gestion de la structure du feuillage permet d'imposer à la plante des conformations beaucoup moins favorables au pathogène. En effet, l'épaisseur et la porosité du feuillage ainsi que sa contiguïté avec la zone fructifère, influent sur l'aération, l'humidité et l'exposition lumineuse régnant en son sein. Ces propriétés attestent donc de la sensibilité de la vigne aux pathologies fongiques. Cette gestion de la structure permet également d'optimiser l'application de fongicides en favorisant la pénétration, l'adhérence ou la durée d'action des produits phytosanitaires. La caractérisation de la structure de la végétation est donc essentielle pour les nouvelles stratégies de lutte contre le mildiou et les autres pathologies cryptogamiques. Elle permet d'estimer

des paramètres d'entrée des modèles de prédiction des risques sanitaires et d'évolution des infections et intervient dans les préconisations de pulvérisation de produits phytosanitaires. Cependant, aujourd'hui ce sont principalement les alertes des réseaux d'épidémiosurveillance qui permettent de déclencher et de raisonner les opérations de protection des cultures.

**Le mildiou, un cas d'étude générique :** De par ses propriétés biologiques, le mildiou de la vigne est ainsi une pathologie explosive<sup>3</sup> et rémanente qui affecte de manière récurrente la majorité des vignobles. L'impact économique et environnemental de la lutte contre le mildiou en font donc une pathologie d'intérêt majeur pour les épidémiologistes. En outre, c'est une pathologie encore assez peu étudiée en imagerie. Il n'existe que deux études préliminaires traitant du sujet (Han et Cointault, 2013 ; Picon *et al.*, 2014). Bien que ces études soient encourageantes, elles montrent la difficulté du sujet. En effet, de par la taille, l'aspect visuel et la répartition spatiale de ses symptômes, le mildiou de la vigne représente un cas d'étude complexe en termes d'imagerie. Observé à l'œil nu sur un tissu ciblé, le mildiou est facilement reconnaissable par un expert. Les propriétés statistiques des images permettent aussi de discriminer les tissus symptomatiques des tissus sains. En revanche, lorsqu'il s'agit d'inspecter de grandes surfaces viticoles et de reconnaître quelques surfaces symptomatiques disséminées au sein du feuillage, l'exercice se révèle un vrai défi pour l'analyse d'image. La tâche est d'autant moins triviale que les symptômes du mildiou sont souvent de petite taille (aux stades précoces) et qu'il existe de nombreux facteurs confondants. Ce sont notamment les symptômes d'autres pathologies de la vigne, et plus généralement tous les phénomènes qui produisent des décolorations jaunes, ou des taches nécrotiques, ce qui est le cas pour bon nombre de stress abiotiques. Le choix de ce cas d'étude est donc motivé à la fois par l'importance économique et environnementale de la lutte contre cette pathologie, mais aussi par l'intérêt méthodologique de cet objet d'étude pour l'imagerie agricole. En effet, la surveillance d'autres pathologies d'intérêt en viticulture, comme l'oïdium, le botrytis ou le blackrot relèvent de problématiques d'analyse d'image comparables.

## 1.4 L'épidémiosurveillance dans le contexte viticole : enjeux et méthodes actuelles

Dans le domaine viticole, l'épidémiosurveillance est une pratique cruciale qui consiste à estimer et prédire l'évolution des phytopathologies, à l'échelle d'un territoire de production homogène. Elle permet de produire des « bulletins de santé végétale » (BSV) à partir d'ob-

servations et de mesures échantillonnées selon les variabilités pédologiques, climatiques et culturelles. Les BSV servent à la fois d'alerte au déclenchement des plans de luttés ainsi que d'outil de préconisation pour les pratiques culturales et les besoins en couverture phytosanitaire. Grâce aux nombreux réseaux d'épidémiosurveillance couvrant les vignobles français, la filière viticole est parvenue à améliorer ses stratégies de protection des cultures. Il en résulte une meilleure garantie des récoltes, une réduction des coûts liés aux produits phytosanitaires, une diminution de la pollution environnementale et une meilleure maîtrise de l'exposition des opérateurs et du voisinage aux molécules actives (Michel, 2016).

Toutefois, avec les méthodes actuelles, l'épidémiosurveillance repose sur la mobilisation d'experts qui estiment, à partir de l'inspection visuelle de quelques pieds échantillonnés, la fréquence<sup>4</sup> et l'intensité<sup>5</sup> des pathologies observées pour l'ensemble du territoire viticole. Ces pratiques sont donc coûteuses et chronophages. De plus, les BSV ne permettent de réaliser que des estimations globales qui sont extrapolées à partir d'observations ponctuelles. Ces observations sont sujettes à la subjectivité des observateurs et aux biais d'échantillonnage. L'épidémiosurveillance pourrait donc tirer profit de l'utilisation de méthodes automatisées permettant de caractériser l'état sanitaire des vignobles à l'échelle du pied ou de la piquetée<sup>6</sup> avec un échantillonnage dense pour l'ensemble des parcelles d'un vignoble. Ainsi produite, une cartographie quantitative et objective de l'état sanitaire serait une donnée précieuse pour le développement de nouvelles pratiques de protection des vignobles.

En matière de lutte chimique, la cartographie sanitaire est une étape indispensable pour la mise en place des pratiques de « pulvérisation de précision », plus économes en intrants. Il est possible d'envisager des opérations d'endiguement des épidémies par la création de zones de protection tampons autour des premiers foyers infectieux détectés (West *et al.*, 2003). Il est aussi possible d'envisager de moduler localement les doses de produits phytosanitaires en fonction de la fréquence de contamination et l'intensité des infections dans une surface unitaire au niveau intra-parcellaire (Oberti *et al.*, 2014; Tona *et al.*, 2016).

---

4. la proportion d'individus atteints par la pathologie

5. proportion moyenne des tissus symptomatiques observés

6. une succession de cinq pieds entre deux piquets

La cartographie constitue aussi un outil d'étude dynamique et historique permettant de définir des zones de risque récurrentes et de prédire la propagation d'une épidémie en fonction des inoculums hérités des saisons antérieures. Pour les phytopathologistes, la cartographie présente aussi un intérêt pour : (i) évaluer l'efficacité de certaines pratiques culturales sur l'état sanitaire, (ii) comparer des phénotypes, (iii) assister la sélection variétale, (iv) valider des modèles épidémiologiques (Vine *et al.*, 1997).

Dans ce contexte, l'utilisation de méthodes optiques se révèle être une solution pertinente. L'étude des propriétés optiques des tissus végétaux peut se réaliser par **spectroradiométrie**, ce qui est le cas de la plupart des études menées jusqu'ici, soit par l'analyse de motifs spatiaux spécifiques dans une ou plusieurs longueurs d'onde en **imagerie**. Ces dernières années, plusieurs projets de détection automatique des pathologies de la vigne ont été conduits en France. Notamment les projets DAMAV (Al Saddik, 2019) et OENOMIP (Albetis, 2018) portant sur la FD ainsi que le projet ADVANTAGE portant sur les MBV (Rançon *et al.*, 2018). En outre, l'utilisation de mesures chimiométriques laisse envisager de détecter des pathologies de façon plus précoce *i.e.* avant l'apparition de symptômes observables par un expert (Nouri, 2017). La détection précoce peut constituer une solution pour agir de manière préventive au plus proche des inoculums primaires, ce qui se révèle particulièrement intéressant pour les pathologies polycycliques comme le mildiou, les pathologies soumises aux PLO comme la FD ou les pathologies traitables uniquement par prophylaxie comme l'esca. Cependant cela reste un objectif difficile à atteindre en pratique, notamment hors conditions contrôlées, comme le montrent plusieurs études récentes (Oberti *et al.*, 2014; Nouri *et al.*, 2018; Mahlein *et al.*, 2017).

## 1.5 Potentialités des méthodes optiques pour le suivi des phytopathologies

Les méthodes optiques permettent de réaliser des mesures non-invasives, à haut-débit et avec peu de main-d'œuvre, qui rendent compte de l'état sanitaire de populations végétales sur de grandes surfaces de production. De plus ces méthodes se prêtent facilement à l'automatisation des acquisitions par l'intermédiaire de capteurs indépendants qui peuvent être embarqués sur différents vecteurs terrestres ou aériens (Mahlein *et al.*, 2012). La possibilité de remplacer des inspections réalisées sur le terrain par des experts de façon ponctuelle par des observations denses et fréquentes se révèle particulièrement intéressante dans le cas d'une pathologie explosive et polycyclique comme le mildiou. En outre l'analyse des spectres et des images issus de ces capteurs bénéficie de l'expérience et des outils développés pour d'autres

applications agricoles, industrielles, militaires et médicales qui peuvent être transposées et adaptées aux besoins de l'épidémiologie.

### 1.5.1 Les interactions entre la lumière et les tissus végétaux

L'étude des interactions entre la lumière et la matière végétale, en particulier le feuillage, permet de caractériser certains phénomènes physiologiques associés à l'état sanitaire des plantes. En effet, les propriétés de transmittance, d'absorbance et de réflectance d'un tissu végétal dépendent de propriétés physico-chimiques comme la teneur en pigments foliaires, la structure cellulaire ou le contenu en eau (Carter et Knapp, 2001). Lorsqu'une plante est en contact avec un agent pathogène qui perturbe son métabolisme ou qui déclenche ses mécanismes de défense, ses propriétés d'interaction avec la lumière sont susceptibles d'être modifiées (Sankaran *et al.*, 2008). Ces changements sont observables à différentes longueurs d'onde dans les domaines de l'infrarouge, du visible et de l'ultra-violet.

Les longueurs d'ondes du domaine visible (VIS) sont comprises entre 380 nm et 730 nm. Elles correspondent aux couleurs du violet au rouge en passant par le vert. Ce domaine spectral rend principalement compte de la composition, de la teneur et de la répartition spatiale des pigments naturels contenus dans les couches superficielles des tissus végétaux (Sims et Gamon, 2002). Ces pigments participent à différentes activités métaboliques fondamentales comme la photosynthèse (chlorophylles et caroténoïdes), l'attraction des pollinisateurs (anthocyanes et flavonoïdes) et dans certains cas à la défense contre les bioagresseurs. Ainsi l'observation d'anomalies radiométriques ou d'irrégularités géométriques dans ces longueurs d'ondes peuvent révéler des perturbations physiologiques dues à des stress abiotiques ou des pathologies.

Certains pigments possèdent également des propriétés d'absorbance dans le domaine ultra-violet (UV) *i.e.* de 200nm à 380nm, ce qui assure aux végétaux une protection contre ces fréquences hautement énergétiques qui peuvent endommager le matériel génétique (Tremblay *et al.*, 2012). Les propriétés des pigments dans l'UV, notamment celles de la chlorophylle, sont souvent étudiées à travers des phénomènes de fluorescence *i.e.* après une excitation active des tissus par des photons issus d'une source artificielle (Cerovic *et al.*, 2007). Dans une moindre mesure ces pigments naturels interagissent aussi avec les photons du domaine de l'infrarouge (IR).

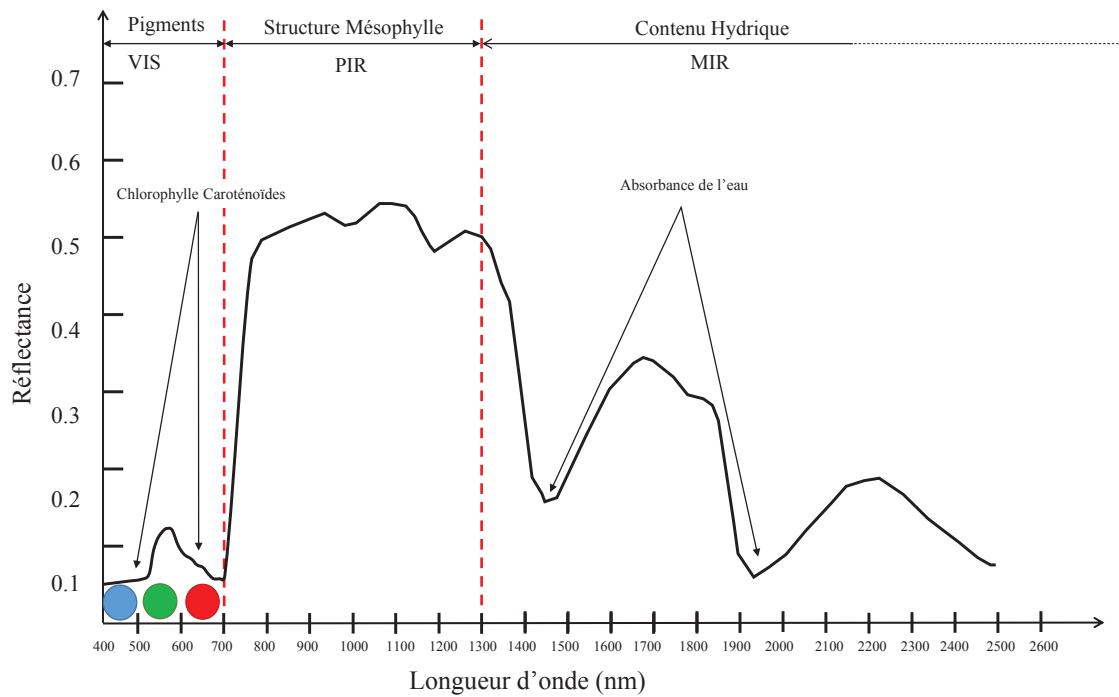


FIGURE 4: Spectre caractéristique d'une feuille de *magnoliophytæ* dans le VIS et IR ; adapté de (Hoffer et Johanssen, 1969)

Le domaine IR permet principalement de rendre compte des propriétés structurelles du mésophylle spongieux, *i.e.* la partie interne des feuilles dans laquelle se réalisent les échanges gazeux. Contrairement aux parties superficielles des feuilles qui sont stratifiées, la partie interne des feuilles est lacunaire et très irrégulière. Ces propriétés structurelles sont observables dans la partie proche IR (PIR) comprise entre 730nm et 1300nm (Mestre, 1935 ; Knipling, 1970). Dans le domaine IR moyen (MIR), on peut observer des propriétés relatives au contenu hydrique des tissus végétaux, avec la présence de deux bandes d'absorbance de l'eau autour de 1430nm et de 1910nm (Allen *et al.*, 1969). Ainsi des désordres métaboliques ou structurels causés par un pathogène peuvent être observés dans le domaine IR. La figure 4 récapitule les propriétés de réflectance générales d'une feuille de plante à fleurs dans les domaines VIS et IR.

### 1.5.2 Méthodes d'analyse spectroradiométriques

Les analyses spectroradiométriques peuvent être réalisées soit à partir de la mesure d'un spectre de réflectance ou de transmittance quasi continu, soit à partir de mesures échantillonnées dans un nombre restreint de longueurs d'onde. La mesure d'un spectre continu peut se réaliser à l'aide d'un spectroradiomètre ponctuel ou à l'aide d'un imageur hyperspectral. Dans les deux cas le capteur fournit un spectre sous la forme d'une série de bandes spectrales étroites (entre 4 nm et 10 nm) et contiguës sur des plages de longueurs d'onde allant du VIS au MIR ou dans l'UV. Les spectroradiomètres ponctuels sont des instruments de contact



qui mesurent un spectre moyen réfléchi par une petite surface unitaire d'intérêt ciblée par l'utilisateur. Dans le cas d'un imageur hyperspectral, la mesure est spatialisée. Chaque pixel de l'image est décrit par un spectre différent. Dans ce cas, les régions d'intérêts sont sélectionnées sur l'image. Dans certains cas, un nombre plus restreint de bandes spectrales permet d'observer des phénomènes physiologiques liés aux pathologies. Les réflectances dans ces bandes sont alors mesurées avec une caméra multispectrale. Les caméras multispectrales sont sensibles à des bandes plus larges (entre 20 nm et 40 nm selon la longueur d'onde) qui sont distantes entre elles dans le spectre. Ces caméras sont généralement sensibles, pour les usages agricoles, à 5 ou 8 bandes dans le VIS (3 bandes : bleu, vert et rouge), le « red-edge » (707 nm à 727 nm), le PIR et/ou le MIR autour des pics de réflectances notables (voir figure 4). Les méthodes d'analyse sont généralement similaires, que les données proviennent d'un capteur ponctuel ou d'un imageur. En effet, la composante spatiale de l'image est encore peu exploitée dans les applications phytopathologiques. C'est avant tout l'information radiométrique qui permet de décrire les phénomènes observés. La dimension spatiale des imageurs permet principalement de réaliser des opérations de prétraitement pour identifier des régions d'intérêt dans l'image. Par exemple Nouri (2017), sélectionne au sein de feuilles individuelles des régions atteintes par une pathologie fongique à étudier tandis que Albetis (2018) sépare le feuillage viticole de l'inter-rang sur des images issues de drones.

### 1.5.2.1 Analyse de spectres denses

L'analyse de données hyperspectrales riches constitue souvent une étape d'étude préliminaire. Ces études consistent dans un premier temps à comparer les signatures spectrales issues de tissus sains et de tissus affectés par des pathologies, voire de comparer les signatures de différentes pathologies. L'objectif est de déterminer s'il existe des dynamiques ou des motifs dans les signatures spectrales qui permettent *a priori* de les discriminer. Dans un second temps, ces études permettent de réaliser de la prospection spectrale, *i.e.* de déterminer les plages du spectre dans lesquelles l'information est la plus pertinente et la plus discriminante.

Plusieurs études hyperspectrales récentes montrent des différences significatives et répétables entre des signatures spectrales saines et des signatures pathologiques. Ainsi, des différences de l'ordre de 10% à 30% de l'indice de réflectance dans certaines longueurs d'onde VIS, PIR et MIR sont observées pour des pathologies de la vigne comme l'esca et la FD (Albetis, 2018 ; Al Saddik, 2019) ou pour des pathologies du pommier comme la tavelure (Nouri, 2017). Ces observations sont cohérentes avec des phénomènes macroscopiques observables sur des tissus malades comme les différents faciès de décoloration ainsi qu'avec des mesures chimiques de la composition de ces tissus. En effet, dans le cas de pathologies dues



à des phytoplasmes comme la FD, des diminutions dans la concentration des chlorophylles et des caroténoïdes apparaissent (Bertamini *et al.*, 2003). Bertamini *et al.* (2002) observent aussi pour des pathologies similaires des perturbations dans les ratios (caroténoïdes/ chlorophylles) et des ratios (chlorophylle a/ chlorophylle b). Par ailleurs, d'autres molécules ayant des propriétés d'absorption VIS et IR sont sujettes à des modifications de concentration dans le cas de ces pathologies. C'est notamment le cas du saccharose (Himeno *et al.*, 2014) et des protéines solubles (Bertamini *et al.*, 2004). Enfin, Vitali *et al.* (2013) observent de fortes diminutions dans les conductances stomatiques pour les feuilles infectées par les pathologies majeures de la vigne. Une diminution de la conductance peut être associée à une diminution locale de la teneur en eau, ce qui explique certains pics de réflectance anormaux dans le MIR. L'activité des stomates peut aussi être impactée par des phénomènes d'obturation ou des déstructurations du mésophylle spongieux, qui apparaissent notamment lors du flétrissement ou de l'enroulement des feuilles (symptôme dit de « port en parapluie ») ce qui peut expliquer les variations de réflectance dans le PIR.

Ces observations sont uniquement qualitatives, elles montrent simplement qu'il existe certaines différences dans les signatures spectrales à partir desquelles il serait possible de discriminer des tissus sains de tissus malades. Afin de caractériser le pouvoir discriminant de ces signatures, il existe différentes méthodes d'analyse statistique. Par exemple, Al Saddik (2019) propose de projeter les signatures spectrales saines et pathologiques sur les axes factoriels d'une ACP<sup>7</sup> puis de calculer et comparer les distances inter-classes et intra-classes. Cette méthode permet de quantifier la séparabilité des signatures spectrales. Les résultats de ces analyses suggèrent que les spectres issus de feuilles malades, qu'elles soient atteintes par l'esca la FD ou le BN, sont séparables des spectres sains pour plusieurs cépages rouges et blancs. Cependant les spectres des différentes pathologies étudiées ne sont pas séparables entre eux sur les axes principaux de variabilité. Le même constat est réalisé pour les stades de sévérité d'une même pathologie. Il ne paraît donc pas possible pour ces pathologies de quantifier la sévérité d'une infection sur la base de ces seules projections du spectre.

---

7. Analyse en Composantes Principales

En pratique, l'évaluation du pouvoir discriminant des données hyperspectrales se réalise plus efficacement à l'aide de méthodes de classification. Les résultats issus de ces études permettent de quantifier l'opérabilité de la détection des pathologies sur la base d'une signature spectrale. Ainsi Albetis (2018) et Al Saddik (2019) parviennent à classifier/discriminer à l'aide de méthodes supervisées usuelles (Support Vector Machine, Gaussian Mixture Models et Random Forest) des feuilles atteintes de FD ou d'esca par rapport à des feuilles saines. Cependant les données hyperspectrales sont fastidieuses à traiter. Ces données sont volumineuses et redondantes. De plus de nombreuses bandes spectrales ne portent aucune variabilité, ne sont pas discriminantes ou reflètent des phénomènes peu spécifiques aux pathologies. En outre, le coût calculatoire du traitement de spectres denses est très important. Dans ces conditions on assiste alors à des phénomènes de sur-apprentissage : c'est le « fléau de la dimensionnalité » (Bellman, 2003). Pour pallier les problèmes liés à la taille et à la structure de ces données, de nombreux auteurs procèdent à une sélection de variables au sein des spectres.

Ainsi, en pratique, il est souvent préférable d'exploiter uniquement certaines portions remarquables du spectre pour obtenir une description plus compacte et plus pertinente des phénomènes observés. Par exemple Nouri (2017) exploite des résultats des travaux hyperspectraux de Delalieux *et al.* (2007) sur la tavelure pour développer des méthodes de sélection de variables. De même, Al Saddik (2019) s'appuie sur une étude hyperspectrale préliminaire afin de concevoir un capteur multispectral spécifique plus facilement opérable en plein champ.

### 1.5.2.2 Analyse d'échantillons spectraux

Il existe différentes stratégies pour exploiter des informations sélectionnées dans les spectres. Il est possible de sélectionner des bandes spectrales directement à l'acquisition sur la base de connaissances pré-établies sur les pathologies et leurs signatures spectrales. Il est aussi possible de sélectionner des variables d'intérêt sur des mesures spectrales continues par le calcul d'indices de végétations (IV), l'estimation de paramètres biophysiques (BP) ou la sélection et la combinaison de nouvelles variables spectrales spécifiques.

**(i) Le calcul d'indices de végétation et de stress pathologique**

Il existe près de 150 indices de végétation (IV) dans la littérature, ils sont principalement liés au comportement des pigments, à l'activité photosynthétique et au contenu en eau des cellules. Ces indices usuels comme le NDVI<sup>8</sup>, le PRI<sup>9</sup>, l'ARI<sup>10</sup> ou le WDI<sup>11</sup> ne sont pas spécifiques aux pathologies elles-mêmes mais révèlent plutôt la présence d'un stress. Ces indices peuvent servir d'alertes précoces dans le cas d'infections mais ne sont *a priori* pas discriminants par rapport aux réponses spectrales que peuvent exprimer des plantes soumises à des stress environnementaux ou abiotiques. Certaines études ont permis d'évaluer le potentiel des IV pour la détection de pathologies végétales à l'aide de protocoles de classification. C'est le cas de Mahlein *et al.* (2010) dans le cas de pathologies fongiques de la betterave sucrière ou Santoso *et al.* (2011) dans le cas de pourritures racinaires du palmier oléagineux. Plus récemment, Al Saddik (2019) et Albetis (2018) proposent de comparer les performances de classification supervisée sur la bases d'IV issus de feuilles atteintes d'esca, de FD et de feuilles saines avec les performances obtenues en classifiant des spectres denses constitués de plus de 2000 bandes étroites de 4 nm. Il est également possible de combiner plusieurs IV avec certaines bandes étroites spécifiques afin de construire des indices plus spécifiques à une pathologie donnée. Dans le cas de l'identification du virus de l'enroulement de la feuille, Rayapati *et al.* (2009) ainsi que Hou *et al.* (2016) sont parvenus à construire des descripteurs spectraux compacts combinant une dizaine d'IV et de bandes étroites du VIS et de l'IR.

**(ii) Estimation de paramètres biophysiques**

Les paramètres biophysiques (PB) décrivent des caractéristiques physiologiques des plantes comme le LAI<sup>12</sup>, la fAPAR<sup>13</sup>, la biomasse, l'albédo ou la Chl<sup>14</sup> (Aitouda, 2012). Ces paramètres peuvent être estimés à partir de mesures spectroradiométriques, associées à des modèles d'inversion prenant en compte l'état de la végétation, les propriétés optiques des feuilles et le transfert radiatif dans le couvert végétal. L'efficacité des paramètres biophysiques dans le suivi de la végétation a été testée et validée sur différentes cultures dans le cadre du projet Farmstar (Blondlot *et al.*, 2005). À la différence des indices de végétation, ils prennent en compte les caractéristiques des capteurs, les conditions d'observation et d'illumination. De ce fait, ils sont souvent considérés comme de très bons candidats pour remplacer les indices

---

8. Normalised Difference Vegetation Index

9. Photochemical Reflectance Index

10. Anthocyanin Reflectance Index

11. Water Deficit Index

12. L'indice de surface foliaire

13. La fraction du rayonnement photosynthétiquement actif absorbé par le couvert

14. Teneur en chlorophylles

de végétation classiques dans la caractérisation et la surveillance de la végétation (Lacaze *et al.*, 2011 ; Roumiguié *et al.*, 2015 ; Féret *et al.*, 2017). Dans le cadre des pathologies de la vigne, Albetis (2018) estime des PB relatifs à la teneur en pigment et au couvert végétal pour discriminer des zones de feuillage atteintes de FD au sein de zones saines. Les PB sont estimés à l'aide d'un modèle atmosphérique LOWTRAN<sup>15</sup> (Kneizys *et al.*, 1988) et de modèles de réflectance du couvert végétal PROSPECT<sup>16</sup> (Jacquemoud et Baret, 1990) et SAIL<sup>17</sup> (Verhoef, 1984). Les résultats de classification issus de PB se révèlent plus performants que ceux issus d'IV ou de spectres denses.

### (iii) Sélection de bandes et construction de variables spectrales spécifiques

Une autre approche consiste à échantillonner des réponses spectrales discriminantes, au sein de données hyperspectrales, sans *a priori* physiologique sur l'interaction plante-pathogène-lumière. Ces méthodes permettent d'obtenir des modèles spectraux plus complexes et plus spécifiques aux pathologies décrites. Ainsi Al-Saddik (2019) propose de construire des descripteurs spectraux à partir de données hyperspectrales grâce à des algorithmes non-supervisés GA-KNN<sup>18</sup> et SPA-KNN<sup>19</sup>. Ces descripteurs « sur mesure » sont comparés en classification avec des résultats issus de spectres denses et d'IV. Les descripteurs GA-KNN démontrent de meilleures performances pour la discrimination de feuilles saines et de feuilles atteintes de FD. Des approches exploitant des régressions de données hyperspectrales ont été expérimentées dans le cas de pathologies de la vigne par Albetis (2018) avec des modèles de régression GLM (generalised linear models) ou dans le cas de pathologies du pommier (Nouri, 2017) avec des modèles PLS-DA (partial least square discriminant analysis) et des modèles SIMCA (Soft Independent Modelling of Class Analogy).

#### 1.5.2.3 Bilan sur le potentiel de la spectroradiométrie pour la détection de phytopathologies

La spectroradiométrie hyperspectrale et multispectrale a montré un fort potentiel à décrire des stress physiologiques associés à des pathologies végétales. En effet sur la base d'informations extraites des signatures spectrales, il est possible de différencier des feuilles individuelles ou des zones de feuillage atteintes de pathologies de leurs homologues sains. Dans le cadre de la vigne Al Saddik (2019) et Albetis (2018) parviennent à faire cette distinction pour

---

15. Low Resolution Transmission

16. Model of leaf optical Properties Spectra

17. Scattering by Arbitrarily Inclined Leave

18. Genetic Algorithm K Nearest Neighbours

19. Successive Projection K Nearest Neighbours

différents cépages de raisins rouges et blancs, aussi bien dans des conditions de laboratoire que dans des conditions d'expérimentation au champ. Dans le cadre de pathologies du pommier, Nouri (2017) parvient en conditions de laboratoire à détecter la tavelure du pommier plusieurs jours avant l'apparition de symptômes visibles. Ce sont principalement les bandes d'absorbance de l'eau dans le MIR qui permettent de déterminer précocement les zones pathologiques d'une feuille. Cependant ces études montrent également qu'il n'est pas possible de distinguer entre elles, sur la base d'informations purement spectrales, des pathologies comme l'esca et la flavescence dorée, bien qu'elles présentent des symptômes facilement différenciables à l'œil nu. De plus ces études concluent qu'il est difficile de quantifier la sévérité des pathologies. Certains stades des pathologies, où les symptômes sont encore discrets, sont même indiscernables des cas sains, alors que ce sont les stades d'intervention privilégiés pour la protection des cultures. En outre, il est montré que les erreurs de détection augmentent fortement (pouvant dépasser 30% de faux positifs) en présence de phénomènes confondants, notamment les décolorations dues à des carences et des déficits hydriques. Une autre conclusion intéressante de ces études concerne les bandes spectrales qui permettent de détecter ces pathologies. En effet ces bandes se situent principalement dans le domaine du visible et retranscrivent donc les changements de pigmentation relatifs aux symptômes visibles de ces pathologies. Toutefois, si la composante spectrale est riche en informations, elle n'est pas suffisamment discriminante pour l'épidémiosurveillance. Par ailleurs la composante spatiale que présentent les motifs spécifiques des symptômes des phytopathologies dans le domaine VIS semble porter une information d'intérêt majeur. En effet Al Saddik *et al.* (2018) proposent de combiner l'analyse spectrale avec de l'analyse de texture sur des images couleur usuelles. Cette combinaison innovante permet d'obtenir de meilleurs résultats de détection. Lorsque l'information spectrale permet de détecter des tissus végétaux anormaux subissant des stress, les motifs spatiaux que forment ces anomalies peuvent retranscrire les faciès des symptômes spécifiques de certaines phytopathologies. C'est pourquoi dans le contexte agro-environnemental et notamment l'épidémiosurveillance, certaines études récentes s'appuient sur des analyses de la géométrie et de la texture d'images couleurs haute résolution.

## **1.6 L'analyse d'images couleurs : des méthodes exploitant les motifs spatiaux distinctifs des symptômes visibles**

L'analyse d'images est un outil de prédilection pour les applications d'agriculture de précision qui a fait l'objet de nombreuses recherches ces deux dernières décennies. Elle est utilisée

notamment pour la reconnaissance des adventices (Haug *et al.*, 2014 ; Dyrmann *et al.*, 2016 ; Bakhshipour *et al.*, 2017 ; Louargant *et al.*, 2018), l'estimation de rendement (Abdelghafour *et al.*, 2017 ; Keresztes *et al.*, 2018), le phénotypage (Kumar et Dominic, 2019 ; Lee *et al.*, 2018) ainsi que pour la détection de phytopathologies (Rançon *et al.*, 2018 ; Abdelghafour *et al.*, 2019 ; Boulent *et al.*, 2019). Dans le cadre de l'épidémiosurveillance, l'imagerie couleur, notamment en proxi-détection montre un fort potentiel à détecter *in situ* les symptômes de certaines phytopathologies d'intérêt. Pour l'approche spatiale en analyse d'image, contrairement à l'approche spectroradiométrique, il ne s'agit pas d'exploiter la réflectance ou le spectre de réflectance des pixels pris indépendamment. Dans cette approche, ce sont principalement les interdépendances des pixels qui sont exploitées pour détecter et caractériser des motifs géométriques ou texturaux. L'analyse de texture est une approche très présente en télédétection depuis les années 1960. Elle est particulièrement employée pour la surveillance des territoires et la cartographie de l'occupation des sols (Regniers, 2014 ; Rosu *et al.*, 2016). En revanche en proxi-détection cette approche est plus rare pour le domaine agricole. Il existe tout de même quelques exemples notamment pour la reconnaissance d'adventices au champs (Polder *et al.*, 2007 ; Cointault *et al.*, 2012).

Cependant, dans le cas des phytopathologies, les études réalisées dans les conditions réelles en plein champ sont encore assez rares. En effet, la plupart des recherches conduites en la matière à ce jour se concentrent sur l'analyse de tissus végétaux isolés et observés dans les conditions moins contraignantes d'un environnement contrôlé de laboratoire. Ces études déterminent principalement les méthodes qui permettent de décrire la morphologie, la texture ou la colorimétrie de différentes typologies de symptômes ainsi que d'identifier et comparer les différents algorithmes de classification ou de segmentation adéquats à la détection de phytopathologies. Dans les revues de littératures, ce sont principalement les outils de description texturale, notamment les matrices de cooccurrence et les indices d'Haralick (Haralick *et al.*, 1973) qui sont utilisés au sein de classifieurs supervisés, principalement les SVM et K-NN<sup>20 21</sup> ou non-supervisés, principalement les K-Means (Kumar, 2019). Certaines études récentes cherchent à adapter et combiner des méthodes usuelles du traitement d'images pour la détection de pathologies végétales. Par exemple Han et Cointault (2013) utilisent des espaces hybrides couleur-texture pour segmenter des taches de mildiou sur des feuilles de vignes isolées. Singh et Mistra (2017) combinent des algorithmes génétiques et des SVM pour segmenter différents symptômes fongiques et bactériens affectant le haricot, la banane,

---

20. K-Nearest Neighbours ; K-plus-proches voisins

21. Support Vector Machine ; Machine à vecteur de support

le citron et la rose.

Plus récemment, certaines études (Rançon *et al.*, 2018 ; Abdelghafour *et al.*, 2019 ; Boulent *et al.*, 2019) s'intéressent à l'évaluation *in situ* de l'état sanitaire par l'analyse d'images couvrant de grandes portions de végétation dans lesquels sont disséminés les symptômes. Ces images sont beaucoup plus complexes à traiter dans la mesure où il faut identifier les motifs particuliers des symptômes au sein d'une scène comportant de nombreuses variabilités ainsi que de nombreux types d'anomalies qui sont de potentiels facteurs confondants. Par ailleurs, dans les conditions non-contrôlées, il est possible que les symptômes d'intérêt, les zones saines et les facteurs confondants soient différents d'une image à l'autre. Pour répondre à ces difficultés supplémentaires, les protocoles d'analyse et les méthodes de traitement des données sont plus complexes.

Dans le cadre de la vigne, Rançon *et al.*, (2018) comparent des approches basées sur des réseaux convolutionnels profonds et des méthodes d'encodage de descripteurs structuraux, les descripteurs SIFT<sup>22</sup> pour détecter des feuilles atteintes d'esca dans des images représentant l'ensemble du feuillage d'un pied. Ces deux méthodes permettent non seulement de détecter des feuilles symptomatiques d'esca mais aussi de déterminer la sévérité des symptômes ainsi que de distinguer des symptômes d'esca de facteurs confondants comme des carences, des nécroses, des symptômes de mildiou et de flavescence dorée. Boulent *et al.* (2019) comparent différentes architectures de réseaux convolutionnels profonds pour détecter des zones de feuillage atteintes de flavescence dorée sur des images contenant des carences jaunissantes proches des symptômes de la FD. Ces deux études récentes exploitent des images couleurs acquises en proxidtection dont les résolutions permettent d'observer des détails au sein des différents organes de la vigne.

**Atouts et conditions pratiques de mises en oeuvre de l'imagerie couleur pour la proxidtection des maladies de la vigne :** L'acquisition d'images couleurs en proxidtection est peu onéreuse et facilement automatisable, notamment en comparaison des spectromètres et des imageurs hyperspectraux. Ainsi, grâce à des systèmes embarqués sur des engins agricoles, des robots ou des drones, il est possible de de recueillir des données sur l'ensemble d'un territoire de production. Ces images permettent d'observer les changements de pigmentation relatifs aux pathologies et observables dans le domaine du visible. De plus la haute résolution de ces images permet d'observer des détails dans le feuillage et au sein des

---

22. Scale Invariant Feature Transform

organes de la vigne sans avoir besoin de cibler les zones d'intérêt à l'acquisition. Cette résolution permet l'utilisation de méthodes complexes qui permettent de caractériser les motifs spécifiques que présentent les symptômes des phytopathologies d'intérêt. En outre la densité de mesures dans les parcelles qu'offre cette méthode d'acquisition permet aussi d'analyser la répartition spatiale et la dynamique des symptômes à l'échelle de la parcelle. Cette information supplémentaire permet d'inclure des critères discriminants supplémentaires. Ces propriétés relatives à l'acquisition et à l'analyse d'images couleur font de cette approche spatiale une méthode particulièrement adaptée aux besoins de l'épidémiologie.





# CHAPITRE 2

---

## Dispositif expérimental : matériel végétal, instrumentation et protocole de suivi

---

### 2.1 Les parcelles d'études

#### 2.1.1 Environnement et contexte pédo-climatique du site d'étude

Les parcelles étudiées dans ces travaux appartiennent au vignoble expérimental de l'INRA de Bordeaux du « Domaine de la Grande Ferrade » à Villenave-d'Ornon (33140). Ce dispositif expérimental est piloté par les unités SAVE<sup>1</sup> et EGFV<sup>2</sup>. L'objectif de ce dispositif est d'évaluer l'incidence des pratiques culturales, des génotypes et des phénotypes pour la résistance du vignoble aux phytopathologies dans le contexte du réchauffement climatique. La conduite de ce vignoble expérimental retranscrit à la fois les enjeux et les contraintes de production du vignoble bordelais sur un terroir emblématique de la région. En effet, les parcelles de la Grande Ferrade permettent de produire, vinifier et commercialiser du vin répondant au cahier des charges de L'AOC<sup>3</sup> Pessac-Léognan. Ces parcelles constituent en somme un cas d'étude représentatif pour la filière viticole du Sud-Ouest. L'AOC Pessac-Léognan regroupe 1600 hectares de production répartis sur 10 communes de l'agglomération bordelaise<sup>4</sup>. La figure 5 présente la situation du domaine expérimental dans le vignoble bordelais.

---

1. Santé et Agroécologie du Vignoble, INRA UMR 1065

2. Écophysiologie et Génétique Fonctionnelle de la Vigne, INRA, UMR 1287

3. Appellation d'Origine Contrôlée

4. Cadaujac, Canéjan, Gradignan, Léognan, Martillac, Mérignac, Pessac, Saint-Médard-d'Eyrans, Talence et Villenave-d'Ornon

Cette appellation est issue d'une subdivision de l'appellation historique « terres de Graves »<sup>5</sup>. Pour cette AOC, la production, la récolte des raisins, la vinification, l'élaboration, l'élevage et le conditionnement doivent être réalisés sur l'aire parcellaire de l'appellation. Les vins rouges sont principalement issus d'assemblages des cépages merlot, cabernet-sauvignon, cabernet-franc et petit-verdot. Dans une moindre mesure, l'encépagement rouge peut aussi inclure du malbec (ou cot) et du carménère. Les vins blancs peuvent être issus de mono-cépages ou d'assemblages de sauvignon blanc, de sémillon, de muscadelle et parfois de sauvignon gris. Les parcelles de Pessac-Léognan sont cultivées sur des terroirs dits de « graves », un sol assez pauvre en argile constitué majoritairement de graviers et d'un peu de sable. En surface, ce sol présente de nombreux galets qui accumulent la chaleur du rayonnement solaire la journée et dont l'inertie permet de restituer cette chaleur en soirée. Ce faciès pédologique est très ressuyant, maintient un micro-climat sec et chaud favorable à la culture de la vigne. Le mode de conduite des cultures est caractérisé par une densité de plantation élevée (> 6500 pieds par hectares) avec un écartement faible des rangs (entre 0.8 m et 1.6 m), une hauteur de feuillage modérée (0.6 fois l'écartement) et une densité de feuillage et une production de fruit restreinte par les quotas et les modalités de taille du cahier des charges de l'AOC. Ces propriétés d'implantation de la culture permettent de créer une compétition hydrique forte entre les pieds ce qui modère le développement du feuillage et permet de limiter l'humidité surfacique. De plus cette implantation permet d'obtenir des parcelles aérées qui évacuent facilement l'humidité de surface après des épisodes de précipitations qui peuvent être fréquents dans ce climat océanique. Cet environnement est plutôt favorable à des situations sanitaires saines dans le vignoble notamment par rapport aux pathologies cryptogamiques qui nécessitent soit la présence d'eau de surface soit d'une humidité atmosphérique importante. Malgré ces précautions, le vignoble bordelais reste l'un des plus exposés à ces pathologies.

---

5. décret n° 2011 – 1095 du 9 septembre 1987 du Journal Officiel de la République Française

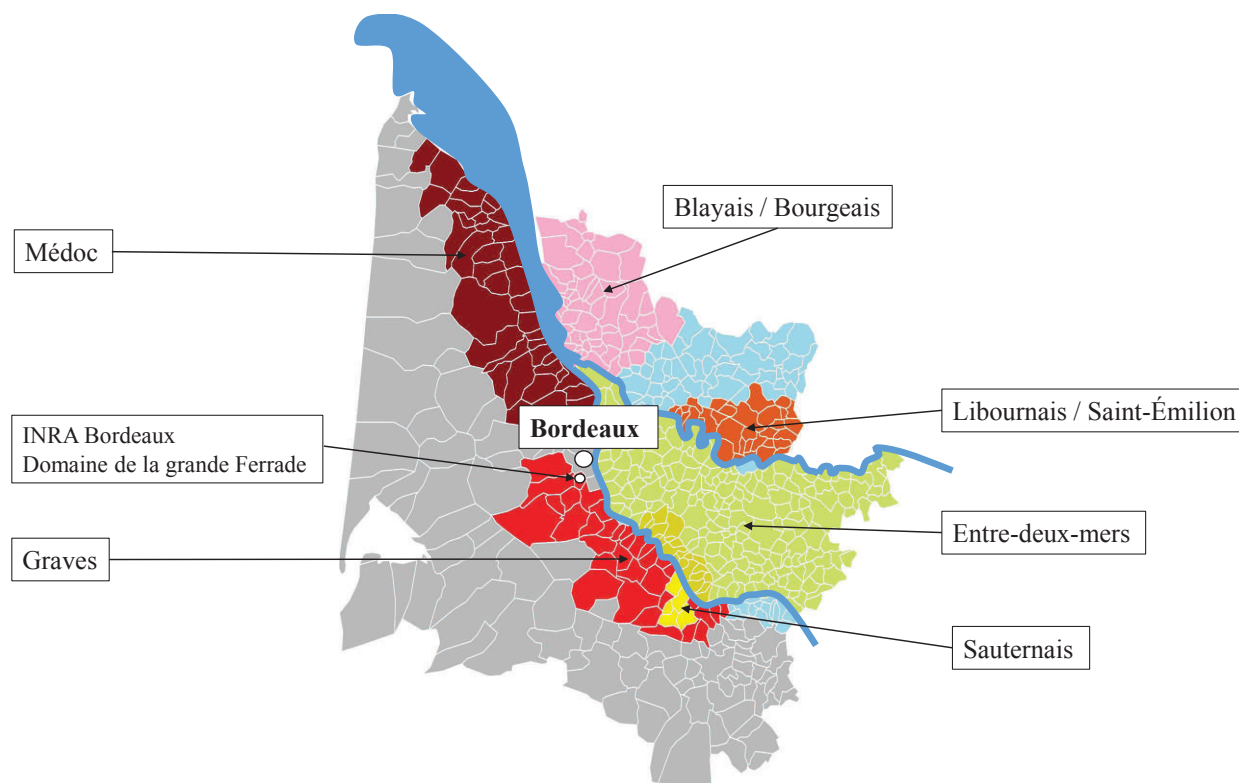


FIGURE 5: Site d'étude dans le vignoble bordelais : Le domaine expérimental de la grande Ferrade (INRA) au sein de l'appellation Pessac-Léognan.

### 2.1.2 Situation sanitaire du vignoble bordelais

Le vignoble bordelais est particulièrement touché par le mildiou. S'il existe des alternances entre des années plutôt clémentes et des années où le mildiou provoquent des pertes considérables de récolte, le coût et le temps consacrés aux opérations de protection contre le mildiou sont toujours élevés. En effet, chaque année les parcelles de témoins non traités (TNT) qui permettent d'évaluer le niveau d'épidémie sont en majorité affectées sévèrement par le mildiou. La différence entre les « bonnes » et les « mauvaises » années réside surtout dans la capacité de la filière à réagir aux différentes phases de contamination. Cette capacité de réaction dépend surtout des conditions météorologiques qui influent sur la précocité de l'épidémie, sur le développement et la sensibilité phénologique des cultures et sur les fenêtres d'intervention climatiques. De plus le vignoble bordelais est parmi les trois vignobles français les plus concernés par le mildiou et qui a le plus recours à des fongicides. En moyenne, l'IFT imputé au mildiou est de 13 sur les trois dernières années (DRAAF Nouvelle-Aquitaine, 2019), ce qui correspond à l'équivalent de 13 applications de fongicides avec la dose unitaire maximale autorisée. Généralement l'ensemble du vignoble est susceptible d'être traité tout au long de la saison contre le mildiou avec des doses variant en fonction de la fréquence des pieds atteints et de l'intensité moyenne d'infection pour chaque parcelle. Certaines années, la totalité du vignoble est traitée avec des fongicides anti-mildiou qui peuvent représenter

jusqu'à 80% de la charge en intrants phytosanitaires (Agreste, 2016). Ce dispositif expérimental est donc approprié à l'observation de symptômes du mildiou à différents stades phénologiques avec différents faciès de symptômes et des sévérités variables. C'est ainsi un cas d'étude générique transposable à l'ensemble du vignoble français concerné par le mildiou et plus généralement par les maladies cryptogamiques.

### 2.1.3 Le dispositif ResIntBio

Le domaine de la grande Ferrade couvre 7.5 ha plantés avec de la vigne. Sur cette surface, différentes parcelles du dispositif ResIntBio ont fait l'objet d'acquisitions d'images. La figure 6 présente la localisation du site d'étude.

Le dispositif ResIntBio datant de 2011 est constitué de six parcelles couvrant 1.8 ha. Elles sont intégrées dans le réseau national DEPHY-EXPE, un réseau d'expérimentations de pratiques et systèmes de cultures économes en pesticides inscrit dans le plan Ecophyto<sup>6</sup>. Ces parcelles font donc l'objet d'un suivi de l'état sanitaire plus important que pour les vignobles commerciaux. Le dispositif a pour objectif de comparer trois systèmes de culture économes en produits phytosanitaires : (i) RES, (ii) INT et (iii) BIO.

(i) **Le système « RES »** pour « résistant », est planté avec la variété hybride « Artaban », génétiquement résistante au mildiou et à l'oïdium. Artaban est un cépage de cuve rouge issu de multiples croisements complexes de quatre espèces du genre *vitis* : (*vitis vinifera*, *vitis rotundifolia*, *vitis rupestris*, *vitis aestivalis*). Ce cépage est issu des travaux sur les variétés hybrides d'Alain Bouquet dans les années 1970 (Bouquet *et al.*, 2009) et les travaux plus récents sur le cépage hybride « Régent » du Julius Kühn Institut en Allemagne. Les parcelles RES ne font l'objet d'aucun traitement phytosanitaire, mais ne présentent cependant pas de symptômes de mildiou. En revanche, le cépage est plutôt sensible à une autre pathologie cryptogamique, le blackrot, qui présente des symptômes de taches nécrotiques qui peuvent se confondre avec le mildiou sur ces images. Ces parcelles permettent à la fois d'observer des témoins négatifs et de conduire des expérimentations sur des facteurs confondants du mildiou.

---

6. Arrêté du 6 octobre 2014 relatif au financement du programme national « Ecophyto 2018 » visant à la réduction de l'usage des pesticides dans l'agriculture

(ii) **Le système « INT »**, pour « lutte intégrée », correspond à une culture conventionnelle de merlot noir pour laquelle l'objectif est de réduire de 50% l'IFT grâce à l'amélioration de l'efficacité de la lutte chimique combinée à des pratiques de protection intégrée. Cette réduction s'accompagne d'une certaine tolérance à la présence de symptômes de mildiou et d'oïdium tant qu'ils n'engendrent pas de pertes de récolte. La protection intégrée est réalisée grâce à la mise en place de mesures prophylactiques limitant la sensibilité des pieds aux maladies, telles que la gestion de l'enherbement, de la vigueur et de l'architecture du feuillage. L'efficacité de la lutte chimique est réalisée à travers un pilotage du positionnement et des doses de traitements en fonction de risques météorologiques et épidémiologiques régionaux. Ce pilotage est dérivé du protocole « mildium<sup>®</sup> » développé conjointement par l'INRA et l'IRSTEA (Delière *et al.*, 2013). Les parcelles INT permettent donc d'observer des symptômes de mildiou dont la répartition et la sévérité sont représentatives de la situation sanitaire du vignoble.

(iii) **Le système « BIO »** est aussi encépagé en merlot noir et intègre les mêmes objectifs d'efficacité de la lutte chimique et de protection intégrée que le système « INT » mais en respectant les pratiques et les produits homologués par le cahier des charges de l'agriculture biologique (AB). L'objectif est de réduire les quantités de cuivre et de soufre apportées dans les parcelles (les principaux agents anti-fongiques utilisés en AB). Ce système prévoit aussi une tolérance aux symptômes et des pertes potentielles de récolte modérées. Comme pour le système INT, le système BIO permet d'observer une dynamique épidémiologique représentative, mais cette fois dans le contexte de l'AB. En effet la conduite biologique des vignobles se popularise et la question de l'usage des pesticides y est tout aussi préoccupante, notamment pour des questions d'enrichissement des sols et de pollution des réseaux hydrographiques en cuivre. De plus les adjuvants d'origine synthétique sont prohibés en AB, notamment les agents d'adhérence et les tensioactifs qui prolongent la durée de protection des produits cuivrés. En leur absence, les opérations de pulvérisation sont généralement plus fréquentes en AB et doivent souvent être renouvelées après les pluies qui lessivent les protections chimiques AB. Ainsi le système BIO permet potentiellement d'observer de manière plus récurrente l'apparition de symptômes précoces, ce qui constitue l'enjeu majeur de l'épidémiologie.




FIGURE 6: Parcelles d'études : dispositifs ResIntBio

## 2.2 Instrumentation : un capteur embarqué autonome pour la cartographie sanitaire des vignobles

### 2.2.1 Un cahier des charges adapté à l'épidémiologie

L'instrumentation utilisée pour acquérir les images de vigne à partir desquelles l'état sanitaire est évalué doit répondre à certaines contraintes inhérentes à l'épidémiologie et aux méthodes de traitement d'images. Premièrement, il faut pouvoir observer la vigne dans son plan de palissage. En effet la vigne est une culture conduite en « haie foliaire », *i.e.* la majorité de sa surface foliaire est présente dans le plan vertical. C'est aussi dans ce plan que sont présents les fruits sur lesquels on peut également observer des symptômes. Ils peuvent se révéler cruciaux lors d'épidémies sévères qui causent des pertes importantes de récolte. Il est donc préférable d'utiliser un capteur terrestre plutôt qu'un vecteur aérien comme un drone afin d'observer la vigne de face plutôt que du dessus. En outre, les symptômes du mildiou et plus généralement des pathologies cryptogamiques sont de petite taille, de l'ordre de quelques centimètres voire quelques millimètres pour les symptômes précoces les plus discrets. Il faut donc être en mesure de réaliser des acquisitions de proximité pour garantir une résolution spatiale suffisante pour observer les détails caractérisant les symptômes à l'étude. De plus l'épidémiologie nécessite en principe une observation fréquente des parcelles avec une couverture dense afin de pouvoir détecter les symptômes au plus proche du début d'une épidémie. Il convient donc d'utiliser un capteur automatisé et embarqué sur un engin pouvant parcourir le vignoble dans la journée. Concernant la nature du capteur, les éléments du chapitre 1 mènent à considérer un imageur couleur, puisque les pathologies

interagissent principalement avec la lumière dans le visible pour former des symptômes dus aux modifications spatiales dans la pigmentation des feuilles. Par ailleurs, l'évaluation de l'état sanitaire à partir d'images repose sur les propriétés statistiques des images. Il s'agit de modéliser différents types de tissus sains et de tissus symptomatiques afin d'établir une règle de décision. Pour ce faire, les images obtenues doivent être les plus homogènes possibles en termes de résolution, de distance et d'angle de capture et surtout d'illumination. Cette homogénéité permet de préserver les propriétés intrinsèques aussi bien des motifs sains que des motifs symptomatiques des tissus telles qu'on peut les observer à l'œil nu. Ainsi les variabilités mesurées dans les images sont majoritairement issues des caractères propres aux tissus plutôt qu'aux sources de variabilité externes. L'obtention de ce pré-requis n'est pas une tâche triviale en particulier dans les conditions non contrôlées du travail en plein champ où les conditions météorologiques et la lumière naturelle peuvent être très variables entre les dates d'acquisition et même au cours du suivi d'une parcelle.

### 2.2.2 Composition du dispositif d'acquisition

Le dispositif utilisé, issu du projet [EARN](#)<sup>7</sup> (Germain *et al.*, 2016), est composé d'une caméra RGB industrielle d'une résolution de 5 Mpx ( $2584 \times 1936$ ) Basler Ace (acA2500-14gc GigE). Cette caméra possède des propriétés nécessaires aux conditions d'acquisition. Cette caméra est robuste aux contraintes de l'environnement agricole telles que les écarts de température élevés, la poussière et l'humidité. Cette caméra est aussi équipée d'un obturateur de type « global shutter », qui contrairement aux caméras grand public (« rolling shutter »), permet d'exposer simultanément l'ensemble de la matrice de capteurs photosensibles. Cette propriété permet de réaliser des photographies sur des temps très courts ( $< 100\mu s$ ) avec une exposition lumineuse homogène et mieux contrôlée de tous les pixels d'une même image. Cette gestion de l'exposition permet d'obtenir des clichés nets même si la caméra est en mouvement ou lorsqu'elle subit des vibrations importantes, ce qui permet de réaliser l'acquisition depuis un engin agricole au travail. De plus, la possibilité de réaliser un cliché sur un temps d'exposition très court permet de mieux contrôler la variabilité de l'illumination naturelle. En effet, la caméra est associée à un puissant flash au xénon de 58 GN<sup>8</sup> (Newer speedlite 750ii) qui permet d'émettre de la lumière à fréquence élevée (jusqu'à 50Hz). Cette association permet de s'affranchir des variations des conditions lumineuses naturelles. En effet, elle permet d'obtenir des images avec une illumination standard tout au long de la

---

7. Estimation Automatique des RendemeNts

8. le Guide Number correspond à la distance exprimée en pieds à laquelle l'intensité lumineuse émise correspond à la norme d'exposition ISO 10157



campagne d'acquisition, quelles que soient les variations de la couverture nuageuse, de l'ensoleillement ou des ombres portées. Cette association permet aussi de créer un effet de « nuit américaine » : le premier plan des images qui contient la végétation d'intérêt est illuminé tandis que le second plan qui contient des éléments non pertinents ou la végétation des autres rangs de culture est rendu obscur par la courte portée du système d'éclairage.

Le dispositif est complété par un récepteur GNSS<sup>9</sup> qui permet de positionner les images dans les parcelles et de retrouver les pieds photographiés. Les coordonnées du capteur permettent aussi de déterminer s'il se trouve dans une parcelle d'intérêt ou si aucune acquisition ne doit être réalisée. De plus, le dispositif contient un télémètre à ultrasons qui permet de détecter la présence d'un pied de vigne à photographier ou s'il s'agit d'un pied manquant. Le télémètre permet également de mesurer la distance à la cible et ainsi de déterminer la taille des pixels des images. Enfin le capteur est complété d'un micro-ordinateur industriel conçu autour d'un processeur ARM à quatre cœurs qui permet de contrôler l'acquisition en fonction des données du GNSS et du télémètre et de stocker les images et les métadonnées. Tous ces éléments sont alimentés par une batterie 12V et fixés au sein d'un boîtier étanche pour former le dispositif d'acquisition présenté à la figure 7(b).



(a) Montage du capteur sur un tracteur vigne



(b) Les éléments du capteur

FIGURE 7: Instrumentation : système d'acquisition viticole autonome (issu du projet EARN)

---

9. Global Navigation Satellite System : système de positionnement par satellites

### 2.2.3 Modalités d'acquisition

Ce capteur est complètement indépendant. Il peut toutefois être contrôlé grâce à une application dédiée et utilisable sur tous les systèmes d'exploitation mobile « Android » à condition d'être à portée du signal WiFi. Ainsi, il peut être monté sur différents types de vecteurs terrestres. Dans le cadre de nos travaux, le capteur est embarqué sur le porte-outil arrière d'un tracteur vigne comme décrit par la figure 7(a). Le capteur est placé à 70 cm du sol et à 50 cm de la cible, permettant que chaque image couvre environ un pied de vigne de la zone fructifère jusqu'au sommet du feuillage avec un léger taux de recouvrement latéral. Cette modalité permet d'observer l'état sanitaire à la même échelle que pour les notations de fréquence et d'intensité estimées par les phytopathologistes avec une résolution d'environ  $4 \text{ px.mm}^{-1}$ . Des acquisitions sont réalisées toutes les semaines sur les parcelles INT et BIO entre les stades phénologiques BBCH 53 « gonflement des inflorescence » et BBCH 83 « mi-véraison » en 2017 ainsi qu'en 2018 (soit entre mai et septembre). Les parcelles RES ont fait l'objet de trois acquisitions chaque année aux stades BBCH 69/70 « fin de floraison, début de nouaison », 75 « petits-pois » et 79 « fermeture des grappes ». La parcelle GreffAdapt a fait l'objet d'une seule acquisition au stade BBCH 79 en 2018. Le tracteur vigne parcourt chaque rang de ces parcelles, ainsi une seule face de chaque pied est photographiée. Les acquisitions sont réalisées à la vitesse de travail conventionnelle du tracteur, *i.e.* entre 3 et 8  $\text{km.h}^{-1}$  selon l'état du sol. La fréquence de capture des images est adaptée à la vitesse d'avancement du tracteur afin de photographier chaque pied. Ainsi ce capteur est capable de réaliser des mesures denses et fréquentes permettant de cartographier entièrement de grandes surfaces d'un vignoble et répond aux besoins de l'épidémiologie.

## 2.3 Les images obtenues pour l'analyse de l'état sanitaire

La figure 8 présente une image caractéristique acquise avec le capteur EARN sur une parcelle INT au stade BBCH 75. Sur cette image, la résolution permet d'observer certains détails au sein des organes. On distingue ainsi la « gaufrure » des feuilles, leurs nervures ou l'insertion des baies de raisin sur leur pédoncule. Cette image contient plusieurs symptômes du mildiou affectant à la fois les feuilles et les fruits qui sont encadrés en rouge sur la figure. A l'échelle de l'image et donc de la plante, ces symptômes caractéristiques sont très ponctuels et disséminés dans la masse du feuillage entremêlé. Ils sont assez difficiles à distinguer à l'œil nu. Pourtant, ce type d'infection constitue déjà un stade suffisamment avancé pour prendre des mesures de protection. Ces symptômes doivent être différenciés des tissus sains, majoritaires dans l'image, mais qui comportent pourtant de nombreuses anomalies sur ces

mêmes images. En effet cet exemple générique présente certains tissus foliaires sains plus clairs que la norme, des nécroses, des décolorations ou même des déchirures. Ainsi pour détecter ces symptômes, il ne s'agit pas simplement d'être en mesure de reconnaître une feuille en bonne santé d'une feuille présentant des anomalies. De plus le contour des organes qui se chevauchent est difficile à déterminer. Afin de détecter ces symptômes, il faut être en mesure de caractériser très spécifiquement les motifs variables provoqués par le mildiou. Ces motifs de petite taille sont quand même observables grâce à la résolution de l'image. La figure 9 présente des vues focalisées sur les symptômes identifiés par les cercles rouges. Sur cette figure il est possible d'observer certaines propriétés particulières à ces symptômes : des gradients progressifs du jaunissement et du brunissement des tissus, un estompement du contour des taches ou encore l'aspect « huileux » des taches. Ces propriétés ont trait à la texture qui est un concept très étudié en analyse d'images pour lequel de nombreuses applications existent dans le domaine agri-environnemental.



FIGURE 8: Une image caractéristique issue du dispositif expérimental. L'image représente le feuillage d'un pied de vigne présentant plusieurs symptômes du mildiou.




FIGURE 9: Exemples de symptômes du mildiou observés sur les images du dispositif expérimental : : symptômes aigus, en haut, et symptômes discrets, en bas.



# CHAPITRE 3

---

## Modéliser conjointement la texture et la couleur dans les images de proxidtection

---

### 3.1 La texture et ses méthodes d'analyse

#### 3.1.1 L'intérêt de la texture pour décrire le couvert végétal

Les images de couverts végétaux peuvent être caractérisées par différents attributs. Il est possible de différencier des types de couverts, d'identifier des espèces, de reconnaître des organes ou de caractériser l'état des tissus grâce à des propriétés morphologiques, colorimétriques ou texturales. Cette tâche est triviale pour les êtres vivants dotés d'une perception visuelle développée. Cependant, sur des images numériques, ces propriétés sont moins évidentes à définir et à modéliser. En effet les images de végétation sont surtout composées de nuances de verts ponctuées de pigmentations rouges, jaunes ou brunes. Ces couleurs sont observables en présence de nombreux phénomènes physiologiques et ne permettent pas à elles seules de caractériser l'état d'une plante, d'un organe ou d'un tissu. Il est également complexe de caractériser les différents objets d'intérêt dans ces images par leurs propriétés morphologiques. Dans le cas de la vigne, la forme et la taille des baies de raisin, relativement constantes, permettent de les caractériser morphologiquement. Le feuillage comporte en revanche beaucoup plus de variabilités géométriques. De plus le contour des feuilles n'est pas évident à définir à cause de l'enchevêtrement des organes, des occultations, des ombres ou des confusions possibles avec les nervures des feuilles, les raffles et généralement toutes les anomalies présentes sur les tissus de la vigne.



Cependant, certaines textures propres aux classes de tissus sont assez distinctives. Par exemple les grappes sont des objets avec une granularité régulière formée de gros éléments sphériques. Les feuilles sont composées de tissus rugueux dont le grain plus fin est irrégulier et entrecoupé de nervures directionnelles. Les tiges et les vrilles sont en comparaison des objets très lisses et directionnels. Les symptômes du mildiou quant à eux créent des irrégularités dans ces motifs qui sont également spécifiques en termes de texture, notamment dans l'organisation de gradients centrifuges au sein des taches d'huile. Ce sont ainsi des propriétés de texture qui sont essentielles à la caractérisation des tissus et de l'état sanitaire. La caractérisation de ces tissus par l'analyse de texture sera présentée plus en détail dans la [partie 3.4](#).

### 3.1.2 Définition de la texture

#### 3.1.2.1 La perception visuelle de la texture : une origine neurologique

La notion de texture réfère à la capacité d'estimer visuellement les sensations tactiles, ou la consistance d'une surface ou d'une substance et de reconnaître des matériaux. Bien que la reconnaissance des textures soit une capacité innée du système de perception visuelle humain, définir cette notion n'est pas trivial. La difficulté provient de la complexité à comprendre et modéliser la nature de l'information que l'être humain capte pour analyser et interpréter une image. Les études en neurosciences et en sciences cognitives appliquées à la perception visuelle humaine en proposent plusieurs définitions. Le neurologue B. Julesz (1962) propose pour la première fois une définition naturaliste de la texture comme « la répétition spatiale d'un même motif dans différentes directions de l'espace ». Haralick (1979) étend cette définition et propose de comprendre la texture comme l'organisation spatiale de motifs primitifs. Gagalowicz (1983) propose une synthèse de ces deux approches comme « une structure spatiale constituée de l'organisation de primitives ayant chacune un aspect aléatoire, donc une structure hiérarchique à deux niveaux ». La vision par ordinateur, s'intéresse particulièrement à cette notion ubiquiste et essentielle à l'analyse d'images. De manière biomimétique, cette discipline vise à modéliser mathématiquement les procédés de reconnaissance visuelle pour automatiser des procédés d'analyse d'images. Finalement, le principe général de ces approches est de décrire voire de modéliser statistiquement les dépendances spatiales locales, c'est-à-dire les dépendances entre pixels voisins (Wei *et al.*, 2009).

### 3.1.2.2 L'analyse de textures

En pratique, cette analyse statistique de la texture aboutit généralement à l'extraction d'un nombre restreint de descripteurs (*i.e.* des caractéristiques visuelles), utilisables ensuite dans des algorithmes de classification (Mueller et Massaron, 2016) ou de segmentation (Coquerez et Bolon, 1995). De nombreux outils ont ainsi été proposés pour réaliser cette représentation statistique. Les principaux outils utilisés pour la reconnaissance et l'analyse de textures sont décrits et catégorisés par exemple par Tuceryan et Jain (1993) ainsi que par Materka et Strzelecki (1998). Une typologie possible est la suivante :

**Les méthodes statistiques descriptives.** Ces méthodes inspirées de la théorie déterministe des textons primitifs de Julesz (1962) visent à décrire la distribution spatiale des intensités des pixels de l'image. Parmi les plus connues, les matrices de cooccurrence décrivent les distributions jointes de paires de pixels (Haralick, 1979). Elles fournissent une description au second ordre des dépendances spatiales entre pixels, généralement suffisante pour la reconnaissance des textures. Difficiles à manipuler en tant qu'objets mathématiques, elles donnent généralement lieu au calcul de descripteurs, par exemple les indices « d'Haralick » (Haralick *et al.*, 1973), utilisés pour des tâches comme la classification ou la segmentation d'images texturées. D'autres méthodes notables du même genre sont les « auto-features » développées par Tuceryan et Jain (1993) ou les méthodes fondées sur les variogrammes (Curran, 1998).

**Les méthodes structurelles** cherchent à décrire la distribution statistique de motifs primitifs. Un exemple d'approche parmi les plus fréquemment employées est la méthode des motifs binaires locaux ou LBP. Le principe est de déterminer la fréquence d'observation de motifs élémentaires formés par des pixels voisins (Ojala *et al.*, 1996).

**Les méthodes paramétriques probabilistes.** Elles sont inspirées des conclusions d'études démontrant que le cortex visuel décompose les images observées en composantes ajustées selon différentes fréquences et orientations remarquables. Ces méthodes exploitent les propriétés multi-fréquentielles de la vision humaine et font appel aux outils de décomposition spatio-fréquentielle. Parmi ces techniques on trouve notamment les transformations de « Fourier » (Zhou *et al.*, 2001), les filtres de Gabor (Manjunath and Ma, 1996 ; Turner, 1986) et les décompositions en ondelettes introduites par Mallat (1989). Ces méthodes rendent possible une modélisation probabiliste de la texture à plusieurs échelles.



Bien entendu, ces catégories sont perméables. Dans le cas de textures orientées, Germain *et al.* (2003) et Da Costa *et al.* (2015) ont proposé des approches statistiques permettant de décrire la distribution spatiale de structures orientées en utilisant les champs d'orientations locales ou de DMV<sup>1</sup>. Plus récemment, Rosu *et al.* (2017) décrivent ces mêmes structures orientées à l'aide du tenseur de structure et en font une modélisation probabiliste leur permettant de mettre en œuvre des approches paramétriques de classification de textures. La texture peut aussi être considérée comme une réalisation de procédés stochastiques. Ainsi, elle peut être décrite par des modèles de champs aléatoires de Markov (MRF<sup>2</sup>) ou des modèles statistiques appliqués à des descripteurs issus de coefficients d'ondelettes (Regniers, 2014) ou de filtres de Gabor (Mathiassen *et al.*, 2002).

## 3.2 Le tenseur de structure local : un outil pour extraire et représenter l'information de texture

Le tenseur de structure (LST<sup>3</sup>) est un outil de référence développé par Bigün (1987) et Knutsson (1989) pour extraire des informations géométriques ou des orientations remarquables dans les motifs locaux d'images d'intensités. Il est communément défini comme la covariance locale de gradients orientés (Bigün *et al.*, 1991). Le tenseur de structure permet de décrire des niveaux de contraste, d'anisotropie ainsi que des orientations principales.

Les champs applicatifs des LST sont divers. Ils ont longtemps été utilisés pour la détection de contours ou d'angles (Harris, 1988 ; Arseneau *et al.*, 2006). Les LST permettent aussi de mesurer le désordre d'un champ de gradients afin de détecter de fortes irrégularités locales. Cette utilisation est appliquée notamment à la détection de failles à partir de données sismiques pour la prospection géologique (Donias *et al.*, 2007 ; Doghraj, 2017). Plus communément, les LST sont utilisés pour la segmentation d'images texturées (Rousson *et al.*, 2003 ; Pham *et al.*, 2015) ou pour classifier des images. Récemment, Rosu *et al.* (2017) proposent d'utiliser les LST pour classifier des images par CBIR<sup>4</sup>. Cette méthode est appliquée à des échelles macroscopiques pour la cartographie des territoires et notamment la classification de parcs ostréicoles et de couverts forestiers ainsi qu'à des échelles microscopique pour la caractérisation de matériaux carbonés nanostructurés (Rosu, 2018).

---

1. Directional Mean Vector = Vecteur Directionnel Moyen

2. Markov Random Fields

3. Local Structure Tensor

4. Content Based Image Retrieval = Recherche d'image par le contenu

Il existe deux familles de méthodes permettant d'estimer des LST. La première, dérivée des travaux originaux de Bigün (1987), est basée sur l'estimation de gradients (Kass et Witkin, 1987; Förstner et Gülch, 1987). La seconde est basée sur l'énergie locale et les filtres en quadrature (Knutsson, 1989). Dans le cadre de ce travail, les LST sont estimés par la méthode des gradients. L'estimation d'un champ de LST d'une image procède en deux étapes.

La première étape consiste à estimer des gradients orthogonaux, dans le voisinage de chaque pixel de l'image. Soit une image  $I$  de taille  $[M \times N]$  pixels, l'image de gradients correspondante  $\vec{\nabla}I$  s'estime par la convolution de  $I$  avec des filtres dérivatifs spatiaux :

$$\vec{\nabla}I = [g_x, g_y]^t = [I * G_x, I * G_y]^t, \quad (3.1)$$

où  $g_x$  and  $g_y$  représentent respectivement les dérivées partielles horizontale et verticale estimées de l'image  $I$ . Le symbole  $*$  désigne l'opérateur de convolution.  $G_x$  et  $G_y$  sont les deux filtres dérivatifs dans les directions horizontale et verticale. Ces filtres peuvent être de différentes natures. Les estimations les plus simples et les plus rapides à l'exécution peuvent être réalisées à l'aide de filtres discrets tels que les opérateurs de Roberts (Davis, 1975) ou de Prewitt-Sobel (Lyvers et Mitchell, 1988). Dans ce travail, les gradients sont estimés de manière très conventionnelle par la convolution linéaire de filtres Gaussiens dérivatifs. Ces filtres sont les dérivées partielles du premier ordre d'une fonction Gaussienne à deux dimensions (Rao et Schunck, 1991) :

$$G_x(x, y) = -\frac{x}{2\pi\sigma_g^4} \exp\left[-\frac{x^2 + y^2}{2\sigma_g^2}\right], \quad G_y(x, y) = -\frac{y}{2\pi\sigma_g^4} \exp\left[-\frac{x^2 + y^2}{2\sigma_g^2}\right]. \quad (3.2)$$

Ces filtres permettent de moduler la taille du voisinage local considéré pour l'estimation des gradients en ajustant la variance  $\sigma_G^2$  du noyau gaussien. Cette modulation permet de s'adapter à l'échelle des textures étudiées.

On obtient ainsi en tout pixel  $(i, j) \in [1, N] \times [1, M]$  de l'image, le couple de gradients  $[g_x(i, j), g_y(i, j)]$  correspondant sur l'image de gradient  $\vec{\nabla}I$ . Pour caractériser la structure locale, on décrit l'organisation de ces gradients par leurs covariances. Pour ce faire, on convolue le produit tensoriel des gradients  $\vec{\nabla}I\vec{\nabla}I^t$  avec un filtre de lissage gaussien 2-D  $W_T$ . La variance  $\sigma_T^2$  du filtre permet d'ajuster une échelle supplémentaire, celle du tenseur. La nature lissante du filtre confère également une certaine robustesse au bruit pixellaire et aux artefacts.

De ce fait, le champ de tenseurs  $Y$  correspondant à l'image  $I$  est obtenu par :

$$Y = W_T * \vec{\nabla} I \vec{\nabla} I^t = W_T * \begin{bmatrix} g_x \cdot g_x & g_x \cdot g_y \\ g_x \cdot g_y & g_y \cdot g_y \end{bmatrix}. \quad (3.3)$$

Ainsi, à tout pixel  $(i, j) \in [1, N] \times [1, M]$  correspond un tenseur de structure  $Y(i, j)$  sous la forme d'une matrice symétrique de taille  $2 \times 2$  :

$$Y(i, j) = \begin{bmatrix} \sigma_{xx}(i, j) & \sigma_{xy}(i, j) \\ \sigma_{xy}(i, j) & \sigma_{yy}(i, j) \end{bmatrix} \quad (3.4)$$

### 3.3 Représentation et modélisation des LST

Les tenseurs de structure étant par essence des matrices de covariance, ils appartiennent à la variété riemannienne des matrices symétriques, semi-définies positives (Rosu, 2018). Ce sont donc des variables dont la manipulation n'est pas triviale. En effet, la plupart des algorithmes de segmentation et de classification, ainsi que les approches de modélisation statistique considèrent comme données des descripteurs assimilables à des variables aléatoires scalaires ou vectorielles. L'application de la géométrie euclidienne ou la modélisation de distributions probabilistes sur ces variables ne sont pas évidentes (Arsigny *et al.*, 2006). Les opérations réalisées doivent prendre en considération les propriétés particulières de cette variété riemannienne. La généralisation des fonctions usuelles de distributions de variables aléatoires aux variétés riemanniennes a fait l'objet de nombreux travaux ces deux dernières décennies. Par exemple, la généralisation des distributions gaussiennes aux variétés riemanniennes a été abordée par Pennec (2006) ainsi que par Lenglet *et al.* (2006). Cependant ces propositions demeuraient incomplètes et reposaient sur des approximations valides uniquement dans certains cas restreints. Ce n'est que récemment que Saïd *et al.* (2017) parviennent à obtenir une expression exacte pour les distributions gaussiennes riemanniennes et proposent des méthodes pour en estimer les paramètres. Ces méthodes ont été notamment employées pour la modélisation de LST dans le but de classifier des textures naturelles issues d'images satellites par Rosu *et al.* (2017).

En pratique, l'estimation des paramètres d'une distribution Gaussienne riemannienne reste difficile et implique une charge calculatoire conséquente. Afin d'assurer une modélisation stable qui représente fidèlement les échantillons de tenseurs observés, il est nécessaire d'avoir recours à des métriques spécifiques comme les métriques Affine-Invariant (AI) (Rosu *et al.*, 2016; Saïd *et al.*, 2017) ou Polaire-Affine (Thanwerdas et Pennec, 2019).

Il existe une autre approche permettant de manipuler ces matrices dans le cadre de modélisations statistiques : l'approche Log-Euclidienne (LE). Introduite par Arsigny *et al.* (2006), elle permet de projeter les matrices de covariance dans un espace euclidien par une transformation logarithmique et d'obtenir ainsi une représentation vectorielle des tenseurs de structure. Dans le domaine logarithmique, les opérations sur ces matrices deviennent euclidiennes. Il est donc possible grâce à l'espace métrique LE de considérer les LST comme des vecteurs modélisables par des distributions gaussiennes multivariées ou des mélanges de gaussiennes. Des résultats expérimentaux démontrent une meilleure stabilité des modèles estimés dans l'espace LE en comparaison de modèles riemanniens AI (Ilea *et al.*, 2018(b)). Des comparaisons réalisées à l'aide de classifications d'images texturées montrent également de meilleures performances pour les modèles dans l'espace LE avec un temps de calcul très inférieur (Rosu *et al.*, 2017). Ces contributions motivent l'adoption de l'espace métrique LE qui permet de considérer les tenseurs de structure comme des vecteurs et de modéliser leurs distributions dans les images de pieds de vigne.

La représentation d'un tenseur de structure  $Y$  dans l'espace LE est réalisée en calculant le logarithme matriciel :

$$Y_{LE} = \log_m(Y) = \begin{bmatrix} \sigma_{LExx} & \sigma_{LExy} \\ \sigma_{LEyx} & \sigma_{LEyy} \end{bmatrix}. \quad (3.5)$$

Considérons la factorisation de la matrice  $Y$  sous la forme :

$$Y = RDR^{-1}, \quad (3.6)$$

où  $D = \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{bmatrix}$  est la matrice diagonale formée par les valeurs propres  $\lambda_1$  et  $\lambda_2$  de  $Y$  (avec  $\lambda_1 \geq \lambda_2$ ).  $R$  est la matrice de rotation composée des vecteurs propres de  $Y$ . Ainsi on obtient le logarithme matriciel comme :

$$\log_m(Y) = R \begin{bmatrix} \log(\lambda_1) & 0 \\ 0 & \log(\lambda_2) \end{bmatrix} R^{-1} \quad (3.7)$$

Comme mentionné par Arsigny (2006), une manière plus simple de considérer le tenseur

dans l'espace LE, est de l'exprimer sous sa forme vectorielle  $\vec{Y}_{LE}$ .

$$\vec{Y}_{LE} = (\sigma_{LExx}, \sigma_{LEyy}, \sqrt{2}\sigma_{LExy})^t, \quad (3.8)$$

Sous cette forme le coefficient  $\sqrt{2}$  permet d'assurer l'égalité suivante :

$$\|\vec{Y}_{LE}\| = \|Y_{LE}\|, \quad (3.9)$$

*i.e.* la norme euclidienne de la forme vectorielle est égale à la norme de Frobenius de la forme matricielle. Cette propriété permet d'appliquer des opérations euclidiennes à la forme vectorielle sans distorsion des propriétés tensorielles.

### 3.4 Caractérisation de textures végétales par le tenseur de structure

Afin d'évaluer si les propriétés fournies par le tenseur de structure peuvent décrire et discriminer les motifs texturaux spécifiques des principaux tissus d'intérêt dans nos images, la présente partie consiste à déterminer le pouvoir discriminant du tenseur de structure à l'échelle locale, *i.e.* à celle d'un tissu ou d'un groupe d'organes, et à l'échelle globale de l'image, *i.e.* de la plante. Cependant, sous leur forme brute (*i.e.* la forme matricielle), les tenseurs de structure sont difficiles à représenter et à visualiser. Généralement pour qualifier les propriétés d'un champ de tenseurs sur une image, il est d'usage de représenter indépendamment trois propriétés fondamentales du tenseur : l'orientation, l'énergie et l'anisotropie (Akl, 2016). Ces trois propriétés s'expriment comme des scalaires issus de la décomposition en éléments propres du tenseur  $Y = RDR^{-1}$ . Dans cette décomposition, les valeurs propres sont liées aux amplitudes des gradients locaux tandis que les vecteurs propres désignent les directions principales de ces gradients (Weickert et Hagen, 2006). Ainsi le premier vecteur propre  $u_1 = (u_{1x}, u_{1y})$  d'un tenseur indique la direction de plus forte variabilité dans un voisinage local. Cette direction est donc orthogonale à l'orientation locale du motif textural ( $\theta = \arctan \frac{u_1(y)}{u_1(x)}$ ). L'anisotropie (également appelée cohérence) exprime le caractère directionnel d'une texture. Elle décrit, si elle existe, une direction dominante des gradients locaux ou si les directions des gradients sont plutôt équidistribuées *i.e.* si la texture est isotrope. Elle se calcule en comparant les valeurs propres entre elles ( $\eta = [\frac{\lambda_1 - \lambda_2}{\lambda_1 + \lambda_2}]$ ). L'énergie décrit la dynamique locale des gradients, c'est une forme de mesure de contraste. Elle se calcule comme la somme des valeurs propres ( $E = \lambda_1 + \lambda_2$ ).

Dans le cas des textures étudiées dans nos images, l'orientation dominante ne possède pas de pouvoir discriminant. En effet les différents tissus doivent pouvoir être caractérisés de la même manière quelle que soit leur orientation dans l'espace, sachant que cette orientation peut être variable selon la position du tissu dans la plante. Il est donc proposé d'observer les propriétés globales d'énergies et d'anisotropies qui permettent de différencier les classes de tissus entre-elles. Une manière visuellement commode pour étudier ces propriétés est de représenter et décrire parallèlement les valeurs propres des tenseurs. Dans les figures suivantes (10, 11 et 12), les champs de tenseurs de structure sont calculés avec les paramètres  $[\sigma_g = 3.5, \sigma_t = 5.5]$ .

La figure 10 représente la capacité à discriminer localement des feuilles et des grappes sur la bases des valeurs propres  $\lambda_1$  et  $\lambda_2$  du tenseur de structure. Ces valeurs propres sont représentées par une même palette de couleurs qui retranscrit une échelle normalisée sur 8-bits (0 correspond au minimum de  $\lambda_2$ , 255 correspond au maximum de  $\lambda_1$ ). Trois situations sont présentées : la situation (a) présente de jeunes organes de petite taille, (b) présente une grappe « non fermée » isolée en avant plan d'une feuille développée présentant une gaufre, (c) représente une grappe « fermée » sur un tapis de feuilles exposant à la fois des faces supérieures et des faces inférieures. Dans les trois situations, il est facile d'identifier la grappe par rapport à la feuille. En effet les feuilles, qu'elles soient plus ou moins lisses ou rugueuses, présentent des valeurs faibles pour  $\lambda_1$  et  $\lambda_2$  (entre 0 et 90), tandis que les grappes exhibent des valeurs fortes (entre 180 et 250). Les deux classes de tissus sont relativement isotropes avec des structures dont l'énergie est significativement plus faible pour les feuilles que pour les grappes. Le contour des feuilles ainsi que certaines nervures sont également distinctes par leur anisotropie. Elles sont visibles sur l'image de la première valeur propre ( $\lambda_1$ ) et beaucoup moins discernables sur la deuxième valeur propre ( $\lambda_2$ ).

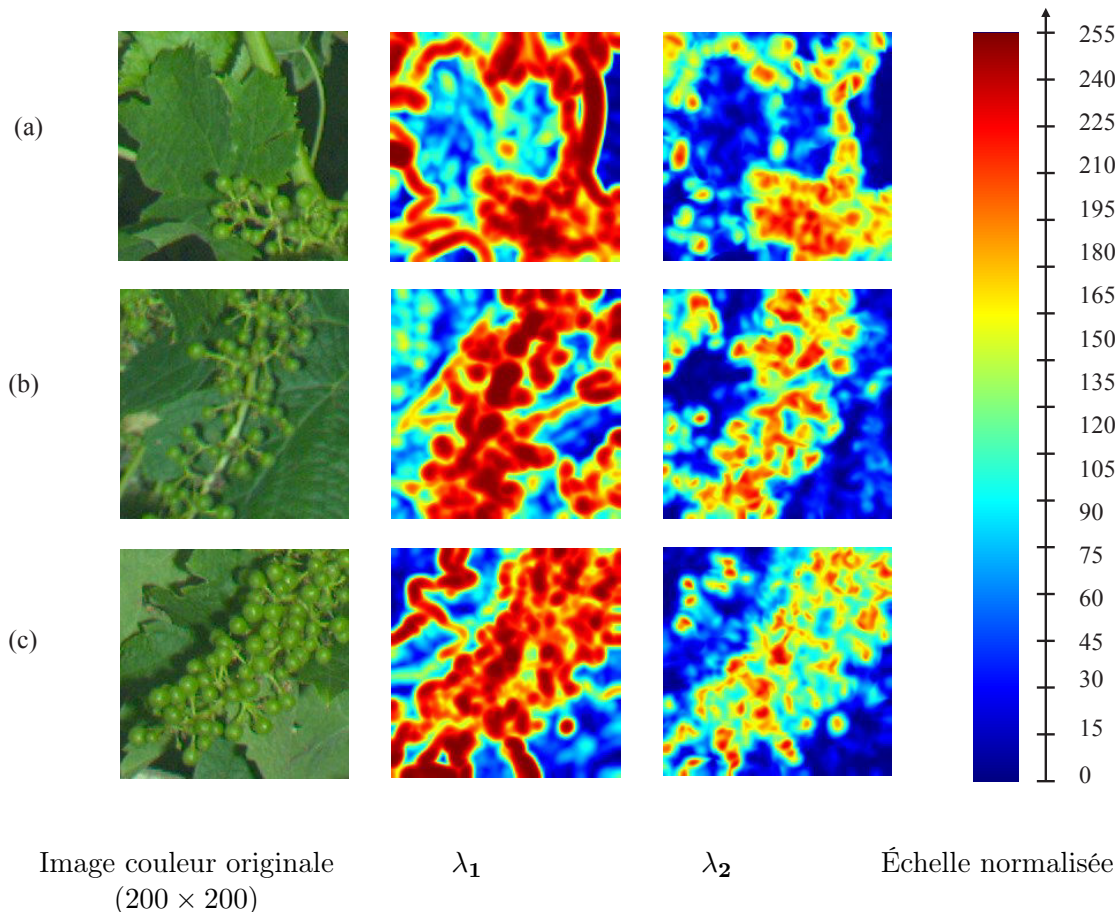


FIGURE 10: Pouvoir discriminant du tenseur de structure à l'échelle locale : séparabilité des feuilles et des grappes à partir des valeurs propres  $\lambda_1$  et  $\lambda_2$  du tenseur sur une échelle normalisée de 8-bits. Trois situations sont présentées (a) , (b) et (c)

La figure 11 illustre la capacité à discriminer localement les tiges du feuillage. Les tiges, qui peuvent être de différents diamètres, se distinguent par de fortes valeurs propres ( $\lambda_1$ ). Cependant, il est possible dans certains cas d'observer des valeurs propres fortes sur des nervures ou sur les contours des feuilles (*e.g.* sur la figure 10). Les tiges sont également très directionnelles et possèdent un niveau d'anisotropie ( $\eta$ ) plus fort et plus constant que les nervures et les bordures de feuilles. En effet, la seconde valeur propre ( $\lambda_2$ ) sur les tiges est plus faible que celles exprimées sur le feuillage, les grappes et les nervures.




FIGURE 11: Pouvoir discriminant du tenseur à l'échelle locale : séparabilité des tiges à partir des valeurs propres  $\lambda_1$  et  $\lambda_2$  du tenseur sur une échelle normalisée de 8-bits.

La figure 12 représente la capacité à distinguer des taches de mildiou sur les feuilles. Trois situations sont présentées : (a) tache circulaire large , (b) ensemble de petites taches et (c) symptômes sur les bordures. Dans le cas (a) on peut distinguer facilement la tache de mildiou, dont les valeurs propres sont moyennes (entre 100 et 120), qui se détache de la feuille. Dans le cas (b) on distingue aussi quelques taches mais dont les valeurs, surtout au centre des taches peuvent se confondre avec celles qu'on retrouve aux frontières entre les tissus et aux abords des nervures. Dans le cas (c), les valeurs correspondant aux taches sont moyennes dans le limbe mais sont indiscernables aux abords des feuilles.






FIGURE 12: Pouvoir discriminant du tenseur à l'échelle locale : séparabilité des symptômes foliaires du mildiou à partir des valeurs propres  $\lambda_1$  et  $\lambda_2$  du tenseur sur une échelle normalisée de 8-bits. Trois situations sont présentées (a) tache circulaire large , (b) ensemble de petites taches et (c) symptômes sur les bordures

Ainsi à l'échelle locale, les valeurs propres du tenseur de structure réduites sur 8-bits permettent de discriminer entre eux des tissus appartenant à des organes différents. Dans une certaine mesure, ces valeurs propres permettent aussi de discriminer les parties symptomatiques des parties saines des feuilles. Cependant, il est impossible dans ces conditions de déterminer un seuil ou un intervalle de valeurs qui déterminent l'appartenance à une classe de tissu. A l'échelle d'une image cette difficulté est encore plus présente. La figure 13 représente la distribution des valeurs propres dans une image représentant un pied de vigne complet. Si on distingue toujours globalement des différences entre les feuilles, leurs contours, les grappes et les tiges, les tissus symptomatiques sont indiscernables à cette échelle. Les variabilités locales dans l'image impliquent ainsi une certaine complexité à attribuer des classes de tissus en fonction des valeurs du tenseur de structure. Ce problème sera étudié par la modélisation de la distribution des tenseurs de structure dans chaque classe (voir [partie 3.5](#)).




FIGURE 13: Pouvoir discriminant du tenseur à l'échelle de l'image ( $2592 \times 2048$ ) : séparabilité globale des organes de la vigne à partir des valeurs propres  $\lambda_1$  et  $\lambda_2$  du tenseur sur une échelle normalisée de 8-bits.

Un autre point essentiel à considérer est le caractère d'échelle propre au tenseur de structure. En effet, sa valeur est liée aux paramètres d'échelle ( $\sigma_g$  et  $\sigma_t$ ). Il faut donc déterminer l'échelle d'observation la plus cohérente et la plus discriminante possible. La figure 14 présente l'énergie du tenseur calculée pour différents couples d'échelles : (a)  $[\sigma_g = 1.5, \sigma_t = 3.5]$ , (b)  $[\sigma_g = 1.5, \sigma_t = 5.5]$  et (c)  $[\sigma_g = 3.5, \sigma_t = 5.5]$ . A chaque échelle, on peut distinguer clairement les différentes classes présentes. Cependant, il est difficile de déterminer ainsi l'échelle qui décrit et discrimine au mieux ces différentes classes. Pour répondre à cette question il est proposé d'évaluer les performances de classification des tissus en fonction de l'échelle (voir chapitre 4).

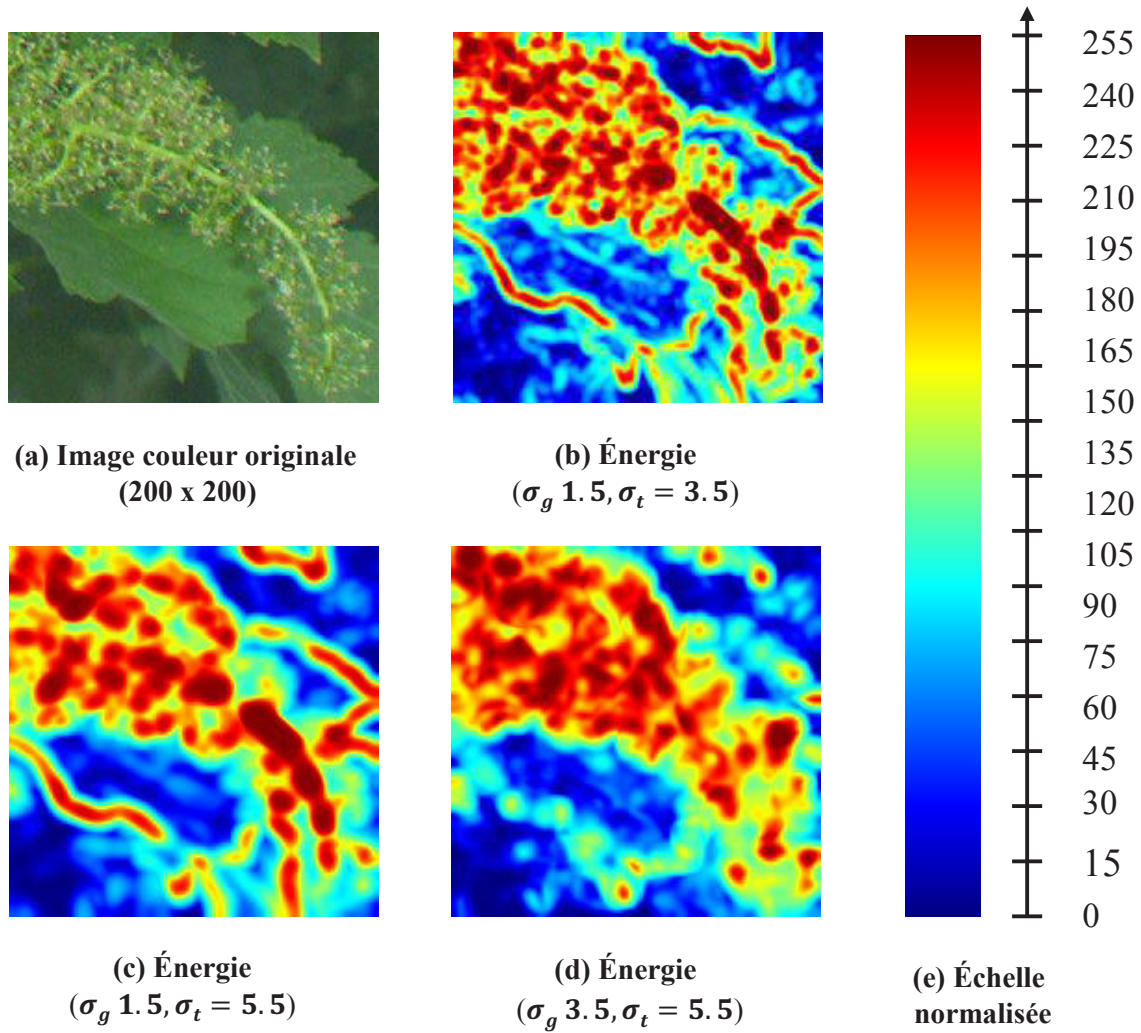


FIGURE 14: Propriétés d'échelle du tenseur de structure : comparaison de la distribution normalisée des énergies pour trois couples d'échelles (b, c et d) sur l'exemple d'une inflorescence (stade BBCH 68)

## 3.5 Modélisation paramétrique des tenseurs de structure

### 3.5.1 Modèles gaussiens multivariés dans l'espace Log-Euclidien

On propose de modéliser la distribution des tenseurs de structure au sein des différentes classes de tissus d'intérêt par des densités de probabilités gaussiennes. Plusieurs auteurs ont déjà proposé des modèles gaussiens adaptés au tenseur de structure, que ce soit directement sous sa forme matricielle avec des modèles gaussiens riemanniens ou sous sa forme vectorielle dans l'espace Log-Euclidien (Saïd *et al.*, 2017; Ilea *et al.*, 2018(a)). L'estimation et la mise en pratique de ces modèles ont été étudiées par Rosu (2018) dans le cadre de la classification de textures naturelles issues d'images satellites.

Dans le cadre de la proxidtection et de l'épidémiosurveillance, cette partie étudie l'adéquation et le comportement de ces modèles à l'échelle de petites régions texturées. Contrairement aux précédentes propositions de modélisation des tenseurs de structure, il s'agit non pas de modéliser la structure à l'échelle de l'image ou d'une partie significative de l'image, mais de procéder à l'échelle locale d'un pixel et de son voisinage. Dans le cadre de ces travaux, les tenseurs sont considérés sous leur forme vectorielle dans l'espace Log-Euclidien. Considérons les six classes d'intérêt suivantes : les feuilles, les grappes, les tiges, les symptômes foliaires du mildiou, les symptômes du mildiou sur grappes, et les autres anomalies (nécroses, carences, impacts de grêles). Dans chacune de ces classes, il est possible de modéliser la population des tenseurs de structure LE par une distribution gaussienne multivariée de dimension  $D$ . Pour une classe donnée, sa densité de probabilité est donnée par :

$$p(\vec{Y}_{LE}|\vec{\mu}, \Sigma) = \frac{1}{\sqrt{(2\pi)^D|\Sigma|}} \exp\left[-\frac{1}{2}(\vec{Y}_{LE} - \vec{\mu})^t \Sigma^{-1}(\vec{Y}_{LE} - \vec{\mu})\right], \quad (3.10)$$


où  $\vec{\mu}$  désigne le vecteur de taille  $[D \times 1]$  moyen du modèle,  $\Sigma$  sa matrice de covariance de taille  $[D \times D]$  et  $|\Sigma|$  le déterminant de la matrice de covariance.

Pour vérifier l'adéquation de la distribution des tenseurs de structure à une densité de probabilité gaussienne multivariée, il est possible d'utiliser une propriété remarquable de la transformation des matrices de l'espace riemannien vers l'espace LE. Cette propriété décrite par Saïd *et al.* (2017) énonce l'équivalence suivante : si la distribution des log-déterminants d'un ensemble de tenseurs de structure est gaussienne, alors l'ensemble des matrices suivent une distribution gaussienne riemannienne et les formes vectorielles dans l'espace LE suivent une distribution gaussienne multivariée.


La figure 15 présente la distribution des valeurs des log-déterminants des tenseurs pour les 6 classes précédemment définies (les tenseurs sont calculés avec les paramètres  $[\sigma_g = 1.5, \sigma_t = 3.5]$ ). Pour chacune des classes, la loi gaussienne théorique de paramètres  $(\mu, \sigma)$  est représentée en rouge sur la figure. Les paramètres de la loi sont estimés à partir d'un échantillon de tenseurs de structure calculés sur des pixels dont la classe d'appartenance est connue. Les échantillons sont issus de 100 images, sur lesquelles sont collectés des effectifs allant de  $1.5 \times 10^4$  à  $1.9 \times 10^6$  tenseurs de structure par classe. Ces effectifs dépendent de l'abondance relative des classes dans l'ensemble d'images d'apprentissage, ils sont notés pour chaque classe. Sur la figure 15 on peut observer qu'à l'exception des classes « mildiou sur grappes » et « anomalies », toutes les distributions sont proches d'une densité de probabilité théorique gaussienne, dont les paramètres sont la variance empirique et la moyenne empirique de la distribution. Pour les classes « mildiou sur grappes » et « anomalies » des modèles de




mélange de gaussiennes semblent pouvoir représenter les distributions. Pour les autres classes, on peut observer que les distributions présentent de légères asymétries. De plus, il semble que le mode de la distribution est également légèrement décalé par rapport à la moyenne. Ainsi il est proposé dans la [partie 3.5.2](#) d'étudier des modèles de mélanges de gaussiennes pour toutes les classes.




(a) Distribution des log-déterminants : classe « feuilles »




(b) Distribution des log-déterminants : classe « grappes »




(c) Distribution classe des log-déterminants : « tiges »



(d) Distribution classe des log-déterminants : « mildiou feuilles »



(e) Distribution des log-déterminants : classe « mildiou grappes »



(f) Distribution classe des log-déterminants : « anomalies générales »

FIGURE 15: Adéquation des distributions des log-déterminants des tenseurs de structure à des densités de probabilité gaussiennes au sein des 6 classes d'intérêt

### 3.5.2 Modèles gaussiens de mélange

Certaines classes ne peuvent clairement pas être représentées par un unique modèle gaussien mais semblent être proches de modèles de mélange mieux adaptés à leur hétérogénéité. Si les autres classes semblent suivre des distributions gaussiennes multivariées, elles sont par construction non-homogènes. En effet, la classe des feuilles regroupe des feuilles observées par leur face supérieure et d'autres par leur face inférieure. Ces deux faces possèdent des propriétés texturales *a priori* différentes. Tandis que la face supérieure est granulaire du fait de la présence de « gaufrure », la face inférieure est plus lisse et présente une « micro pilosité » à plus petite échelle. Il en est de même pour la classe des symptômes foliaires du mildiou : il existe différents faciès plus ou moins précoces et plus ou moins sévères et des symptômes de différentes tailles. On peut donc supposer l'existence de sous-classes qui suivent chacune une distribution gaussienne de paramètres différents. Par exemple, la figure 15(e) semble présenter une distribution composée de deux ou trois lois gaussiennes. On propose donc de modéliser également les distributions de chacune des classes de tenseurs par un mélange de gaussiennes multivariées. La densité de probabilité correspondant au mélange de  $K$  distribution gaussiennes multivariées s'exprime comme la somme pondérée des densités de probabilité de  $K$  modèles gaussiens. Elle est définie par l'équation 3.11 :

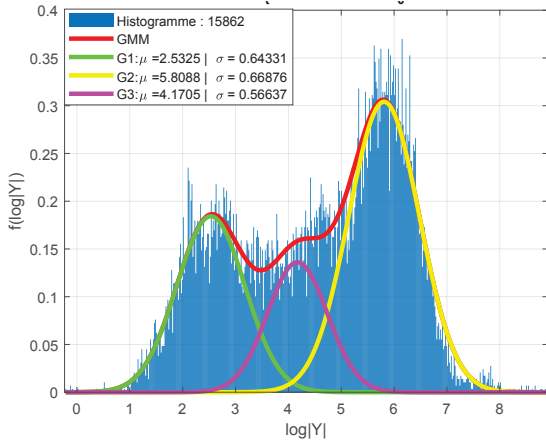
$$p(\vec{Y}_{LE} | (\omega_k, \vec{\mu}_k, \Sigma_k)_{k=1:K}) = \sum_{k=1}^K \omega_k p(\vec{Y}_{LE} | \vec{\mu}_k, \Sigma_k), \quad (3.11)$$

où  $\vec{\mu}_k$  et  $\Sigma_k$  représentent respectivement le vecteur moyen et la matrice de covariance *i.e.* les paramètres empiriques de la  $k^{ieme}$  distribution gaussienne multivariée du mélange.  $\omega_k$  représente le poids de chacune des distributions du mélange avec  $\omega_k > 0$  et  $\sum_{k=1}^K \omega_k = 1$ . Les paramètres  $(\omega_k, \vec{\mu}_k, \Sigma_k)_{k=1:K}$  du mélange peuvent être estimés grâce à l'algorithme « Expectation-Maximization » (EM) : *e.g.* (Bilmes, 2000) qui déduit le modèle qui maximise la vraisemblance des données au mélange.


La figure 16 représente l'adéquation des classes à des modèles de mélange observés à travers la distribution des log-déterminants (les tenseurs sont calculés avec les paramètres  $[\sigma_g = 1.5, \sigma_t = 3.5]$ ). Les classes « mildiou sur grappes » (a,b) et « anomalies » (c,d), qui ne peuvent pas être modélisées par une seule loi gaussienne sont présentées. Il est aussi proposé de comparer l'adéquation à un modèle de mélange avec l'adéquation à la loi gaussienne pour l'exemple de la classe « mildiou sur feuilles » (e,f). La figure 16(a) représente les trois noyaux gaussiens  $(G_1, G_2, G_3)$  constituant le mélange (GMM) décrivant la classe. Avec trois noyaux,

il semble alors possible de mieux représenter la classe. La figure 16(b) montre la différence d'adéquation de la distribution entre le modèle de mélange et la loi gaussienne simple ( $G$ ). Les figures 16 (c,d) décrivent respectivement les mêmes phénomènes pour la classe « anomalies ». Cependant, pour cette classe, un mélange à deux noyaux est le plus ressemblant à la distribution empirique. Pour la classe « mildiou sur feuilles » qui est relativement proche d'une distribution gaussienne, la figure 16(e) présente une forte ressemblance à un mélange à trois noyaux. La figure 16(f) montre que le mélange représente mieux l'asymétrie de la distribution, le mode ainsi que les parties marginales de la distribution. Finalement le mélange obtenu est légèrement plus vraisemblable. Une autre comparaison des modèles gaussiens multivariés et des modèles de mélanges est présentée par une évaluation des performances de classification relatives des deux approches dans le chapitre 4.






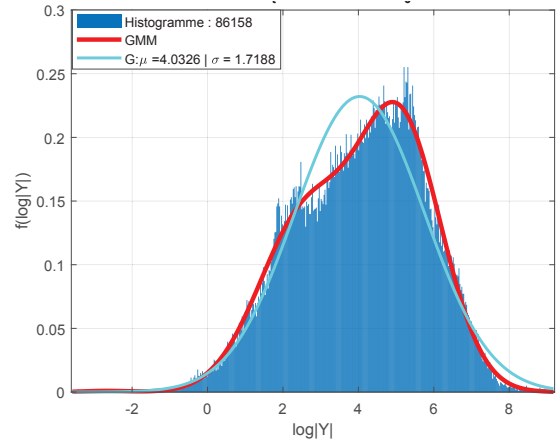
(a) Adéquation au mélange : classe « mildiou grappes »




(b) Comparaison mélange - gaussienne unique : classe « mildiou grappes »




(c) Adéquation au mélange : classe « anomalies »



(d) Comparaison mélange - gaussienne unique : classe « anomalies »



(e) Adéquation au mélange : classe « mildiou feuilles »



(f) Comparaison mélange - gaussienne unique : classe « mildiou feuilles »

FIGURE 16: Adéquation des distributions des log-déterminants des tenseurs de structure à des densités de probabilité de mélanges de gaussiennes pour les classes « mildiou grappes » (a,b), « anomalies »(c,d) et « mildiou feuilles »(e,f). Les figures (a,c,e) présentent après pondération les  $K=3$  gaussiennes (G1,G2,G3) composant le mélanges (GMM). Les figures (b,d,f) comparent l'adéquation des mélanges GMM et les lois gaussiennes (G).

**Bilan intermédiaire** Cette première partie du chapitre vise à caractériser les différents tissus d'intérêt dans les images étudiées à l'aide du tenseur de structure. La [partie 3.4](#) a présenté le potentiel des tenseurs de structure à discriminer les différents tissus d'intérêts entre-eux, *i.e.* les valeurs que prennent les tenseurs de structure sont globalement différentes pour les organes et les symptômes considérés. La [partie 3.5](#) a montré qu'il est possible de modéliser de manière probabiliste la distribution des tenseurs dans chaque classe de tissus. Grâce à une transformation logarithmique des tenseurs de structure dans l'espace euclidien, il devient possible d'étudier des modèles usuels de l'espace euclidien. Les modèles gaussiens multivariés considérés constituent une représentation adéquate de la distribution des tenseurs de structure. De plus, il a été montré qu'il est possible de représenter correctement les populations étudiées à partir d'un ensemble d'échantillons relativement restreint et que cet ensemble permet d'estimer des paramètres tels que les modèles obtenus soient convaincants. A l'issue de cette partie, on dispose donc d'un descripteur textural pertinent et modélisable pour chacune des classes de tissus d'intérêt et qui permet de les discriminer entre-elles. La suite de ce chapitre a pour objectif d'enrichir le descripteur formulé en prenant en compte l'information colorimétrique et d'étudier l'adéquation de nouveaux descripteurs étendus à la couleur pour les modèles considérés.

## 3.6 Extraire et représenter l'information colorimétrique conjointement à l'information de structure

### 3.6.1 La notion de couleur et ses représentations

La couleur est le résultat de l'interprétation spectrale par le cortex visuel de la lumière incidente qui stimule les photorécepteurs de la rétine appelés « cônes » (Le Grand, 1972). Biologiquement, la couleur est encodée en trois composantes relatives à la sensibilité spectrale de chacune des trois familles de cônes à une plage de longueur d'onde : une composante relative au bleu, une au vert et une dernière au rouge. Cependant, lors de l'interprétation psychovisuelle, ces signaux sont combinés pour former trois nouvelles composantes. Une première composante achromatique relative à la luminance et deux composantes chromatiques (Roorda et al., 2001). Ainsi la couleur est par nature une information décrite par une composante vectorielle à trois dimensions au minimum.

Les espaces couleurs permettent d'exprimer numériquement l'information de couleur. Pour rendre compte de la trivalence de la vision humaine, la couleur est généralement représentée par un triplet qui correspond à ses coordonnées uniques dans l'espace choisi. Il existe différents espaces adaptés aux contraintes physiques de mesure, d'affichage et d'impression des couleurs ainsi que certains espaces dits « perceptuels » plus adaptés à l'analyse des couleurs. Ces espaces sont décrits et catégorisés par Levkowitz (2007) de la manière suivante.

### 3.6.1.1 Les espaces primaires.

**L'espace RGB.** Espace le plus conventionnel, il est constitué de trois composantes monochromatiques associés aux longueurs d'onde Bleue (435.8nm), Verte (546.1nm) et Rouge (700nm). Ces composantes constituent les axes du cube RGB dont l'origine nulle est le noir. Il est utilisé pour synthétiser et afficher de manière additive des images sur des écrans et correspond à la mesure physique réalisée par les capteurs photosensibles des caméras RGB.

**L'espace XYZ.** Cet espace représente la couleur grâce à trois composantes primaires X, Y et Z. Il permet de représenter des couleurs qui sont impossibles à formuler par synthèse additive dans l'espace RGB. L'espace XYZ est une transformation linéaire de l'espace RGB par rapport à une référence du blanc.

**L'espace CMY.** Cet espace est dédié à l'impression des couleurs et repose sur le principe de synthèse soustractive. Comme l'espace RGB, il est représenté par un cube mais dont l'origine est le blanc et dont les axes sont définis par les trois composantes C (Cyan), M (Magenta) et Y (Yellow, Jaune). Ces composantes sont respectivement les opposées des primaires R, G et B.

### 3.6.1.2 Les espaces perceptuels.

Ces espaces tendent à correspondre à la perception visuelle humaine en considérant des composantes chromatiques et une composante achromatique relative à l'intensité ou « la clarté » de la couleur.

**Les espaces HSV et HSL.** Ces espaces sont des représentations cylindriques de la couleur issues de déformations non linéaires du cube RGB. Ils permettent de définir la couleur grâce à trois composantes. Un axe achromatique qui relie le noir au blanc soit en intensité (Value en anglais :  $V = \max[R, G, B]$ ) soit en Luminosité (Lightness  $L = \frac{1}{2}(\max[R, G, B] + \min[R, G, B])$ ). Les composantes chromatiques sont définies par des coordonnées dont l'angle représente la Teinte (Hue en anglais), *i.e.* l'association à une couleur primaire, et dont le rayon représente la Saturation, *i.e.* la pureté de cette couleur primaire. En pratique, ces espaces sont restreints, *i.e.* toutes les coordonnées possibles du cylindre ne correspondent pas à une couleur réelle. Ainsi l'espace HSV est contenu dans un cône tandis que l'espace HSL est contenu dans un double cône à base hexagonale.

**Les espaces L\*a\*b\* et L\*u\*v\*.** Ces espaces sont aussi appelés « espaces perceptuels uniformes ». Contrairement aux autres espaces, ils permettent de concevoir la notion de dissimilarité entre couleurs. La distance euclidienne entre deux triplets se rapproche de la différence perceptuelle entre les deux couleurs (Coquin *et al.*, 2002). Ils sont tous les deux obtenus par des transformations non linéaires de l'espace XYZ. Pour l'espace L\*a\*b\*, L\* est la composante achromatique de clarté tandis que les composantes a\* et b\* représentent respectivement les composantes chromatiques de l'opposition de couleur vert-rouge et de l'opposition de couleur bleu-jaune. Pour l'espace L\*u\*v\*, la composante L\* est identique, les composantes u\* et v\* quant à elles représentent les mêmes oppositions de couleur respectives, mais la transformation depuis les coordonnées XYZ est différente.

### 3.6.1.3 Les espaces indépendants

Ces espaces sont définis de manière à décrire la couleur par une décomposition en trois variables décorréées.

**L'espace  $X_1X_2X_3$**  Cet espace est obtenu à partir d'une analyse en composantes principales (ACP) des couleurs RGB d'une image. Généralement la composante  $X_1$  qui est responsable du maximum de variabilité correspond à une forme de clarté. Cependant, la décomposition d'une couleur est dépendante de l'image dans laquelle elle est considérée. Deux couleurs identiques issues d'images différentes seront donc décomposées suivant des axes différents.

**L'espace  $I_1I_2I_3$  d'Otha** Cet espace correspond aussi à une décomposition issue d'une ACP mais sur la base d'une composante d'intensité et de deux composantes chromatiques qui représentent respectivement les oppositions bleu-rouge et magenta-vert.

## 3.6.2 L'étude des relations entre texture et couleur

La couleur et la texture sont deux propriétés naturellement liées. C'est cette relation complexe qui permet au système de perception visuel humain d'interpréter une image. Expérimentalement, on constate que les observateurs possèdent une meilleure capacité à estimer, à différencier et à segmenter des couleurs, des intensités et des régions colorées en présence de motifs texturaux. Réciproquement, le discernement des textures est exacerbé en présence de couleurs (Montag et Berns, 2000 ; Xin *et al.*, 2005 ; Lin, 2011). Ces deux notions jouent donc un rôle complémentaire dans la caractérisation des images. Par exemple, Trussel *et al.* (2011) parviennent à modéliser la perception de micro-variations dans les textures en reliant la fonction de transfert optique de l'œil humain à sa réponse fréquentielle aux couleurs. Le développement de méthodes décrivant l'interaction entre la couleur et la texture présente donc un intérêt majeur pour l'analyse d'images de grande complexité (Pietikäinen *et al.*, 2002). Si la motivation est claire, l'obtention d'une représentation mathématique conjointe cohérente de la texture et de la couleur reste encore un problème ouvert (Whelan et Ghita, 2008).

Une texture-couleur peut être considérée comme un motif décrivant la relation entre la distribution spatiale des structures et des propriétés chromatiques (Drimbarean et Whelan, 2001). Cependant la plupart des méthodes d'analyse de la texture sont adaptées à des images monochromes d'intensités plutôt qu'à des images couleurs. Ainsi de nombreuses études abordent le problème en analysant séparément la texture et la couleur pour ensuite prendre une décision conjointe. Bien qu'elle soit très simple, cette approche permet d'obtenir des résultats significativement supérieurs à ceux obtenus uniquement grâce à la texture sans modifier la complexité calculatoire (Mojsilovic *et al.*, 1999; Nammalwar *et al.*, 2003; Drimbarean et Whelan, 2001). Il est également possible de déterminer parallèlement des régions d'intérêt sur la base de la texture et d'autres sur la base de la couleur, puis de fusionner ces décisions pour obtenir une segmentation unifiant les deux propriétés (Paschos et Valavanis, 1999).

Une autre approche consiste à étendre et adapter les outils standards de l'analyse de texture aux images couleurs. On peut distinguer trois familles de méthodes d'extension.

#### **(i) Traitement indépendant des canaux de couleurs.**

Ces méthodes consistent à décomposer une image couleur en canaux monochromes sur lesquels peuvent être calculés indépendamment des descripteurs avec les outils usuels de l'analyse de texture. Parmi ces outils, on trouve principalement les matrices de cooccurrences, les LBP<sup>5</sup> et les DCT<sup>6</sup> (Nammalwar *et al.*, 2003). Ces descripteurs peuvent être concaténés ou combinés pour servir de variables d'entrées aux algorithmes de classification et de segmentation. Ces méthodes conduisent donc à multiplier les descripteurs et à travailler en plus grande dimension. Une autre conséquence est la redondance de l'information. En effet, il est rarement possible de considérer les canaux d'une image couleur comme indépendants. En pratique, ces canaux sont corrélés, surtout localement. C'est pourquoi ces méthodes font souvent appel à des procédés de réduction de dimension et de décorrélation afin de sélectionner un ensemble restreint de variables pertinentes.

---

5. Local Binary Pattern

6. Discrete Cosine Transform : Transformée en Cosinus Discrète

**(ii) Propriétés transversales et interactions spatiales entre canaux.**

Ces méthodes consistent à combiner des propriétés spatiales observées indépendamment sur chaque canal avec des propriétés d'interactions locales entre les canaux. Panjawi et Healey (1995) proposent des modèles de Champs Aléatoires de Markov considérant des interactions d'ensembles de pixels dans un voisinage sur chaque canal ainsi que des interactions transversales entre ces ensembles. Jain et Healy proposent de combiner les réponses d'un ensemble de filtres de Gabor décrivant des structures spatiales indépendamment sur chaque canal avec « la théorie des signaux antagonistes de la couleur » d'Ewald Hering (1920) pour former des descripteurs de Gabor transversaux.

**(iii) Généralisation des outils de caractérisation de textures monochromes aux espaces couleur.**

Ces méthodes considèrent directement les relations spatiales qui peuvent exister entre les pixels des différents canaux d'une image couleur. Ainsi certains outils usuels comme les matrices de cooccurrence ont été étendus pour décrire la distribution des combinaisons locales d'intensités sur plusieurs canaux (Palm, 2004 ; Schwartz et Pedrini, 2007). De même, les descripteurs SIFT<sup>7</sup> ont été déclinés de différentes manières pour caractériser des structures couleurs (Abdel-Hakim et Farag, 2006 ; Bosch et al., 2006 ; Burghouts et Geusebroek, 2009). Ces descripteurs permettent généralement de classifier ou de segmenter des textures colorées de manière plus performante que leurs homologues dédiés aux images monochromes. Néanmoins ces descripteurs présentent une dimensionnalité et un coût calculatoire bien supérieurs. Pour résoudre ce problème, Song (2011) propose des descripteurs locaux compacts, qui caractérisent la distribution spatiale locale des couleurs. Ces descripteurs sont obtenus par des transformations affines entre les coordonnées spatiales et les coordonnées couleurs. En plus d'être beaucoup plus compacts, ces descripteurs possèdent de nombreuses propriétés d'invariance géométriques et colorimétriques, les rendant robustes au bruit local.

**(iv) Représentations formalistes des couleurs**

Dans les représentations conventionnelles, la couleur est considérée comme un ensemble de scalaires qui sont analysés indépendamment. Cette approche d'analyse des composantes de la couleur peut amener à caractériser des phénomènes marginaux qui ne décrivent pas de façon pertinente la dynamique spatiale des couleurs telle qu'elle est réellement perçue. Pour répondre à ce problème, certaines études proposent des représentations plus formalistes de la couleur qui se rapprochent de l'interprétation psychovisuelle. Ces représentations permettent de traiter la couleur comme un objet vectoriel dont les composantes sont étudiées conjointement.

---

7. Scale Invariant Feature Transform

tement. A la fin des années 1990, Sangwine (1996) ainsi que Pei et Chang (1997) proposent simultanément une représentation des couleurs sous la forme d'un encodage en quaternions. Plus récemment, Denis (2007) reprend ces représentations et introduit des représentations similaires fondées sur les algèbres géométriques. Ces nouvelles représentations requièrent de redéfinir de nombreuses opérations usuelles nécessaires en analyse de textures. Ainsi elles permettent d'utiliser des approches puissantes du domaine monochrome qu'il n'étaient jusqu'alors pas possible d'étendre à la couleur, notamment les approches fréquentielles de Fourier et les ondelettes (Denis, 2007, Souillard, 2012).

### 3.6.3 Conjuguer l'information de structure et l'information colorimétrique

Cette partie présente différentes méthodes permettant de formuler des descripteurs conjuguant les tenseurs de structure avec des variables colorimétriques. Ces méthodes consistent à adapter au tenseur de structure les approches génériques déclinées dans la [partie 3.6.2](#). Trois approches sont considérées : (i) analyser indépendamment la texture et la couleur, (ii) décrire des relations conjointes entre texture et colorimétrie, (iii) analyser séparément les canaux de couleurs. Pour chacune des approches, il est proposé d'étudier l'adéquation des nouveaux descripteurs formulés avec des modèles adaptés de ceux proposés dans la [partie 3.5](#).

### 3.6.4 Analyser indépendamment la texture et la couleur

Une première approche consiste à extraire l'information colorimétrique sous la forme de moyennes locales des intensités dans les canaux de couleurs. Les moyennes locales considérées sont obtenues par la convolution d'un filtre de lissage à noyau gaussien  $W_c$  avec chacun des canaux de couleur. Ce filtre est similaire à celui présenté dans la [partie 3.2](#). Les variables obtenues sont ensuite concaténées à la forme vectorielle du tenseur de structure dans l'espace LE. Cette représentation sera désignée dans la suite comme *CELEST* (Colour Extended Log-Euclidean Structure Tensor). La représentation *CELEST* est considérée pour les espaces de couleurs « RGB » et « L\*a\*b\* »



### Représentation *CELEST* dans l'espace RGB :

Dans l'espace RGB, chacun des canaux est convolué au filtre de lissage des couleurs  $W_c$  de paramètre  $\sigma_c$ . Sont ainsi obtenus trois canaux  $R'$ ,  $G'$  et  $B'$  représentant les moyennes locales des trois canaux :

$$R' = W_c * R, \quad G' = W_c * G, \quad B' = W_c * B. \quad (3.12)$$

Ainsi à tout triplet  $[r, g, b](i, j)$ ,  $(i, j) \in [1, N] \times [1, M]$  d'une image RGB correspond le triplet lissé  $[r', g', b'](i, j)$ .

En concaténant ce triplet avec la forme vectorielle du tenseur de structure dans l'espace LE calculé sur l'image d'intensité  $I$  (voir [partie 3.3](#)) on obtient ainsi un descripteur euclidien à 6 dimensions  $\vec{Y}_{CELEST_{RGB}}$  :

$$\vec{Y}_{CELEST_{RGB}} = (\sigma_{LExx}, \sigma_{LEyy}, \sqrt{2}\sigma_{LExy}, r', g', b')^t \quad (3.13)$$

### Représentation *CELEST* dans l'espace $L^*a^*b^*$ :

L'espace  $L^*a^*b^*$  a comme propriété de séparer deux canaux chromatiques  $a^*$  et  $b^*$  indépendants du canal de luminance  $L^*$ . Ainsi dans cet espace, ce sont seulement les deux canaux chromatiques  $a^*$  et  $b^*$  qui sont convolués au noyau gaussien  $W_c(\sigma_c)$ . De la même manière que dans l'espace RGB on obtient  $a'$  et  $b'$  comme :

$$a' = W_c * a^*, \quad b' = W_c * b^*. \quad (3.14)$$

Ainsi à tout triplet  $[L, a^*, b^*](i, j)$ ,  $(i, j) \in [1, N] \times [1, M]$  correspond le couple  $[a', b'](i, j)$  correspondant.

Dans cette approche, c'est sur le canal  $L^*$  qu'est calculé le tenseur de structure. Le tenseur ainsi obtenu décrit une structure à partir de gradients de luminance indépendants des variations locales de chrominance. De la même manière, on obtient par concaténation un descripteur euclidien à 5 dimensions  $\vec{Y}_{CELEST_{Lab}}$  :

$$\vec{Y}_{CELEST_{Lab}} = (\sigma_{LExx}, \sigma_{LEyy}, \sqrt{2}\sigma_{LExy}, a', b')^t \quad (3.15)$$

### Représentation *CELEST* et invariance en rotation :

Dans la [partie 3.4](#), il a été évoqué que lorsqu'on compare les textures présentes dans les images de vigne, les orientations principales des motifs ne sont pas des propriétés significatives. Plus encore, lorsqu'il s'agit de modéliser des classes de tissus, il faut être en mesure de décrire la structure d'un tissu de la même manière quelle que soit son orientation. Par exemple, il faut pouvoir décrire les tiges de manière homogène bien qu'il en existe certaines orientées horizontalement et d'autres verticalement. De même, les motifs spécifiques des feuilles se doivent d'être décrits uniformément bien que leurs nervures puissent être orientées différemment d'une feuille à l'autre. Il convient donc de proposer un descripteur de structure invariant en rotation. Ce sont principalement des propriétés dérivant des relations entre les différentes orientations qui caractérisent les propriétés intrinsèques des textures observées dans notre cas d'étude. Ainsi, ce sont plutôt les propriétés relatives à l'énergie et à l'anisotropie que la valeur angulaire de l'orientation que l'on souhaite exploiter.

La représentation vectorielle des tenseurs de structure dans l'espace LE permet d'introduire la propriété d'invariance en rotation. En effet, un tenseur  $\vec{Y}_{LE}$  est obtenu par une décomposition en éléments propres d'une matrice. Cette décomposition produit une matrice diagonale  $D$  dont les valeurs propres  $(\lambda_1, \lambda_2)$  sont uniques mais dont il peut exister plusieurs matrices de rotation possibles (voir [partie 3.3](#)). Ainsi, en ne retenant que les valeurs propres du tenseur de structure, on obtient un descripteur invariant en rotation. Ainsi les représentations *CELEST* invariantes en rotation deviennent respectivement dans l'espace RGB et L\*a\*b\* :

$$\vec{Y}_{CELEST_{RGB}} = (\log(\lambda_1), \log(\lambda_2), r', g', b')^t; \quad \vec{Y}_{CELEST_{Lab}} = (\log(\lambda_1), \log(\lambda_2), a^*, b^*)^t \quad (3.16)$$

Par commodité, les mêmes notations sont utilisées et désigneront par la suite les versions invariantes en rotation des représentations *CELEST*.

### Représentation tensorielle de la couleur dans l'espace HSL : TC-LEST

Rittner *et al.* (2007) proposent de décrire la couleur non pas comme un triplet de scalaires mais comme un tenseur unique qui peut être décrit par une ellipse. Cette représentation est proposée afin de pouvoir obtenir des mesures de dissimilarités et des relations d'ordre cohérentes entre deux couleurs. Cette représentation est intéressante dans le cadre d'une modélisation car elle permet également de mesurer une distance cohérente entre un descripteur couleur et le vecteur moyen d'une distribution gaussienne.

La méthode proposée s'applique dans différents espaces couleurs. Cependant expérimentalement elle s'est montrée plus adaptée à l'espace HSL. La méthode consiste à former un tenseur à partir d'un triplet  $[H, S, L]$ . La décomposition en éléments propres d'un tenseur peut se représenter sous la forme d'une ellipse. L'amplitude  $T$ <sup>8</sup> de cette ellipse correspond à la somme des valeurs propres (la trace) du tenseur :  $\mathbf{T} = (\lambda_1 + \lambda_2)$ . L'excentricité  $E$  de l'ellipse correspond au rapport normalisé entre les valeurs propres :  $\mathbf{E} = (1 - \frac{\lambda_2}{\lambda_1})$ . Enfin l'angle ( $\theta$ ) de l'ellipse par rapport à l'axe horizontal, correspond à l'angle de la matrice de rotation qui s'obtient à partir du premier vecteur propre  $\mathbf{u}_1$  :  $\theta = \arctan \frac{\mathbf{u}_1(\mathbf{y})}{\mathbf{u}_1(\mathbf{x})}$ . Ces trois attributs à eux seuls permettent de définir une unique ellipse représentant un unique tenseur (voir figure 17). Rittner et al. (2007) font correspondre chacune des coordonnées de l'espace HSV aux trois attributs de l'ellipse.  $H$  l'angle  $\theta$ ,  $S$  représente l'excentricité  $E$  et  $L$  représente l'amplitude  $T$ . La figure 18 représente les changements de configuration de l'ellipse en fonction des variations dans les dimensions H, S et L.

Ainsi on peut retrouver les éléments propres de l'ellipse par les équations suivantes :

$$\left. \begin{array}{l} H = \theta \\ S = 1 - \frac{\lambda_2}{\lambda_1} \\ L = \lambda_1 + \lambda_2 \end{array} \right\} \Rightarrow \begin{array}{l} H = \theta \\ \lambda_1 = \frac{L}{2 - S} \\ \lambda_2 = \frac{L(1 - S)}{2 - S} \end{array} \quad (3.17)$$

On peut ainsi recomposer le tenseur couleur  $T$  par :

$$T = \begin{bmatrix} T_{00} & T_{10} \\ T_{01} & T_{11} \end{bmatrix} = W_T * \begin{bmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix} \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{bmatrix} \begin{bmatrix} \cos(\theta) & \sin(\theta) \\ -\sin(\theta) & \cos(\theta) \end{bmatrix} \quad (3.18)$$

---

8. Rittner et al. (2007) désignent l'amplitude comme la « Trace » de l'ellipse

Finalement on obtient le descripteur  $\vec{Y}_{TC-LEST}$  (Tensorial Colour Log-Euclidean Structure Tensor) par la transformation LE du tenseur représentant la couleur puis par concaténation avec le tenseur de structure LE :

$$\vec{Y}_{TC-LEST} = (\log(\lambda_1), \log(\lambda_2), \log(T_{00}), \log(T_{11}), \sqrt{2}\log(T_{01}))^t \quad (3.19)$$







FIGURE 17: Représentation tensorielle elliptique de la couleur. L'angle  $\theta$  représente la teinte (H), les vecteurs  $\vec{u}_1$  et  $\vec{u}_2$  décrivent les vecteurs propres du tenseur associés aux axes de l'ellipse et aux composantes S et L



(a) Hue =  $\theta$



(b) Saturation = E



(c) Luminance = T

FIGURE 18: Représentation elliptique de l'information colorimétrique HSL. La figure décrit les changements de configuration de l'ellipse pour des variations indépendantes de chacune des composantes H (a), S (b) et L (c).

### 3.6.5 Décrire des relations conjointes entre texture et colorimétrie : la représentation *LEEST*

De Luis-Garcia *et al.* (2008) ont proposé un tenseur de structure décrivant la covariance gradient-couleur. Cette approche consiste à intégrer l'information de couleur dans les gradients avant d'exprimer le tenseur par l'estimation des covariance. Le tenseur étendu à la couleur  $\vec{Y}_{CE}$  se définit ainsi :

$$\vec{Y}_{CE} = W_T * [\nabla \vec{I}_{CE} \nabla \vec{I}_{CE}^t], \quad (3.20)$$

avec  $\nabla \vec{I}_{CE} = [g_x, g_y, R, G, B]$ . On obtient ainsi la matrice  $[5 \times 5]$  :

$$Y_{CE} = W_T * \begin{bmatrix} g_x \cdot g_x & g_x \cdot g_y & g_x \cdot R & g_x \cdot G & g_x \cdot B \\ g_y \cdot g_x & g_y \cdot g_y & g_y \cdot R & g_y \cdot G & g_y \cdot B \\ R \cdot g_x & R \cdot g_y & R \cdot R & R \cdot G & R \cdot B \\ G \cdot g_x & G \cdot g_y & G \cdot R & G \cdot G & G \cdot B \\ B \cdot g_x & B \cdot g_y & B \cdot R & B \cdot G & B \cdot B \end{bmatrix} \quad (3.21)$$

Comme dans le cas de la représentation *CELEST*, il est possible d'obtenir la forme vectorielle du tenseur  $\nabla \vec{I}_{CE}$  par transformation dans l'espace LE. On obtient ainsi un descripteur couleur-texture vectoriel à 15 dimensions. Cette représentation sera désignée comme *LEEST* (Log-Euclidean Extended Structure Tensor). Contrairement à la représentation *CELEST*, *LEEST*, consiste à étendre le tenseur à la couleur et à inclure des relations entre gradients et couleur avant le passage dans l'espace LE. Pour la représentation *LEEST*, il est difficile d'envisager une forme invariante en rotation de la même manière que pour *CELEST*. En effet, le tenseur représente la covariance de gradients étendus  $\nabla \vec{I}_{CE}$  contenant une information conjointe de couleur-texture. L'application de rotations à cette forme particulière ne possède pas d'interprétation géométrique évidente. La représentation *LEEST*, ici construite à partir de l'espace *RGB*, est bien évidemment applicable à l'espace  $L^*a^*b^*$ , où les gradients  $[g_x, g_y]$  se calculent sur le canal de luminance  $L^*$  et le triplet  $[R, G, B]$  est remplacé par  $[a^*, b^*]$ .

### 3.6.6 Analyser chaque canal indépendamment : la représentation *LEGEST*

Cette approche consiste à calculer un tenseur de structure sur chacun des canaux, puis à concaténer les descripteurs obtenus pour obtenir un vecteur dans l'espace LE décrivant la structure dans chacun des canaux. Cette représentation est désignée comme *LEGEST* (Log-Euclidean Gradient Extended Structure Tensor). Elle est considérée pour les espaces couleurs RGB et L\*a\*b\*. On obtient ainsi un tenseur par canal. Pour le canal *R* on obtient par exemple le tenseur  $Y_R$  par :

$$Y_R = W_T * \begin{bmatrix} g_{Rx} \cdot g_{Rx} & g_{Rx} \cdot g_{Ry} \\ g_{Ry} \cdot g_{Rx} & g_{Ry} \cdot g_{Ry} \end{bmatrix}. \quad (3.22)$$

On obtient pour les autres canaux la même expression « mutatis mutandis » R.

Il semble possible pour *LEGEST* d'assurer une invariance en rotation dans chacun des canaux de couleur en retenant uniquement les valeurs propres de chacun des tenseurs, à la différence près que les matrices de rotations sont *a priori* différentes pour les 3 canaux. La représentation *LEGEST* conduit finalement à des descripteurs vectoriels à 6 dimensions :


$$\vec{Y}_{LEGEST_{RGB}} = [\log(\lambda_{R1}), \log(\lambda_{R2}), \log(\lambda_{G1}), \log(\lambda_{G2}), \log(\lambda_{B1}), \log(\lambda_{B2})]^t \quad (3.23)$$

$$\vec{Y}_{LEGEST_{Lab}} = [\log(\lambda_{L1}), \log(\lambda_{L2}), \log(\lambda_{a1}), \log(\lambda_{a2}), \log(\lambda_{b1}), \log(\lambda_{b2})]^t \quad (3.24)$$


### 3.6.7 Adéquation des différentes représentations couleur-structure aux modèles proposés

Les nouveaux descripteurs proposés précédemment sont des représentations vectorielles conjointes des informations de couleur et de structure. Certaines de ces représentations sont obtenues par la vectorisation dans l'espace LE d'un tenseur de structure étendu à la couleur soit par la considération de gradients chromatiques (*LEGEST*) soit par la considération de covariances locales entre des gradients d'intensité et des moyennes chromatiques (*LEEST*). Les autres représentations sont obtenues par la concaténation de la forme vectorielle du tenseur de structure dans l'espace LE avec soit un vecteur euclidien d'informations colorimétriques *CELEST* soit avec la forme vectorielle LE d'un tenseur représentant l'information colorimétrique (*TC – LEST*). Dans les cas des représentations *LEGEST* et *LEEST*, il est donc possible d'étudier l'adéquation de la distribution aux modèles en observant la distribution des log-déterminants de leur forme matricielle. Pour les autres représentations, il n'existe pas de forme matricielle conjointe. Cependant, puisque l'adéquation des composantes de structure a déjà été étudiée, il s'agit dans ces cas d'étudier l'adéquation marginale des composantes chromatiques. Pour la représentation *TC – LEST*, il est possible d'observer la distribution des log-déterminants de  $T$ , le tenseur représentant l'information de couleur dans l'espace HSV. Pour la représentation *CELEST*, il faut étudier une à une chacune des composantes colorimétriques compte tenu de la forme vectorielle.


Les figures 19 et 20 représentent les adéquations des distributions des différentes représentations pour l'exemple de la classe « mildiou feuilles ». Les modèles gaussiens ainsi que les modèles de mélange sont considérés pour des tenseurs calculés avec les paramètres ( $\sigma_g = 1.5, \sigma_t = 3.5$ ).




(a) Adéquation gaussienne pour «  $r'$  » de  $CELEST_{RGB}$




(b) Adéquation gaussienne des « tenseurs hsv » de  $TC - LEST$




(c) Adéquation au mélange pour «  $r'$  » de  $CELEST_{RGB}$



(d) Adéquation au mélange des « tenseur hsv » de  $TC - LEST$



(e) Comparaison des modèles pour «  $r'$  » de  $CELEST_{RGB}$



(f) Comparaison des modèles pour les « tenseur hsv » de  $TC - LEST$

FIGURE 19: Adéquation des distributions des log-déterminants des tenseurs de structure étendus à la couleur pour la classe « mildiou feuille ». Les modèles considérés sont soit des densités de probabilité gaussiennes (a,b) soit des modèles de mélange (c,d). La comparaison de l'adéquation aux modèles est présentée pour (e,f). Les représentation considérées sont  $CELEST_{RGB}$  (a,c,e) et  $TC - LEST$  (b,d,f).




La figure 19 représente les adéquations respectives des distributions de la composante  $r'$  de la représentation  $CELEST_{RGB}$  à une densité de probabilité gaussienne (a), à une densité de mélange (c). La comparaison des deux modèles est représentée en (e). Les mêmes phénomènes sont représentés pour la représentation  $TC - LEST$ , respectivement en (b), (d) et (f). Dans ce cas, ce sont les distributions des log-déterminants qui sont représentées. Dans les deux cas, les distributions des composantes correspondent assez mal à des densités de probabilité gaussiennes. En effet, elles sont légèrement asymétriques et décentrées par rapport au maximum de probabilité. Ainsi ce sont surtout le pic central et les parties marginales des distributions qui sont mal représentés. A noter que le même phénomène est observable pour les composantes  $g'$  et  $b'$ , tandis que dans le cas  $CELEST_{L^*a^*b^*}$ , les distributions des composantes  $a^*$  et  $b^*$  sont très étroites, les variances sont plus faibles et les distributions sont mieux représentées par des distributions gaussiennes (voir Annexe A). Pour les deux représentations, les modèles de mélange sont beaucoup plus pertinents. A noter que dans le cas de la représentation  $TC - LEST$  la crête de la distribution n'est tout de même pas encore bien décrite.

La figure 20 représente les adéquations respectives des distributions de la composante  $a^*$  de la représentation  $LEGEST_{Lab}$  à une densité de probabilité gaussienne (a), à une densité de mélange (c). La comparaison des deux modèles est représentée en (e). Les mêmes phénomènes sont décrits pour la représentation  $LEEST_{RGB}$ , respectivement en (b), (d) et (f). Dans ce cas ce sont les distributions des log-déterminants qui sont représentées. Dans les deux cas, les distributions des composantes sont peu adaptées à une densité de probabilité gaussienne. En effet, elles sont légèrement asymétriques et décentrées par rapport au maximum de probabilité. Là encore, ce sont surtout le pic central et les parties marginales des distributions qui sont mal modélisés. Pour les deux représentations, les modèles de mélange sont beaucoup plus pertinents.


Toutefois un problème majeur des représentations  $LEEST$  et  $LEGEST$  peut ici être souligné. En effet, il n'est pas toujours possible d'exprimer les descripteurs de ces représentations. Dans de nombreux cas, les matrices de covariances produites sont mal conditionnées *i.e.* la décomposition en éléments propres conduit à des valeurs propres nulles (voire non calculables). Dans ces conditions, les matrices ne sont pas strictement SPD et ne peuvent donc pas être vectorisées par la méthode LE. C'est pourquoi les effectifs présentés sur la figure 20 sont inférieurs à l'effectif total de la classe « mildiou feuilles ». L'adéquation aux modèles n'est seulement étudiée que pour un sous ensemble de la population pour lequel il est possible d'exprimer les descripteurs. Ainsi pour la représentation  $LEEST_{RGB}$ , sur l'exemple

de la classe « mildiou feuilles », 38% de la population ne peut pas être décrite dans cette représentation. Ce phénomène peut s'expliquer par la dimension du descripteur dans cette représentation (matrice  $[5 \times 5]$ , vecteur  $15D$ ). Pour estimer correctement une covariance, il faut un échantillon de taille suffisante. Cette taille est contrôlée indirectement par  $\sigma_t$  qui conditionne la fenêtre sur laquelle la covariance des gradients est estimée. Or ce paramètre doit également correspondre à une échelle d'analyse cohérente avec les textures étudiées. Ce phénomène est aussi observable pour la représentation  $LEEST_{Lab}$  (matrice  $[4 \times 4]$ , vecteur  $10D$ ), avec 22% de la population qui ne peut pas être décrite dans cette représentation pour la classe « mildiou feuilles » (voir [Annexe A](#)).

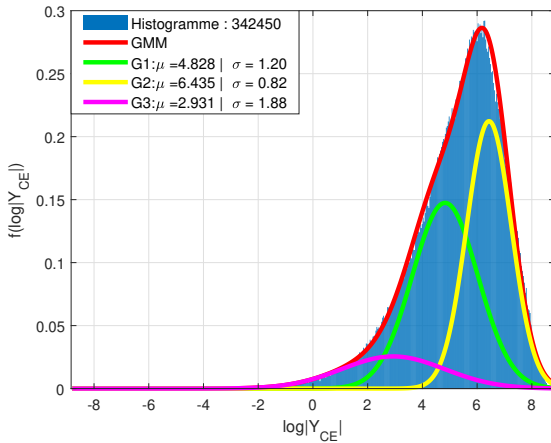
Dans le cas de la représentation  $LEGEST$ , le problème du conditionnement des matrices de covariances s'explique différemment. En effet ces matrices sont de dimensions égales à celles du tenseur de structure et elles sont exprimées pour chacun des canaux respectifs des espaces de couleur  $RGB$  ou  $L^*a^*b^*$ . Cependant, la signification géométrique de la covariance des gradients chromatiques n'est pas formellement établie dans les espaces de couleurs conventionnels. Dans l'espace  $RGB$ , il est possible que certains gradients résultent d'artefacts chromatiques qui ne décrivent pas une propriété de structure locale. Ainsi, pour la représentation  $LEGEST_{RGB}$ , sur l'exemple de la classe « mildiou feuilles », 24% de la population ne peut pas être décrite sur le canal R. Dans l'espace  $L^*a^*b^*$ , les canaux sont indépendants. Si le tenseur issu du canal  $L^*$  ne pose aucune difficulté à être exprimé, les mêmes problèmes de conditionnement se posent pour la structure des canaux  $a^*$  et  $b^*$ . Ainsi 15% de la population n'est pas exprimable par la représentation  $LEGEST_{Lab}$  pour l'exemple de la classe « mildiou sur feuilles ». Les mêmes propriétés et difficultés ont été observées sur les autres classes, même si les résultats ne sont pas exposés ici dans un souci de concision.




(a) Adéquation gaussienne des tenseurs  $LEEST_{RGB}$




(b) Adéquation gaussienne des tenseurs  $Y_a$  de  $LEGEST_{Lab}$




(c) Adéquation au mélanges des tenseurs  $LEEST_{RGB}$



(d) Adéquation au mélange des tenseurs  $Y_a$  de  $LEGEST_{Lab}$



(e) comparaison des modèles pour les tenseurs  $LEEST_{RGB}$



(f) comparaison des modèles pour les tenseurs  $Y_a$  de  $LEGEST_{Lab}$

FIGURE 20: Adéquation des distributions des log-déterminants des tenseurs de structure étendus à la couleur pour la classe « mildiou feuille ». Les modèles considérés sont soit des densités de probabilité gaussiennes (a,b) soit des modèles de mélange (c,d). La comparaison de l'adéquation aux modèles est présentée pour (e,f). Les représentations considérées sont  $LEEST_{RGB}$  (a,c,e) et  $LEGEST_{Lab}$  (b,d,f).

## 3.7 Conclusion du chapitre : bilan de l'approche structure-couleur

Dans ce chapitre nous avons abordé les relations entre les propriétés de texture et les propriétés colorimétriques. Différentes stratégies de combinaison du tenseur local de structure (LST) avec des informations colorimétriques ont été proposées et comparées. Chacune de ces stratégies a conduit à la formulation d'un descripteur représenté dans l'espace log-euclidien. Dans cet espace, les représentations des descripteurs sont modélisables pour chaque classe de tissus par des distributions gaussiennes multivariées ou des mélanges de gaussiennes. A ce stade, certaines propriétés des représentations peuvent déjà être comparées. Premièrement, les représentations aux dimensions les plus élevées (*LEEST* et *LEGEST*) posent des problèmes de conditionnement. En pratique, une proportion significative des pixels de certaines classes ne peuvent pas être exprimés dans ces représentations. Le choix de l'espace colorimétrique apparaît également important. De plus, pour une même stratégie, les classes sont en général mieux décrites par les modèles lorsqu'on considère l'espace  $L^*a^*b^*$  plutôt que l'espace *RGB*. Par ailleurs, les représentations proposées diffèrent également par leurs propriétés d'invariance en rotation, par les définitions des notions de dissimilarité entre couleurs ou par les significations géométriques des gradients employés. Dans d'autres contextes, ces propriétés ont déjà été étudiées dans la littérature relative aux relations entre texture et couleur. Dans les chapitres suivants, les représentations seront évaluées voire comparées dans le cadre applicatif de la classification des tissus de la vigne.



# CHAPITRE 4

---

## Reconnaissance des organes de la vigne

---

### 4.1 Introduction et objectifs du chapitre

L'évaluation de certaines propriétés relatives à l'architecture et à la physiologie de la vigne est essentielle pour évaluer les risques sanitaires et mettre en place des méthodes de lutte dans les vignobles (voir [partie 1.3.3](#)). Ce chapitre présente et analyse une chaîne de traitement d'images qui a pour objectif de produire des cartes de classification pixellaire des différents types de tissus sains présents sur un pied de vigne. Ces cartes pourraient permettre de décrire des phénomènes liés à la sensibilité d'un pied aux pathologies fongiques. Cette classification est aussi une étape préliminaire à la détection de symptômes. En effet, pour distinguer des tissus pathologiques dans une image, il faut être dans un premier temps en mesure de discriminer spécifiquement les tissus sains entre-eux. De plus les symptômes des maladies fongiques comme le mildiou sont spécifiques selon les types de tissus. Ainsi la description de l'environnement d'un symptôme est une information supplémentaire pour le caractériser.

La chaîne de traitement proposée est présentée à la figure [21](#). Le processus de classification est basé sur l'estimation des vraisemblances des propriétés locales de structure et de couleur à des modèles paramétriques décrivant les classes de tissus étudiées. Les propriétés locales conjointes de structure-couleur sont fondées sur les méthodes de représentation développées dans le [chapitre 3](#). Dans cette chaîne de traitement, seules sont considérées les représentations  $LEEST_{RGB}$  et  $CELEST_{RGB}$ . Les autres représentations ont été développées spécifiquement pour les besoins du [chapitre 5](#) traitant de la détection des symptômes de maladies fongiques. Les modèles considérés pour décrire les classes de tissus sont les modèles gaussiens et les modèles de mélange dans l'espace LE proposés et étudiés dans le [chapitre 3](#). Le processus

d'affectation d'un pixel à une classe d'organe s'appuie sur l'estimateur du MAP<sup>1</sup>. Il est complété par une étape de régularisation spatiale synthétisant les décisions locales en une description cohérente de l'architecture et de la physiologie des pieds de vigne. Les parties suivantes ont pour objectif de décrire les étapes de la chaîne de traitement spécifiques à la reconnaissance des organes et d'analyser les performances et la robustesse de la chaîne. Les travaux de ce chapitre ont fait l'objet d'une communication en conférence internationale (Abdelghafour *et al.*, 2019a) et d'un article de revue (Abdelghafour *et al.*, 2019b) .

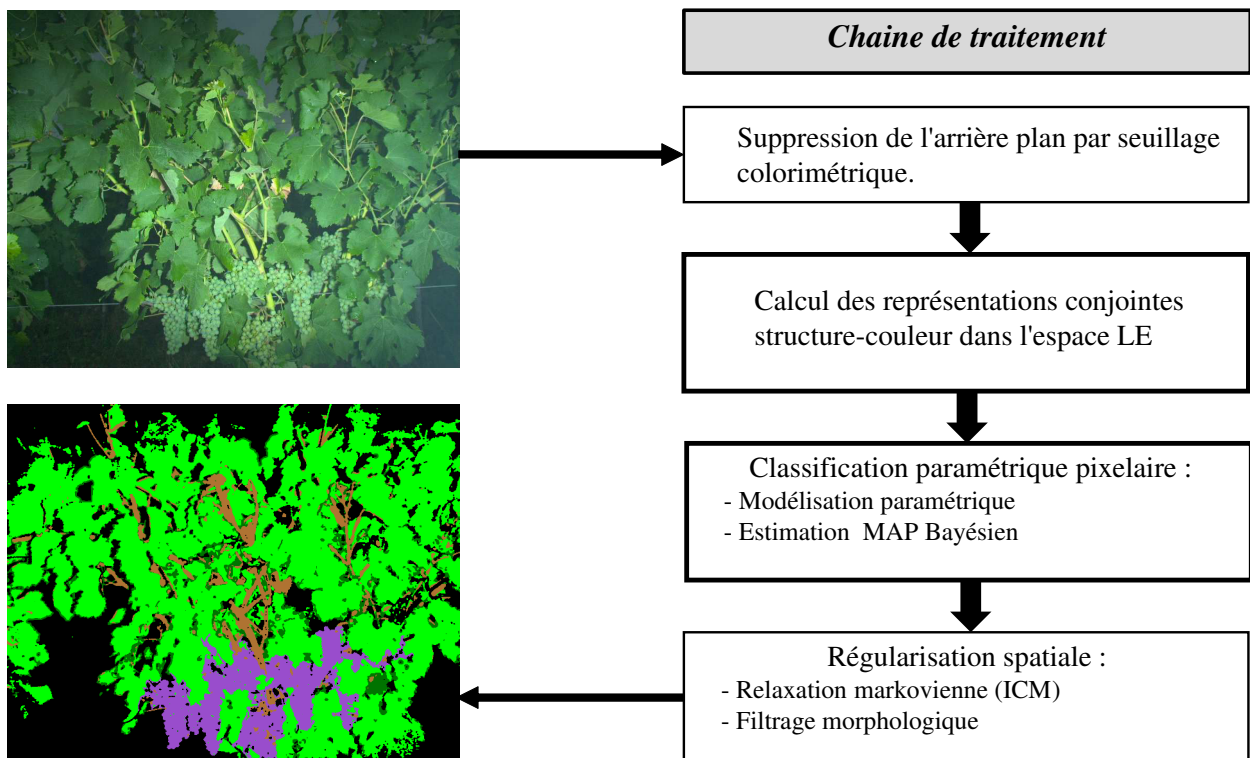


FIGURE 21: Chaîne de traitement pour la classification pixellaire des tissus sains de la vigne.

## 4.2 Pré-traitement : suppression de l'arrière plan par seuillage colorimétrique

L'objectif du prétraitement est de restreindre le traitement principal à des régions d'intérêt en éliminant au préalable les parties non-pertinentes des images *i.e.* les éléments qui n'appartiennent pas au pied considéré ou aux pieds voisins sur le plan de palissage du rang considéré. Ces éléments incluent le ciel, le sol et l'herbe, les éléments artificiels du palissage (piquets, fils) ainsi que le feuillage sombre des pieds en arrière plan. Un simple seuillage

1. Maximum *a posteriori*

des canaux de l'image dans l'espace HSV permet d'atteindre cet objectif. Les canaux de teinte (H) et de saturation (S) permettent d'éliminer les pixels dont les couleurs ne sont pas vraisemblables dans la végétation. Ainsi les couleurs verte, jaune, orange et marron sont conservées tandis que les couleurs grise, bleue et rouge sont éliminées. Le canal d'intensité (V) quant à lui permet d'éliminer les parties sombres de l'arrière plan, les ombres ainsi que les rares pixels surexposés ou sous-exposés qui présentent des valeurs extrêmes. L'utilisation d'un flash puissant pendant un temps d'exposition très court permet d'illuminer le feuillage et d'atténuer les ombres dans le premier plan de l'image tandis que l'arrière-plan, hors de portée du flash, est assombri (voir [chapitre 2](#)). Dans ces conditions, il est possible d'éliminer l'arrière plan, même lorsqu'il contient des pixels verts au sein d'herbe ou de feuillage des autres rangs, dont les valeurs de saturation et surtout d'intensités sont plus faibles.

Le seuillage est suivi d'opérations morphologiques, des ouvertures et des fermetures (Serra, 1986), permettant d'homogénéiser la pré-segmentation. La figure 22 présente un exemple de résultat de pré-traitement pour le stade BBCH79 (fermeture des grappes), sur la figure tous les pixels éliminés sont remplacés par un pixel noir. Les opérations suivantes dans la chaîne de traitement seront appliquées uniquement aux pixels conservés. Les seuils à appliquer dans chacun des canaux H,S et V sont déterminés grâce aux histogrammes des valeurs H, S et V. La figure 23 présente l'histogramme des valeurs de teinte (H) obtenu à partir de 1000 images au stade BBCH79. Cet histogramme montre deux modes ressemblant à des gaussiennes. Le premier mode, de plus grande amplitude, est constitué principalement des pixels des tissus du pied tandis que le second contient principalement les pixels de l'arrière plan. Le seuil de teinte (H) est donc déterminé par les limites du mode gaussien principal, *i.e.*  $H \in [45, 80]$ . On observe le même phénomène pour les canaux S et V dont les seuils sont déterminés pour  $S \in [65, 230]$  et  $V \in [80, 230]$ . On rappelle que la teinte est une valeur angulaire comprise entre  $0^\circ$  et  $180^\circ$ , tandis que S et V prennent des valeurs entre 0 et 255. Ces seuils sont identiques pour les trois stades considérés. S'ils se sont révélés pertinents pour le jeu d'images disponibles, on pourrait imaginer dans une application plus opérationnelle de procéder à une détermination automatique des seuils.






FIGURE 22: Suppression de l'arrière plan par seuillage sur les composantes  $HSV$  et opérations morphologiques : exemple au stade BBCH79 (fermeture de la grappe).  
 $H \in [45, 80]$ ,  $S \in [65, 230]$  et  $V \in [80, 230]$




FIGURE 23: Histogramme des teintes (H) de 1000 images de la base de données au stade BBCH79

## 4.3 Classification pixellaire : décision probabiliste

### 4.3.1 Estimation du maximum *a posteriori* (MAP)

Cette étape consiste à déterminer la classe d'appartenance la plus probable d'un pixel en fonction d'un descripteur  $Y$  qui décrit des propriétés locales dans le voisinage du pixel (dans notre cas, un tenseur de structure dans l'une des représentations considérées). La décision est basée sur le principe de l'estimateur Maximum *A Posteriori* (MAP), un procédé bayésien qui détermine la classe  $\hat{c}$  la plus probable parmi un ensemble  $L$  de classes  $c$ , tel que :  $\hat{c} = \underset{c \in L}{\operatorname{argmax}} p(c|Y)$ .

D'après le théorème de Bayes,  $p(c|Y) = \frac{f(Y|c)p(c)}{f(Y)}$  d'où :

$$\underset{c \in L}{\operatorname{argmax}} p(c|Y) = \underset{c \in L}{\operatorname{argmax}} f(Y|c)p(c). \quad (4.1)$$

Dans ces équations,  $f(Y|c)$  désigne la vraisemblance d'un descripteur  $Y$  décrite par une fonction de densité de probabilité théorique  $f$ . Dans notre cas,  $f$  peut être un des modèles gaussiens et des modèles de mélanges présentés dans la [partie 3.5](#).  $p(c)$  désigne la probabilité *a priori* de la classe  $c$ , *i.e.* la proportion relative théorique de la classe  $c$  dans l'ensemble des  $L$  classes. Les deux termes peuvent être estimés à partir d'un ensemble dit « d'apprentissage » constitué d'échantillons de descripteurs  $Y$  représentatifs des variabilités de chaque classe considérée.

Dans le cas d'un modèle gaussien, la vraisemblance d'un tenseur représenté dans l'espace LE au modèle de la classe  $c$  s'exprime :

$$f(\vec{Y}_{LE} | \vec{\mu}_c, \Sigma_c) = \frac{1}{(2\pi)^{N/2} |\Sigma_c|^{1/2}} \exp\left(-\frac{1}{2} (\vec{Y}_{LE} - \vec{\mu}_c)^t \Sigma_c^{-1} (\vec{Y}_{LE} - \vec{\mu}_c)\right). \quad (4.2)$$

Dans le cas des modèles de mélange :

$$f(\vec{Y}_{LE} | (\omega_{c,k}, \vec{\mu}_{c,k}, \Sigma_{c,k})_{k=1:K}) = \sum_{k=1}^K \omega_{c,k} p_k(\vec{Y}_{LE} | \vec{\mu}_{c,k}, \Sigma_{c,k}), \quad (4.3)$$

où  $\forall(c, k), \omega_{c,k} > 0$  sont les pondérations du mélange ( $\sum_{k=1}^K \omega_{c,k} = 1$ ).

### 4.3.2 Estimation des probabilités *a priori*

Les trois hypothèses suivantes peuvent être formulées pour exprimer la probabilité  $p(c)$  :

- (1) Une distribution équiprobable des classes :  $p(c) = \frac{1}{L}$ ,  
 $L$  étant le nombre de classes .
- (2) Une distribution non-équiprobable des classes :  $p(c) = \pi_c$ ,  
la fréquence statistique d'occurrence de la classe  $c$ .
- (3) Une distribution non-équiprobable et spatialement variable des classes :  
 $p(c) = \pi_c(h)$ , une fonction de répartition spatiale, *i.e.* la probabilité *a priori* d'une classe dépend de la position dans l'image du pixel représenté par  $Y$ .

L'hypothèse (3) est la plus réaliste dans le cas de la vigne. En effet, les images de vigne sont spatialement structurées. Il existe donc une plus forte probabilité d'observer des fruits et des inflorescences dans la partie inférieure de l'image d'autant plus que le feuillage est moins dense dans cette partie de l'image. Dans la partie médiane de l'image, le feuillage est plus dense et peut occulter partiellement des tiges ou quelques rares fruits. Dans la partie supérieure de l'image, le feuillage est moins dense et laisse apparaître les tiges, en particulier leur apex, tandis que la présence de fruits est très improbable. Il semble donc approprié de considérer que  $p(c)$  est une fonction de la hauteur du pixel dans l'image. Cette fonction est propre aux différents stades phénologiques pour lesquels la densité du feuillage et l'espace occupé par les fruits varient.

Le critère de décision MAP est donc constitué d'une vraisemblance  $f(Y|c)$  au modèle de la classe  $c$  modulée par  $\pi_c(h)$  représentant la proportion relative de la classe de tissu  $c$  à une hauteur  $h$  au sein de l'image (*i.e.* de la plante). Il est proposé de diviser verticalement l'image en trois parties de hauteurs égales. Dans chaque partie, les proportions relatives des classes sont estimées comme les proportions moyennes observées dans le jeu d'images pour un stade BBCH donné.

## 4.4 Régularisation spatiale

Le procédé de classification proposé repose sur une décision probabiliste locale réalisée indépendamment en chaque pixel sans considération des réalisations dans le voisinage du pixel. Néanmoins, les images de la vigne présentent une organisation spatiale naturelle. C'est tout simplement l'arrangement des tissus en organes dont les propriétés de structure sont localement homogènes. Ainsi il est très improbable d'observer des distributions discontinues des classes. Ces classes se distribuent en réalité de manière connexe pour former des tissus continus et des organes. Pourtant le procédé de classification proposé peut produire des résultats spatialement irréguliers avec des erreurs sporadiques. C'est pourquoi la chaîne de traitement inclut des étapes de régularisation spatiale pour assurer une cohérence locale des décisions plus en accord avec la réalité. Deux méthodes successives sont proposées : une première basée sur un algorithme de relaxation markovienne, l'algorithme ICM<sup>2</sup>, la seconde basée sur des opérations de morphologie mathématique.

### 4.4.1 Relaxation markovienne :

Dans ce procédé, les résultats de classification obtenus par le MAP (*i.e.* le champ de labels des classes) sont considérés comme un champ aléatoire de Markov dans lequel le label de chaque pixel dépend uniquement des labels de ses voisins directs. L'algorithme ICM est un processus d'optimisation destiné à obtenir le champ de labels le plus régulier compte-tenu à la fois des dépendances locales des labels et du modèle paramétrique sous-jacent décrivant la structure locale des pixels au sein de chaque classe (Besag, 1986). En pratique, l'ICM consiste à trouver un compromis entre les décisions probabilistes ponctuelles et un critère de cohérence spatiale. Le traitement d'un champ de labels par l'ICM produit généralement une classification plus régulière et localement homogène.

L'ICM est un processus itératif. Le champ de labels initial est fourni par le processus de classification par MAP (*cf.* [partie 4.3.1](#)). Chaque itération consiste à vérifier pour chaque pixel s'il existe une substitution du label qui résulte en un champ de labels plus stable. Une substitution est considérée plus stable si elle conduit à une énergie locale plus faible. Les énergies ( $E$ ) sont calculées en prenant en compte deux termes, le terme de rappel aux données (RD) et le terme de régularisation (RS) :  $E = RD + RS$ .

---

2. Iterated Conditional Modes

Le terme de rappel s'exprime pour chaque pixel  $(i, j)$  comme :

$$RD(i, j) = -\log[p(\hat{c}(i, j)|\vec{Y})], \quad (4.4)$$

où  $c$  est la classe du pixel.

Le terme de cohérence spatiale est estimé dans le voisinage du pixel traité, ce voisinage est constitué des 8 pixels connexes. Ce terme s'exprime :

$$RS(i, j) = \sum_{x=i-1}^{i+1} \sum_{y=j-1}^{j+1} \beta; \quad \beta = 1 \text{ si } c(x, y) \neq c(i, j) \text{ et } \beta = -1 \text{ si } c(x, y) = c(i, j). \quad (4.5)$$

On attribut alors au pixel  $(i, j)$  le label de la classe  $c$  qui minimise l'énergie.

## 4.4.2 Morphologie mathématique

Les opérations de morphologie mathématique permettent de régulariser la classification à une échelle plus importante que la relaxation markovienne qui agit généralement à l'échelle du voisinage considéré. Ces opérations sont notamment utiles lorsque des groupes importants de pixels sont incorrectement classifiés, mais que leurs labels sont homogènes. Dans ces cas, la relaxation markovienne par ICM est inefficace. En pratique, la régularisation morphologique consiste à corriger itérativement les irrégularités de forme aux frontières des régions. Cette correction est réalisée grâce à des opérations d'ouverture et de fermeture morphologiques (Serra, 1986).

## 4.5 Analyse de la chaîne de traitement

### 4.5.1 Protocole général

Plusieurs modalités sont proposées pour chaque étape de la chaîne de traitement. Le but de cette analyse est de comparer différentes combinaisons de ces modalités en termes de performances de classification et de montrer l'intérêt des étapes considérées. Les modalités considérées concernent la représentation des descripteurs structure-couleur, le type de modèle probabiliste, la gestion des probabilités *a priori* dans la décision MAP ainsi que les procédés de régularisation spatiale. Seules les représentations  $LEEST_{RGB}$  et  $CELEST_{RGB}$  sont considérées dans ce chapitre, les autres représentations seront étudiées dans le [chapitre 5](#). Deux types de modèles sont étudiés : des modèles gaussiens multivariés, qui seront désignés

« mvG<sup>3</sup> » et des modèles de mélanges à trois composantes, qui seront désignés « mvGM<sup>4</sup> ». La gestion des probabilités *a priori* sera étudiée en comparant l’hypothèse « équiprobable-homogène » et l’hypothèse « fonction à variabilité spatiale » (notée  $\pi_c(\mathbf{h})$ ). Enfin, on décrira l’influence des procédés de régularisation spatiale.


Cette chaîne de traitement est appliquée sur des images acquises en 2017 sur les parcelles RESINTBIO à trois stades phénologiques : BBCH68 / floraison phase terminale (23 mai), BBCH75 / petits-pois (12 juin) et BBCH79 / fermeture des grappes (10 juillet). La figure 26 présente pour chaque stade phénologique étudié, un exemple d’image caractéristique de la base de données 2017. Pour chacun des stades phénologiques, quatre classes seront considérées : le limbe des feuilles, les bordures des feuilles, les grappes (ou inflorescences pour BBCH68) ainsi que les tiges. La classe « bordure de feuilles » peut être intéressante dans le cas où l’objectif serait de détecter des feuilles individuelles. Ici l’objectif est plutôt de détecter des zones de feuillages. En pratique, les bordures des feuilles ne sont pas toujours très distinctes selon l’enchevêtrement des organes. Modéliser et classifier les bordures à part sert surtout à éviter les confusions entre certaines portions des feuilles et des tiges. En effet dans les deux cas, les structures observées sont très directionnelles et il convient donc d’avoir un modèle particulier pour ces parties spécifiques du feuillage.

---

3. multivariate Gaussian

4. multivariate Gaussian Mixture





■ Limbes   ■ Grappes   ■ Tiges   ■ Bordures des feuilles

(a) Image labellisée pour les quatre classes : « Limbes », « Grappes », « Tiges » et « bordures »



(b) image originale stade BBCH79

FIGURE 24: Exemple de labellisation : vérité terrain au stade BBCH79 (a). Image originale correspondante (b)

Pour chaque stade phénologique, 16 images de vérité terrain sont labellisés. Pour chaque image environ  $2 \cdot 10^5$  pixels sont échantillonnés. L'effectif de chaque classe dépend de l'abondance relative des classes dans les images. Ce jeu d'images est utilisé comme ensemble d'apprentissage pour l'estimation des modèles considérés. Il permet par ailleurs d'évaluer les performances de classification par un procédé de validation croisée « Leave one out ». Selon ce procédé, l'apprentissage est réalisé sur l'ensemble des images à l'exception d'une image de test sur laquelle est réalisée la validation. Les performances sont exprimées sous forme de « matrices de confusions » qui détaillent les concordances et les non-concordances entre les labels réels et les labels estimés pour chacune des classes. A partir de ces matrices de confusion, trois métriques sont calculées : « la précision globale<sup>5</sup>(OA) », la « précision » et le « rappel ». L'OA résume les performances globales atteintes pour toutes les classes considérées. L'OA représente la proportion d'individus correctement classifiés par rapport au nombre d'individus testés. La précision représente, parmi les individus affectés à la classes  $c$ , la proportion des individus qui appartiennent effectivement à  $c$ . Le rappel représente, pour une classe donnée, la proportion des individus appartenant réellement à cette classe qui ont été estimés correctement. La figure 25 décrit le principe général d'une matrice de confusion pour 4 classes ainsi que le principe de calcul des trois métriques proposées.

		Classes prédites				Rappel	OA
		A	B	C	D		
Classes réelles	A	$VP_A$	$FN_A$			$\frac{VP_A}{VP_A + FN_A}$	$\frac{\sum(VP)}{\sum(VP + FN)}$
	B	$FP_A$	$VP_B$			$\frac{VP_B}{VP_B + FN_B}$	
	C			$VP_C$		$\frac{VP_C}{VP_C + FN_C}$	
	D				$VP_D$	$\frac{VP_D}{VP_D + FN_D}$	
Précision		$\frac{VP_A}{VP_A + FP_A}$	$\frac{VP_B}{VP_B + FP_B}$	$\frac{VP_C}{VP_C + FP_C}$	$\frac{VP_D}{VP_D + FP_D}$		

FIGURE 25: Estimation des métriques de performance OA, précision et rappel à partir des instances « Vrai Positifs (VP) », « Faux Négatifs (FN) » et « Faux positifs » (FP).

5. Overall Accuracy en anglais





(a) Stade BBCH68



(b) Stade BBCH75



(c) Stade BBCH79

FIGURE 26: Images de trois pieds aux stades BBCH68 (a), BBCH75 (b) et BBCH79 (c).  
92

## 4.5.2 Optimisation des paramètres d'échelle

Le calcul des tenseurs de structure, tel qu'il a été défini dans la [partie 3.2](#), dépend essentiellement de deux paramètres d'échelle. Le paramètre  $\sigma_g$  détermine l'échelle à laquelle les gradients sont calculés. Le paramètre  $\sigma_t$  détermine l'échelle à laquelle est considérée l'information de structure i.e. l'échelle à laquelle le tenseur est régularisé par filtrage gaussien (cf. équation [3.3](#)). Tandis que le premier paramètre se doit d'être défini en fonction de la taille des motifs élémentaires observés, le second se doit d'être en cohérence avec l'échelle à laquelle l'organisation des motifs élémentaires (*i.e.* la texture) doit être décrite. Les valeurs conjointes de ces deux paramètres d'échelle peuvent donc avoir une forte influence sur la pertinence des propriétés décrites par les tenseurs structure. Il s'agit donc dans cette partie de déterminer un couple de paramètres qui optimise les performances de classification. Cependant, le couple optimal de paramètres d'échelle peut être variable selon les classes de tissus et les stades de développement considérés. En effet, observée à petite échelle, la texture des feuilles est décrite par sa granularité et la présence de discontinuités au niveau des nervures. A des échelles plus importantes, la texture des feuilles se décrit par des motifs plus lisses et plus réguliers. De la même manière, pour les grappes, les petites échelles d'analyses permettent de décrire les propriétés de structure radiale des baies de raisin, tandis que des échelles supérieures décriront plutôt des motifs relatifs à l'agencement des baies et des pédoncules autour de la rafle.

Pour déterminer un couple  $(\sigma_g, \sigma_t)$  permettant de décrire convenablement toutes les classes considérées, il convient de trouver un compromis entre les échelles optimales des différentes classes. Il est également possible de considérer différentes échelles adaptées à chaque classe, en particulier s'il n'existe pas un couple unique de paramètres permettant ce compromis. Dans le cas d'une approche multi-échelles, il s'agit soit de considérer un descripteur qui décrit la structure à différentes échelles, soit de comparer les descripteurs propres à chaque échelle et de déterminer localement l'échelle la plus pertinente.

La détermination d'un couple permettant de décrire et de discriminer les classes de tissus considérés est loin d'être triviale. Cette question a déjà été partiellement abordée dans la [partie 3.4](#) et notamment à travers l'analyse de la [figure 14](#). Dans cette partie, il est proposé de déterminer expérimentalement le couple de paramètres d'échelle qui optimise les performances de classification à chacun des stades phénologiques considérés (BBCH 68, 75 et 79).

La figure 27 présente les performances de classification de chacune des classes en fonction du couple de paramètres d'échelle considérés. Les résultats sont présentés pour le stade BBCH 79 (fermeture des grappes). Ces résultats sont obtenus avec les modèles  $mvG$  en représentation  $CELEST_{RGB}$  sans régularisation spatiale.

Pour toutes les classes à l'exception de « bordure des feuilles », la métrique de précision est très stable aux variations de l'échelle  $\sigma_t$  du tenseur pour une valeur fixe de l'échelle  $\sigma_g$  des gradients. Les bordures des feuilles constituant les régions les plus étroites ( $< 4px$ ), il est ainsi plutôt difficile de caractériser leurs propriétés de structure pour des échelles supérieures à leur épaisseur. En pratique, lorsque l'échelle d'analyse est trop grande, une certaine proportion des bordures est classifiée dans la classe « limbes ». Cette proportion augmente pour des valeurs croissantes de  $\sigma_g$  et  $\sigma_t$ . Concernant les autres classes, le seul cas où il est possible d'atteindre une précision de 80% pour les grappes est lorsque  $\sigma_g = 3.5$ . C'est aussi cette échelle de gradient qui maximise la précision pour la classe « feuille », qui atteint 98% tout en assurant un minimum de 80% de précision pour la classe « tiges ».

Les taux de rappel sont quant à eux plus sensibles aux variations d'échelle des tenseurs ( $\sigma_t$ ). Sur la plage de paramètres considérée dans les cas des tiges et des limbes, le rappel a tendance à décroître pour des valeurs croissantes de  $\sigma_t$ . Inversement, dans le cas des grappes, le rappel a tendance à augmenter dans les mêmes proportions. Il faut donc déterminer un compromis qui permette de maximiser conjointement les rappels des classes les plus importantes (limbes et grappes). Ce compromis peut être trouvé à l'intersection des courbes de rappel de ces deux classes, à la valeur  $\sigma_t = 5.5$ . Finalement, le rappel optimal est obtenu pour le couple  $(\sigma_g = 3.5, \sigma_t = 5.5)$ , ce qui permet à la fois de maximiser le rappel de la classe « grappes » tout en assurant un rappel de 88% pour la classe « limbe » et de 87% pour la classe « tige ». Les paramètres permettant le meilleur compromis sont ainsi les mêmes pour les deux métriques. Dans la suite du chapitre, tous les analyses de performances sont conduites avec des tenseurs calculés à partir de ce couple  $(\sigma_g = 3.5; \sigma_t = 5.5)$ .

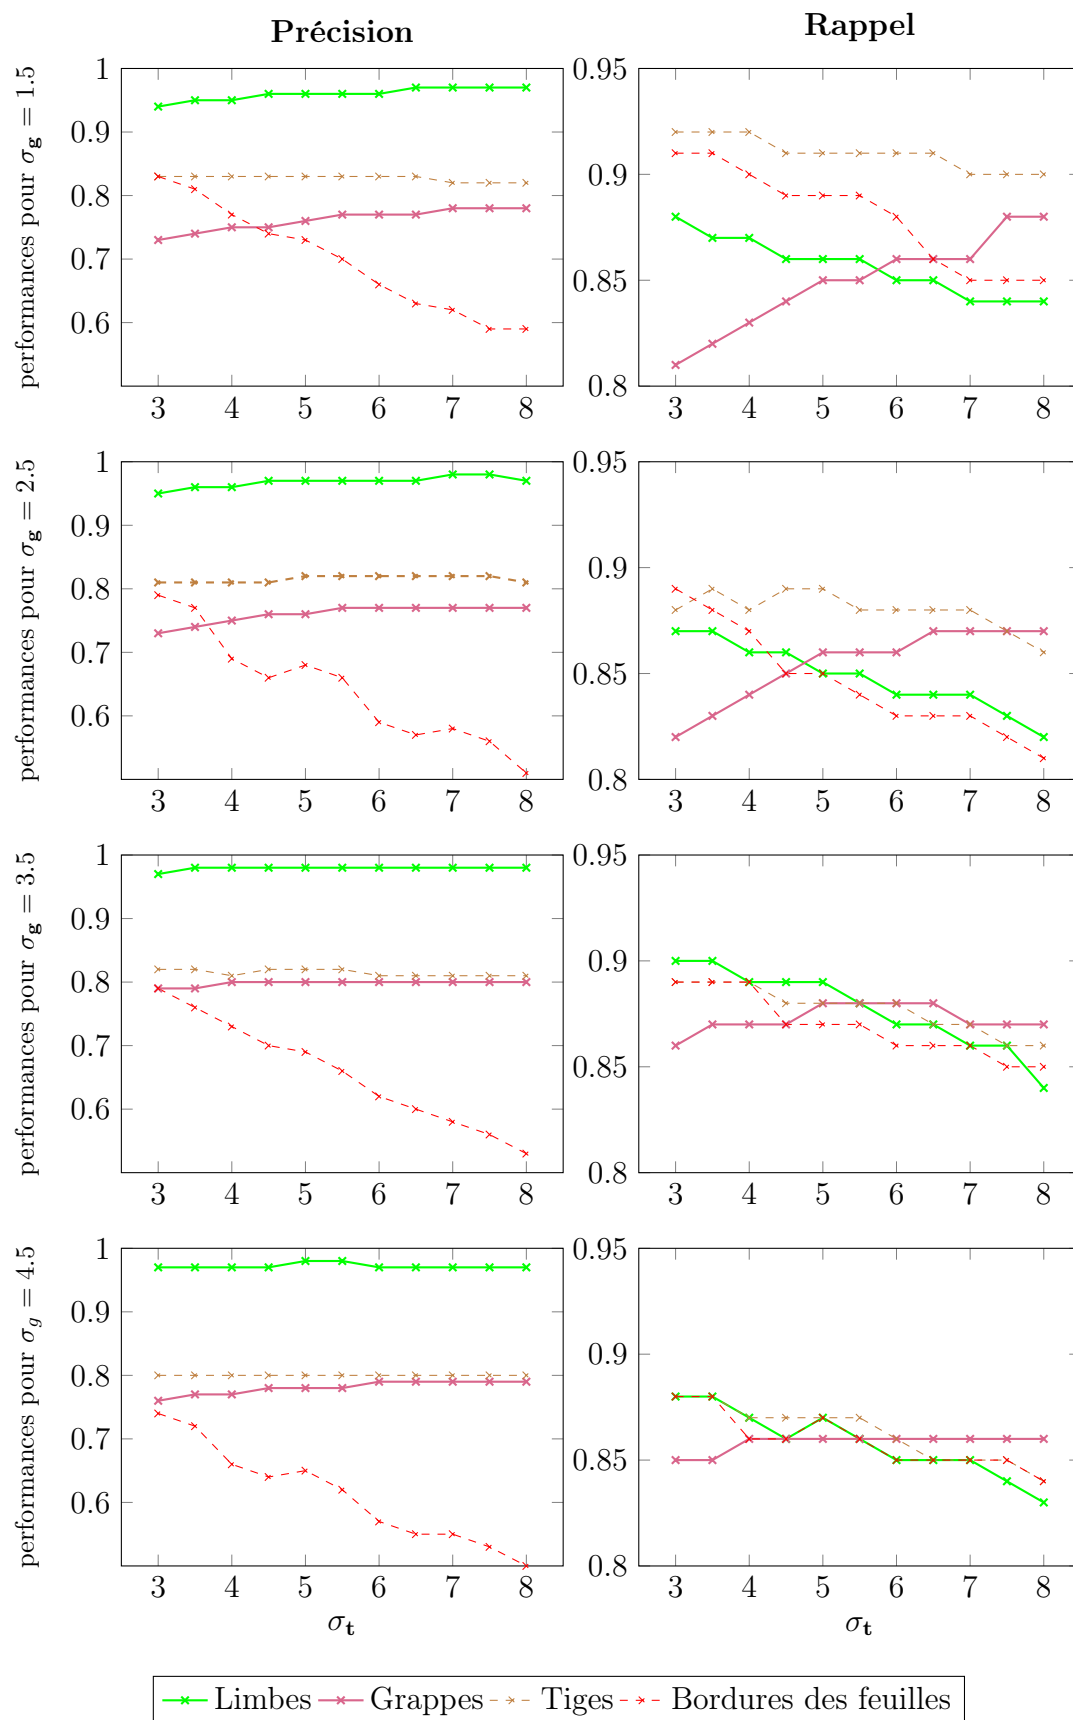


FIGURE 27: Influence du paramètre d'échelle  $\sigma_t$  pour différentes échelles  $\sigma_g$  des gradients sur les performances de classification au stage BBCH 79 (fermeture de la grappe). La colonne de gauche présente la métrique « précision », celle de droite la métrique « rappel »



### 4.5.3 Analyse des procédés de régularisation spatiale

La figure 28 présente le résultat des opérations de régularisation spatiale pour un exemple de classification issue de l'estimation MAP. Cette figure compare une classification obtenue avec la représentation  $CELEST_{RGB}$  pour la modalité  $mvGM + pi_c(h)$  au stade BBCH79 ( figure 28(a) ) avec le résultat régularisé par l'ICM et les opérations de morphologie mathématiques ( figure 28(b) ). La régularisation produit une classification plus cohérente spatialement. En effet l'image régularisée présente des régions dont les labels sont plus homogènes où les variations sporadiques de labels engendrés par l'estimation MAP sont éliminées. De plus, certaines erreurs récurrentes, comme des petits amas de pixels classifiés comme des limbes ou des bordures qui sont enclavés dans des grappes (ou *vice versa*) sont corrigées. Cependant, dans certains cas la régularisation peut simplifier à l'excès certains contours irréguliers, faisant disparaître des bordures ou de petites excroissances dans les grappes. Ainsi, le processus peut engendrer quelques nouvelles erreurs. Néanmoins, dans ce type d'images où les régions sont plutôt étendues et continues, la proportion de contours est considérablement plus faible en comparaison avec le cœur des organes, ce qui justifie l'utilisation d'une régularisation spatiale.

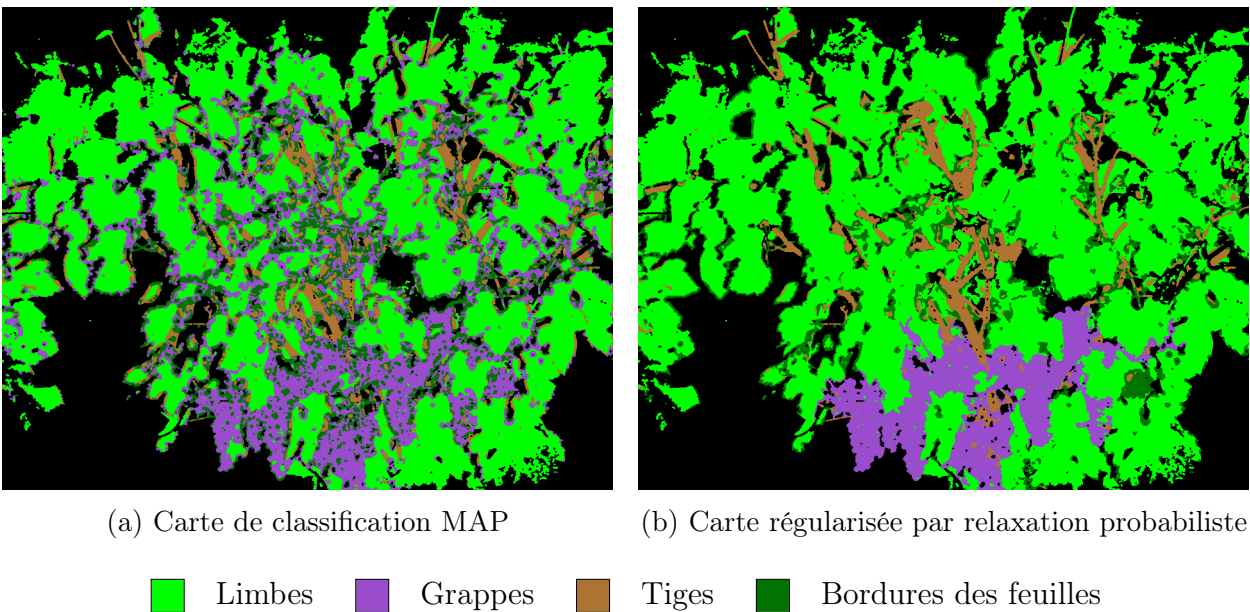


FIGURE 28: Exemple de résultats de régularisation par relaxation probabiliste (b) obtenus à partir d'une classification pixellaire au stade BBCH79 (a). La classification est produite avec la représentation  $CELEST_{RGB}$  pour la modalité  $mvGM + pi_c(h)$

Par ailleurs, la régularisation permet d'améliorer les performances de classification, même si ce n'est pas l'objectif principal. Cette amélioration peut être quantifiée lors du processus de validation. Le tableau 4.1 compare les matrices de confusion et les métriques associées qui résultent du traitement de 16 images au stade BBCH79 avant et après régularisation spatiale. Les résultats sont exprimés pour environ  $3.2 \times 10^6$  pixels labellisés représentant près d'un douzième des pixels du premier plan des 16 images. L'OA progresse de 92% à 94% après la régularisation spatiale. Cette progression est principalement due à une augmentation significative de la précision et du rappel pour les classes « limbes », « grappes » et « bordures ». Par exemple, 50% des pixels de limbes incorrectement classifiés comme des grappes et 68% des pixels de grappes incorrectement classifiés comme des limbes sont corrigés par la régularisation. De la même manière, 70% des bordures de feuilles incorrectement classifiées comme des grappes et 50% comme des tiges sont correctement réaffectées. Cependant la régularisation augmente aussi de 25% les erreurs de classification de tiges dans la classe limbe, ce qui cause une diminution de 2% du rappel et de la précision pour cette classe.

TABLE 4.1: Influence de la régularisation spatiale sur les performances de classification. Exemple pour un jeu de 16 images au stade BBCH 79

(a) sans régularisation		Classe prédite				Total	Rappel	OA
		Limbes	Grappes	Tiges	Bordures			
Classe réelle	Limbe	1702436	50162	9269	5131	1766998	0.96	0.92
	Grappes	49196	690458	2020	10292	751966	0.92	
	Tiges	29106	18887	379623	11733	439349	0.86	
	Bordures	37791	15951	9248	172535	235525	0.73	
Total		1818529	775458	400160	199691			
Précision		0.94	0.89	0.95	0.86			

(b) après régularisation		Classe prédite				Total	Rappel	OA
		Limbes	Grappes	Tiges	Bordures			
Classe réelle	Limbes	1709775	23367	23543	10313	1766998	0.97	0.94
	Grappes	16769	722641	1678	10878	751966	0.96	
	Tiges	39259	15579	371062	13449	439349	0.84	
	Bordures	15074	6612	4726	209113	235525	0.89	
Total		1780877	768199	401009	243753			
Précision		0.96	0.94	0.93	0.86			

#### 4.5.4 Comparaison des représentations *LEEST* et *CELEST*.

Les représentations *LEEST* et *CELEST* sont deux variantes d'un descripteur structure-couleur. Elles diffèrent par leurs dimensions vectorielles et leurs propriétés d'invariance en rotation. *LEEST* est une représentation des covariances structure-couleur en dimension 15. *CELEST* est une représentation plus compacte (en dimension 5) permettant de combiner informations de couleur et de structure tout en garantissant une invariance en rotation. La représentation *CELEST* pourrait se montrer plus adéquate pour l'apprentissage de modèles et l'estimation des paramètres à partir d'un échantillon limité avec une meilleure stabilité numérique, particulièrement dans la mesure où de nombreuses étapes de la chaîne de traitement impliquent le calcul et l'inversion de matrices de covariances. Le tableau 4.2 compare les performances de classification obtenues soit avec des descripteurs purement structurels (LST), soit avec des descripteurs purement colorimétriques (RGB), soit avec les repré-

tations *LEEST* et *CELEST* qui combinent les deux. La comparaison est établie pour le stade BBCH79 avec des modèles gaussiens *mvG*.

TABLE 4.2: Comparaison des descripteurs et des représentations au stade BBCH 79 pour des modèles *mvG* sans régularisation ( $\sigma_g = 3.5, \sigma_t = 5.5$ ).

Représentation	Précision				Rappel				OA
	Limbes	Grappes	Tiges	Bordures	Limbes	Grappes	Tiges	Bordures	
RGB	0.48	0.37	0.29	0.17	0.69	0.51	0.43	0.22	0.41
LST	0.96	0.61	0.68	0.27	0.79	0.74	0.53	0.55	0.72
LEEST	0.95	0.79	0.80	0.45	0.86	0.79	0.81	0.75	0.83
CELEST	<b>0.98</b>	<b>0.80</b>	<b>0.82</b>	<b>0.67</b>	<b>0.88</b>	<b>0.88</b>	<b>0.89</b>	<b>0.87</b>	<b>0.88</b>

Seule, l'information purement colorimétrique n'est pas suffisante pour décrire et discriminer les différents tissus de la vigne. Les résultats fondés uniquement sur la colorimétrie produisent des classifications médiocres, comme le montre l'OA de 41%. L'information purement structurelle fournie par les LST décrit bien mieux les propriétés des tissus étudiés. En effet, dans le cas des LST, l'OA dépasse 70%. Toutefois, les performances de classification sont encore insuffisantes pour retranscrire l'architecture et les propriétés physiologiques des pieds de vigne. Dans ce cas, les taux de rappel sont en dessous de 80% et la précision est médiocre pour la classe « grappes » (61%). Dans le cas des deux représentations *LEEST* et *CELEST*, les performances de classification sont significativement améliorées. Les représentations conjointes structure-couleur sont donc essentielles pour extraire les propriétés distinctes des classes de tissus étudiées. Les OA dans ces représentations atteignent respectivement 83% et 88%. La représentation *CELEST*, bien que plus simple dans la manière de joindre les informations de structure et de couleur, se montre plus performante pour toutes les classes que la représentation *LEEST*, plus complexe et plus riche en information. L'avantage de *CELEST* se perçoit notamment par les taux de rappel des classes « grappes » et « tiges », respectivement de 88% et 89% contre 79% et 81% pour *LEEST*. Dans la suite du chapitre, la chaîne de traitement sera uniquement étudiée en considérant les descripteurs structure-couleur dans la représentation *CELEST*.



Le tableau 4.3 compare les performances de classification obtenues pour différentes combinaisons de modalités de décision et de régularisation. Les comparaisons sont réalisées uniquement au stade BBCH79 pour la représentation *CELEST*. Les modèles *mvGM* ont été considérés pour des mélanges de  $K = 3$  modes gaussiens, la dimension de mélange bien adaptée à notre cas (voir chapitre 3). L'utilisation de la modalité  $\pi_c(h)$  tend à améliorer globalement les performances de classification, comme le montre une légère augmentation de L'OA (+2%). En revanche, l'amélioration des performances par cette modalité est variable. Par exemple pour les classes « grappes » et « tiges », la précision augmente avec cette modalité alors que la précision de la classe « feuilles » décroît tandis que son rappel augmente. Le même constat est réalisé pour la modalité ICM : bien que ce ne soit pas le rôle principale de la régularisation spatiale, elle contribue à une légère augmentation globale des performances (OA), mais avec une certaine sélectivité pour les performances intra-classe. Les modèles de mélange *mvGM* se montrent toujours plus performants que les modèles gaussiens simples *mvG* pour toutes les classes à l'exception de la classe « bordures ». Finalement en combinant toutes les modalités proposées,  $mvGM + \pi_c(h) + ICM + Morph$  on obtient les performances maximales de classification.

TABLE 4.3: Comparaison des différentes modalités de décision et de régularisation pour la représentation *CELEST* au stade BBCH 79

Modalités		Précision				Rappel				OA
Décision	Régularisation	Limbes	Grappes	Tiges	Bordures	Limbes	Grappes	Tiges	Bordures	
mvG	$\emptyset$	0.98	0.80	0.82	0.67	0.88	0.88	0.89	0.87	0.88
mvG + sprob	$\emptyset$	0.94	0.88	0.89	0.82	0.95	0.89	0.86	0.76	0.90
mvG + sprob	ICM	0.97	0.85	0.86	0.77	0.94	0.90	0.89	0.90	0.91
mvGM	$\emptyset$	0.98	0.83	0.87	0.75	0.90	0.91	0.92	0.86	0.90
mvGM + sprob	$\emptyset$	0.94	0.89	0.95	0.86	0.96	0.92	0.86	0.73	0.92
mvGM+ sprob	ICM	0.91	0.94	0.95	0.81	0.97	0.93	0.84	0.93	0.92
mvGM + sprob	ICM + Morph	<b>0.96</b>	<b>0.94</b>	<b>0.93</b>	<b>0.86</b>	<b>0.97</b>	<b>0.96</b>	<b>0.84</b>	<b>0.89</b>	<b>0.93</b>

#### 4.5.5 Performances et robustesse de la chaîne de traitement à différents stades phénologiques

Après réglage des paramètres, l'application de la chaîne de traitement produit des classifications très proches des vérités terrains pour les trois stades phénologiques considérés. Cette chaîne est obtenue en combinant la représentation *CELEST*, les modèles *mvGM*, la gestion des probabilités a priori avec la modalité  $\pi_c(h)$  et les procédés de régularisation spatiale. Le tableau 4.4 présentent les métriques de performances de cette chaîne pour trois stades : BBCH68, BBCH75 et BBCH79. Les métriques de classification dépassent toutes 80% (sauf pour la classe annexe « bordures ») et atteignent jusqu'à 97%. Les performances propres à


chaque classe sont variables selon les stades phénologiques. Ces différences s’expliquent par la fiabilité de l’estimation de la répartition spatiale des organes  $\pi_c(h)$ , en particulier dans le cas du stade BBCH75, où il existe une grande variabilité de positions et d’abondance des grappes ainsi qu’une grande variabilité de densité du feuillage entre les images. Pour les stades suivants, certaines opérations mécaniques (rognage, effeuillage, éclaircissage) ont tendance à rendre ces paramètres plus homogènes d’un pied de vigne à l’autre. La figure 29 présente pour chaque stade phénologique un exemple représentatif des classifications (b,d,f) issus de cette chaîne de traitement qui sont très proches des images originales (a,c,e). S’il est difficile avec cette méthode de segmenter individuellement chaque organe, elle permet de retranscrire très fidèlement la morphologie et l’espace occupé par les classes majoritaires (limbes et grappes / inflorescences). La figure 29 montre les difficultés à définir avec précision les limites des feuilles. Dans certains cas les bordures ne sont pas détectées (f) ou alors détectées à l’excès au niveau de certaines nervures centrales ou à la convergence de plusieurs feuilles (d). Par ailleurs, si les plus grosses tiges sont correctement retranscrites, celles qui sont très occultées sont plus rarement détectées. Dans les zones plus hétérogènes on observe certains faux positifs pour les tiges. Finalement, ces résultats permettent toutefois d’estimer la surface des feuilles et des fruits visibles, d’estimer la porosité du feuillage et l’espacement entre les fruits avec une fiabilité très satisfaisante.

TABLE 4.4: Comparaison des performances obtenues avec les modalités de la chaîne de traitement optimisée pour trois stades phénologiques BBCH68, BBCH75 et BBCH79.

Metriques	Précision				Rappel				OA
Stade phénologique	Limbes	Grappes	Tiges	Bordures	Limbes	Grappes	Tiges	Bordures	
Floraison : phase terminale (BBCH 68)	0.90	0.88	0.93	0.84	0.94	0.90	0.83	0.75	0.91
Petits-pois (BBCH 75)	0.86	0.82	0.89	0.69	0.84	0.92	0.73	0.77	0.88
Fermeture des grappes (BBCH 79)	0.96	0.94	0.93	0.86	0.97	0.96	0.84	0.89	0.93




(a) image originale BBCH68



(b) Carte de classification  $CELEST_{RGB}$  BBCH68




(c) Image originale BBCH75



(d) Carte de classification  $CELEST_{RGB}$  BBCH75



(e) Image originale BBCH79



(f) Carte de classification  $CELEST_{RGB}$  BBCH79

Limbes
  Grappes
  Tiges
  Bordures des feuilles

FIGURE 29: Résultats de la chaîne de traitement : classifications pixellaires obtenues avec la modalité  $CELEST_{RGB} + mvGM + sprob + ICM$  pour les stades BBCH 68 (b), BBCH 75 (d) et BBCH 79 (f).

## 4.6 Conclusion du chapitre

Ce chapitre a permis de valider expérimentalement l'intérêt des modèles statistiques décrivant conjointement des propriétés structure-couleur pour caractériser et discriminer les différents tissus sains présents sur un pied de vigne. La validation expérimentale a été réalisée à l'aide de tests de classification et de l'analyse des métriques de performance. Les représentations conjointes structure-couleur et les modèles paramétriques proposés dans le [chapitre 3](#) ont pu être combinés à des procédés de décision probabiliste bayésienne (le MAP) et de relaxation markovienne pour former une chaîne de traitement cohérente, permettant de classifier les images en catégories de tissus sains. Pour chaque étape de la chaîne de traitement, différentes modalités ont été considérées et comparées en termes de performances de classification pour finalement définir une chaîne de traitement bien adaptée au problème.

Pour ce qui concerne les descripteurs, deux questions ont été étudiées : l'échelle d'analyse de la structure et la méthode de représentation conjointe structure-couleur. L'échelle d'analyse est l'un des paramètres de la chaîne qui doit être ajusté par l'opérateur. Les paramètres d'échelles peuvent être définis intuitivement de manière à correspondre à la taille des textures étudiés. Dans une plage de valeurs cohérente avec les textures, le tenseur local de structure se montre plutôt robuste aux variations d'échelles d'analyse et produit des résultats de classification dont les performances sont stables. Concernant les représentations, l'approche *CELEST*, invariante en rotation, est la plus fiable numériquement (sans doute du fait de sa compacité) . En pratique, c'est aussi la représentation qui permet les meilleures performances de classification. Pour l'étape de modélisation des descripteurs, si l'utilisation de modèles gaussiens permet d'obtenir des classifications convenables, le choix de modèles de mélange, théoriquement plus adaptés, (voir [chapitre 3](#)) se révèle également plus performant en termes de classification. Les performances sont aussi significativement améliorées grâce à l'introduction de probabilités *a priori* comme une fonction spatiale qui dépend du stade phénologique considéré. La relaxation markovienne, quant à elle, permet de synthétiser les décisions locales prises en fonction d'un modèle afin de respecter des critères de cohérence spatiale et de rendre compte de l'agencement des tissus en organes.



Finalement, une fois réglée, cette chaîne de traitement permet de reconstruire fidèlement la carte des organes de la vigne pour des stades phénologiques où la structure de la vigne et la morphologie des organes sont très différentes. Ces résultats originaux montrent qu'il est possible de surmonter les difficultés que pose l'analyse d'images acquises dans le contexte applicatif contraignant de la viticulture. Il convient quand même de noter que la chaîne de traitement est validée pour un jeu de données très restreint (16 images par stade phénologique), pour des conditions de cultures assez homogènes. Ce nombre d'images limité tient à la durée considérable de l'étape d'annotation nécessaire à l'apprentissage. Si, malgré la taille relativement faible du jeu de données ( $\sim 10^8 pixels$ ), il est possible d'apprendre des modèles stables et d'appliquer la chaîne de traitement à toutes les parcelles étudiées, la taille des données de vérité terrain reste une limite majeure pour valider la méthode. Afin d'évaluer les performances de la méthode, il serait souhaitable de l'appliquer dans un contexte expérimental d'agriculture de précision plus vaste pour lequel on disposerait de données agronomiques locales comparables aux informations que l'on peut extraire des résultats de classification e.g. des surfaces foliaires, des porosités ou des poids de grappes. De plus, il faudrait pouvoir évaluer le potentiel d'exploitation des cartes de classification dans un contexte agronomique plus varié en termes de cépages et de pratiques culturales.

Enfin, les méthodes proposées dans la chaîne de traitement sont suffisamment génériques et maîtrisées pour considérer de les transposer à la détection de tissus symptomatiques dans le cas de la vigne ou à d'autres cultures présentant des structures similaires comme les arbres fruitiers. Le chapitre suivant propose d'adapter ces méthodes pour développer une chaîne de traitement dédiée à la détection de symptômes foliaires du mildiou de la vigne.

# CHAPITRE 5

---

## Détection des symptômes du mildiou de la vigne et estimation de l'intensité de l'infection

---

### 5.1 Introduction

Ce chapitre présente et évalue une chaîne de traitement d'images dédiée à la détection des symptômes du mildiou de la vigne et à l'estimation de l'intensité de l'infection. Il s'agit de dénombrer les symptômes et d'estimer la proportion de surfaces symptomatiques afin de quantifier l'intensité de la pathologie sur chaque pied. La stratégie de classification pixellaire présentée dans le [chapitre 4](#) apparaît *a priori* adaptée pour répondre à ces objectifs . En effet, les représentations structure-couleurs proposées semblent pouvoir décrire et discriminer les symptômes du mildiou (voir [partie 3.4](#)). De plus, il a déjà été montré sur la base de ces représentations qu'il est possible de modéliser la distribution des symptômes du mildiou de la même manière que les classes de tissus sains (voir [partie 3.5](#)). Toutefois, le problème de la détection de symptômes demeure plus complexe que celui traité dans le chapitre précédent. Il s'agit de caractériser à une échelle très fine des phénomènes rares et disséminés dans les images. En effet, les symptômes apparaissent de manière sporadique sous la forme de discontinuités dans les tissus sains. Cependant les limites entre les zones symptomatiques et les zones saines sont moins franches que celles observées dans les zones d'enchevêtrement des organes. De plus, la morphologie des symptômes du mildiou évolue dans le temps plus rapidement que les tissus sains qui évoluent selon des stades phénologiques bien définis.

La première partie du chapitre consiste à évaluer l'influence de ces limites sur les performances de la chaîne de traitement présentée dans le [chapitre 4](#) pour la classification de symptômes du mildiou. Au regard des nouvelles difficultés que pose la classe de tissus symptomatiques, la seconde partie introduit une nouvelle méthode de décision. Elle consiste en une reconstruction par hystérésis des symptômes à partir de germes plus facilement identifiés, effectuée sur la base d'une combinaison de deux critères relatifs aux distances de Mahalanobis entre les descripteurs et les modèles des différentes classes de tissus.


## 5.2 Données d'apprentissage et de validation

Dans ce chapitre, on considère un jeu de 100 images issues d'une même parcelle de Merlot noir. Les images ont été acquises à la mi-juin 2018, au stade « petit-pois » (BBCH 75). Toutes les images étudiées sont soit saines, soit atteintes uniquement par le mildiou et par des stress abiotiques se manifestant sous la forme de nécroses ou de décolorations. Ce jeu d'images représente une situation sanitaire à la fois courante et délicate en viticulture. En effet, les symptômes sont encore rares à l'échelle de la parcelle et précoces pour la plupart, cependant la densité locale des symptômes sur certains pieds traduit une présence d'*inoculum* pouvant aboutir rapidement à une épidémie générale. C'est dans ce contexte qu'une évaluation complète des parcelles présente le plus d'intérêt. L'enjeu principal est ainsi de repérer les premiers groupes de symptômes qui présentent un risque.

Le jeu d'images est labellisé en 7 classes : « Limbes », « Bordures de feuilles », « Grappes », « Tiges », « Mildiou feuilles », « Mildiou grappes » et « Anomalies » (les symptômes des stress abiotiques). Pour chaque image, environ  $5 \cdot 10^4$  pixels sont labellisés. Pour les classes de mildiou, tous les pixels, identifiés par photo-interprétation des images, sont labellisés. Au total, on dispose d'une base de données de  $4,7 \cdot 10^7$  pixels labellisés dont  $5,5 \cdot 10^4$  dans la classe « Mildiou feuilles ». La figure [30](#) présente un exemple de labellisation des 7 classes considérées. On s'intéresse ici uniquement aux performances de classification des symptômes foliaires du mildiou. En effet, les symptômes présents sur les grappes sont extrêmement rares dans notre cas d'étude et le modèle associé à cette classe est peu adéquat (voir [chapitre 3](#), partie [3.5](#)). Comme dans le chapitre précédent, le jeu de données constitue à la fois l'ensemble d'apprentissage et l'ensemble de validation croisée (« leave-one-out »).



(a) Image originale



■ Limbes    ■ Grappes    ■ Tiges    ■ Bordures des feuilles  
■ Mildiou feuilles    ■ Mildiou grappes    ■ Anomalies

(b) Image labellisée en 7 classes

FIGURE 30: Exemple de labellisation des tissus sains, des tissus symptomatiques et des anomalies (b) de l'image originale (a).



### 5.3 Limites de la classification par MAP pour la détection des symptômes du mildiou

En matière de détection de symptômes du mildiou, une première difficulté de la stratégie de classification pixellaire du [chapitre 4](#) concerne la modélisation. En effet, la classe des tissus symptomatiques présente une variabilité intrinsèque plus importante que les classes précédemment étudiées. Les symptômes du mildiou peuvent être très diversifiés en termes de taille, de faciès et même de colorimétrie (voir [figure 31](#)). De plus, certains attributs des symptômes peuvent se confondre avec d'autres classes de tissus. Par exemple au sein des symptômes précoces, les parties externes ou les parties les plus estompées des « taches d'huiles » peuvent présenter une forte ressemblance avec certains jeunes tissus foliaires sains ou avec des tissus carencés. Certains symptômes plus sévères, notamment ceux dont la partie centrale se nécrose, montrent des similarités avec des décolorations rencontrées en périphérie de nécroses d'origine « mécanique » (plaies de rognage, d'effeuillage, impacts de grêle, brûlures). Ainsi les vraisemblances de ces éléments aux modèles de la classe mildiou peuvent être moins discriminantes.

Une seconde difficulté majeure concerne l'estimation du MAP (Maximum *A Posteriori*). Pour rappel, le MAP, s'exprime sous la forme :

$$\hat{c} = \underset{c \in L}{\operatorname{argmax}} p(c|\vec{Y}) = \underset{c \in L}{\operatorname{argmax}} f(\vec{Y}|c) \cdot p(c),$$

où  $f(\vec{Y}|c)$  représente la vraisemblance d'un descripteur  $\vec{Y}$  au modèle de la classe  $c$  et  $p(c)$  représente la probabilité *a priori* de la classe  $c$ , *i.e.* la proportion de la classe  $c$  dans les images. La qualité du résultat de classification dépend du pouvoir discriminant du descripteur considéré et de la séparabilité des modèles des différentes classes. Dans la mesure où certains individus marginaux des classes de tissus sains possèdent des propriétés similaires à certaines parties des symptômes, on peut s'attendre à certaines confusions. En ce qui concerne l'estimation des probabilités *a priori*, la tâche est également plus complexe dans le cas du mildiou.




(a)



(i)



(ii)



(iii)



(iv)



(v)



(vi)

(b)

FIGURE 31: Exemple d'une image représentative du jeu de données, (a) les symptômes sont entourés par des cercles rouges . (b) Les symptômes sont présentés avec plus de détails.

En effet, sur les organes sains, il est possible de s'appuyer sur la connaissance de l'architecture et de la phénologie de la vigne pour estimer les probabilités *a priori* des classes. Dans le cas du mildiou, on dispose de moins d'information pour estimer la probabilité *a priori* d'apparition des symptômes. Cependant il est raisonnable de faire l'hypothèse que l'apparition d'un symptôme est un phénomène rare, en particulier parce que l'on cherche à estimer le risque de déclaration d'une épidémie plutôt que de faire l'état des lieux d'une infestation sévère. Pour estimer cette probabilité *a priori*, il reste possible de s'appuyer sur certaines données exogènes, par exemple un risque climatique combiné à une estimation antérieure de l'état sanitaire. Toutefois, la répartition des symptômes du mildiou, est très variable sur une parcelle. De plus, la répartition spatiale des symptômes au sein d'un même pied n'obéit pas à une règle connue. Les symptômes peuvent aussi bien être concentrés sur les jeunes parties de la plante *i.e.* souvent le sommet du feuillage, comme ils peuvent être concentrés dans le cœur du feuillage plus dense et donc plus sujet à l'humidité, ou encore être répartis uniformément.


La probabilité *a priori* est une composante d'autant plus importante que l'on s'intéresse à une classe aussi rare que les symptômes du mildiou. Elle permet ici de moduler la vraisemblance pour ne conserver que les instances les plus proches du modèle mildiou. Déjà, dans le cas de la classification des tissus, les expériences du [chapitre 4](#) ont montré l'importance de la probabilité *a priori* et l'amélioration des performances de classification lorsqu'on dispose d'une bonne connaissance *a priori* de la distribution des classes. Aussi, il conviendra ici, pour le cas spécifique des symptômes foliaires du mildiou, d'évaluer la pertinence de l'estimateur MAP en fonction de différentes hypothèses sur la probabilité *a priori* d'apparition de cette classe.

La figure [31](#), illustre la variabilité des symptômes et leur répartition spatiale. Elle présente une image avec une douzaine de symptômes disséminés sur tout le plan vertical du feuillage (fig [31a](#)). La figure [31\(b\)](#) présente plus en détail les symptômes. Certains symptômes sont très distinctifs : (i) tache d'huile nécrosée au centre qui couvre tout le cœur de la feuille, (ii) couronne de petites taches d'huile commençant à se nécroser, (iii) taches d'huile coalescentes. D'autres symptômes sont plus discrets à la fois sur la face inférieure des feuilles (iv) et (vi) et sur la face supérieure (v). La difficulté consiste alors à retrouver ces quelques particularités parmi toute une diversité de tissus et de structures.

Comparons dans un premier temps les décisions prises sur la base du MV (Maximum de Vraisemblance) ou du MAP pour l'exemple d'une image représentative de la variabilité des symptômes au sein du jeu de données. La figure 32 permet de comparer pour cet exemple les résultats de classification dans deux situations. Dans la première situation, on considère qu'on ne dispose pas de connaissance permettant d'estimer la probabilité *a priori* de la classe mildiou. Les décisions s'appuient alors non pas sur l'estimation du MAP mais sur l'estimation du MV, ce qui revient à considérer toutes les classes équiprobables. La classification résultante du MV est présentée sur la figure 32(a). Dans la seconde situation, on fait l'hypothèse que la classe mildiou couvre 5% de la surface foliaire, autrement dit que la probabilité a priori de la classe mildiou est égale à 5% de celle de la classe feuille. Les résultats de classification sous cette hypothèse sont présentés figure 32(b). Dans les deux cas, les résultats sont obtenus avec la représentation  $TC - LEST$  et des modèles de mélange. Ce sera également le cas dans la suite de cette partie.

D'un point de vue purement qualitatif, à l'échelle d'une image, le MV n'est pas suffisamment discriminant. En effet sur la figure 32(a), si tous les symptômes identifiés lors de la photo-interprétation (marqués par les cercles rouges) sont détectés, les faux positifs de la classe mildiou sont extrêmement nombreux. Les éléments identifiés sur la base du MV comme du mildiou correspondent beaucoup plus souvent à des tissus sains qu'à des tissus réellement symptomatiques. Les résultats de classification sur la base du MAP et sous l'hypothèse que le mildiou représente 5% de la surface foliaire sont également insatisfaisants. Cette classification produit beaucoup moins de faux positifs, néanmoins leur nombre reste bien trop important par rapport aux classifications pertinentes. De plus, la reconnaissance des symptômes est incomplète sous cette hypothèse. Certaines taches disparaissent complètement de la classification, par exemple celle de l'exemple (v) ou deux des cinq taches de l'exemple (ii). Les symptômes les plus discrets sont très mal retranscrits, seuls quelques pixels des symptômes (iii), (iv) et (vi) sont retrouvés. Finalement, ce sont uniquement les symptômes les plus marqués qui sont correctement restitués, comme l'exemple (i). Ces résultats se vérifient quantitativement : le tableau en Annexe B présente la matrice de confusion et les performances de la classe mildiou correspondant à la figure 32.





(a)



(b)

FIGURE 32: Influence des probabilités a priori pour la classification des symptômes foliaires du mildiou : comparaison MV vs MAP. (a) présente les résultats dans le cas où toutes les classes sont équiprobables (MV). (b) représente un cas où la probabilité *a priori*  $P_{mildiou} = 5\%$  de la surface foliaire. Les symptômes réels sont repérés par des cercles rouges.

Le tableau 5.1, présente pour les 100 images du jeu de données, la répartition des faux positifs dans les classes saines pour les cas des décisions MV et MAP ( $P_{mildiou} = 5\%$ ). Il faut noter que les contributions des classes saines aux erreurs sont très déséquilibrées. Globalement les classes « Grappes » et « Anomalies » sont rarement confondues avec les symptômes du mildiou. Si la couleur brune des nécroses peut se retrouver dans certaines taches de mildiou, la structure des nécroses est assez lisse en comparaison avec les gradients présents dans les taches d’huiles qui traduisent l’estompement et le développement centrifuge du mildiou. Pour le cas des grappes saines, il n’y a pas de décolorations et leur structure granulaire se différencie assez facilement des symptômes dont la structure est plus homogène. Ainsi ce sont surtout les feuilles et les tiges qui se confondent avec les symptômes. Dans le cas du MV, les erreurs se situent principalement sur des portions brillantes des feuilles, dont l’angle d’exposition crée certains gradients de luminance qui rappellent l’estompement des symptômes. Dans le cas du MAP, une probabilité a priori restrictive pour la classe mildiou (5%), permet d’écarter la plupart des erreurs sur les feuilles. Ce sont alors les tiges qui sont le plus souvent confondues avec des symptômes, notamment les parties en périphérie de nécroses dues à des impacts de grêle ou à des plaies de rognage sur les tiges (voir figure 33). Si globalement, le MAP permet de réduire de presque 90% ces erreurs (voir les effectifs totaux des erreurs sur le tableau 5.1), celles-ci sont encore trop nombreuses pour parvenir à une classification pertinente des symptômes du mildiou.

TABLE 5.1: Répartition des faux positifs dans les classes saines pour les 100 images du jeu de données

(classe mildiou réelle = 5486 px)	Répartition des faux positifs par classe en (%)				
	Feuilles	Grappes	Tiges	Anomalies	Effectif total
MV	59	11	26	4	135 293
MAP : $P_{mildiou} < 5\%$	24	10	65	1	17 374

Le tableau 5.2 présente les performances de classification pour le jeu de données complet et avec différentes hypothèses arbitraires concernant les probabilités *a priori* de la classe mildiou. Cette expérience permet d’évaluer la pertinence du MAP en fonction de la fréquence estimée d’apparition des symptômes. Ces hypothèses considèrent des probabilités *a priori* de la classe mildiou variant de 1% à 10% de la surface foliaire totale. Quelle que soit l’hypothèse considérée, les résultats sont insatisfaisants. Lorsque la probabilité est plus restrictive, la précision augmente légèrement et le rappel se dégrade du même ordre de grandeur. Pour toutes les hypothèses, le rappel est correct ( $> 85\%$ ) mais la précision reste médiocre ( $< 25\%$ ).



La variabilité du niveau d'infestation de chaque pied est telle que déterminer une probabilité globale ne semble pas pertinent, d'autant qu'en réalité il faudrait prendre en compte le fait que de nombreux pieds sont parfaitement sains et que d'autres pieds pourraient très bien être atteints par d'autres maladies.

TABLE 5.2: Comparaison des performances de classification selon la probabilité *a priori* du mildiou pour les 100 images du jeu de données.

Probabilité	Précision	Rappel
équiprobable	0.03	0.95
$P = 10\%$	0.19	0.93
$P = 8\%$	0.20	0.92
$P = 5\%$	0.22	0.90
$P = 1\%$	0.25	0.87




FIGURE 33: Exemples d'erreurs de classification sur les feuilles (a) et (b) ainsi que sur les tiges (c) et (d) dans le cas du MV et dans le cas du MAP ( $p_{\text{mildiou}} = 5\%$ ).

Finalement, la difficulté de réglage du MAP et ses résultats médiocres rendent la chaîne de traitement du [chapitre 4](#) peu adaptée à la classification des symptômes du mildiou. En l'absence de connaissance sur la distribution spatiale des symptômes voire sur la fréquence globale d'apparition de la pathologie, il n'est pas raisonnable de proposer une probabilité *a priori* fiable pour estimer le MAP et retranscrire les symptômes. Par ailleurs, le MV n'est pas suffisamment discriminant, ce qui traduit un probable recouvrement entre le modèle du mildiou et les modèles des classes saines. Toutefois la stratégie de classification pixellaire qui s'appuie sur des descripteurs locaux des propriétés conjointes de structure et de couleur et des modèles statistiques de leurs distributions au sein de chaque classe n'est pas nécessairement à rejeter. La partie suivante présente une stratégie qui s'appuie toujours sur ces représentations et ces modèles, mais avec une méthode de décision mieux adaptée au problème du mildiou.

## 5.4 Reconstruction des symptômes du mildiou par hystérésis

Il apparaît que le MV n'est pas un critère suffisant pour affecter un pixel à la classe « Mildiou feuilles ». En pratique, les décisions basées sur cet unique critère ont tendance à classifier incorrectement certains éléments de tissus sains ou aux abords de certaines anomalies (voir [figure 33](#)). A l'échelle de la surface du feuillage, ces erreurs sont minimales. Cependant, compte-tenu de la disproportion entre ces deux classes, ces erreurs représentent un effectif considérable pour la classe « Mildiou feuilles » dont l'occurrence est statistiquement très rare.

Pourtant, l'observateur est capable de reconnaître facilement une tache symptomatique du mildiou, c'est à dire une zone plus ou moins diffuse centrée autour de points plus caractéristiques. Ce sont sans doute principalement des critères de cohérence spatiale autour de ces quelques points remarquables qui lui permettent de détecter la tache. De ce fait, l'ensemble d'apprentissage de la classe mildiou est construit à la fois à partir d'éléments dont les propriétés locales de structure-couleur sont très distinctes mais aussi d'éléments dont les propriétés peuvent s'apparenter à certains cas particulier de tissus sains.



Dans ces conditions, une approche fondée sur la reconstruction d'une zone connexe autour de quelques points très caractéristiques du mildiou, un peu à la manière d'un algorithme de segmentation par croissance autour de germes (Cocquerez et Bolon, 1995), est sans doute plus pertinente qu'une simple classification de pixels. Pour intégrer cette notion de cohérence spatiale, il est proposé de réaliser une reconstruction par hystérésis. Dans un premier temps, il faut déterminer un ensemble de critères très restrictifs, permettant, parmi les pixels « Mildiou » issus d'une classification MV, de ne retenir que les pixels de « germes » *i.e.* des pixels pour lesquels le niveau de confiance attribué à chaque décision est élevé. Dans un second temps, des critères plus permissifs permettent d'ajouter aux germes de nouveaux pixels, à condition de respecter une contrainte de connexité avec les pixels déjà retenus. Dans les deux cas, il est proposé de combiner deux critères, un critère « intra-classe » et un critère « inter-classe ». Ces critères sont relatifs à la distance de Mahalanobis (Mahalanobis, 1936) entre un descripteur et le barycentre du modèle d'une classe. Ces distances traduisent une information très proche de la vraisemblance. Cependant en pratique il est plus simple de déterminer des seuils relatifs aux distances. Ces critères sont décrits dans les parties suivantes.

#### 5.4.1 Critère « intra-classe » : conserver les pixels les plus représentatifs des symptômes de mildiou

Le critère « intra-classe » permet de vérifier la pertinence de l'appartenance d'un pixel à la classe mildiou. Il consiste à comparer la distance de Mahalanobis  $d_{mahal}(\vec{Y}, \mu_{mildiou})$  entre le descripteur  $\vec{Y}$  d'un pixel et le barycentre  $\mu_{mildiou}$  du modèle mildiou. Sous l'hypothèse qu'un pixel décrit par  $\vec{Y}$  appartient à la classe mildiou et sous l'hypothèse de normalité du modèle alors :

$$\vec{Y} \sim \mathcal{N}(\mu_{mildiou}, \Sigma_{mildiou}), \quad (5.1)$$

$\mu_{mildiou}$  et  $\Sigma_{mildiou}$  étant respectivement le barycentre et la matrice de covariance du modèle mildiou et  $d_{mahal}(\vec{Y}, \mu_{mildiou}) = \sqrt{(\vec{Y} - \mu_{mildiou})^t \Sigma_{mildiou}^{-1} (\vec{Y} - \mu_{mildiou})}$ .

Sous ces hypothèses :

$$d_{mahal}^2(\vec{Y}, \mu_{mildiou}) \sim \chi^2(N), \quad (5.2)$$

où  $\chi^2(N)$  est une loi du « Khi deux » à  $N$  degrés de liberté où  $N$  est égal à la dimension des descripteurs considérés.

On détermine alors un seuil de distance  $\delta_\alpha = \sqrt{\chi_\alpha^2}$  tel que  $p(\chi^2 < \chi_\alpha^2) = \alpha$  où  $\chi_\alpha^2$  est un quantile de la loi  $\chi^2(N)$ . Rejeter les instances telles que  $d_{mahal}(\vec{Y}, \mu_{mildiou}) > \delta_\alpha$  revient donc à ne préserver qu'une proportion  $\alpha$  des instances les plus représentatives et les plus proches du barycentre du modèle mildiou :

$$d_{mahal}(\vec{Y}, \mu_{mildiou}) < \delta_\alpha \quad \longmapsto \vec{Y} \in c_{mildiou} \quad (5.3)$$

### 5.4.2 Critère « inter-classes » : éliminer les pixels incertains

Par ailleurs, il est possible que certains tissus sains présentant des anomalies possèdent des propriétés qui se rapprochent des symptômes du mildiou ou simplement que des pixels en périphérie de taches de mildiou ressemblent fortement à des pixels sains. Dans ce cas, l'application du premier critère (intra-classe) ne permet pas toujours d'écarter ces pixels. En revanche, il est possible de vérifier s'il existe une incertitude entre deux classes, *i.e.* si un pixel possède à la fois une distance faible à la classe mildiou ainsi qu'une distance relativement faible à une classe saine. Le critère inter-classes consiste à déterminer les pixels pour lesquels un descripteur  $\vec{Y}$  n'est pas significativement plus proche de la classe mildiou que d'une autre classe saine  $c$ . Pour ce faire, on compare le ratio  $R_{obs}$  entre les carrés des distances de Mahalanobis aux classes mildiou et saine. Compte-tenu de la faible probabilité d'occurrence d'un symptôme, s'il existe une telle incertitude entre l'affectation d'une instance à la classe mildiou et l'affectation à une classe saine, il semble plus pertinent de prendre une décision en faveur de la classe saine. Ainsi, on détermine un seuil minimal  $R_{min}$  tel que si le rapport  $R_{obs}$  entre les carrés des deux distances de Mahalanobis est inférieur à ce seuil, alors on rejette l'instance pour la classe mildiou :

$$R_{obs} = \frac{d_{mahal}^2(\vec{Y}, \mu_c)}{d_{mahal}^2(\vec{Y}, \mu_{mildiou})} < R_{min} \quad \longmapsto \vec{Y} \notin c_{mildiou}, \quad (5.4)$$

On considère seulement des valeurs de seuil  $R_{min} > 1$  de sorte que le critère d'affectation à la classe mildiou soit plus restrictif que la décision par MV.

### Cas des modèles de mélanges.

L'utilisation de la distance de Mahalanobis ne prend tout son sens que dans le cas d'une distribution gaussienne multivariée, définie par un couple unique  $(\mu, \Sigma)$ . Dans le cas d'un modèle de mélange, il est possible de considérer une moyenne pondérée des distances à chacune des composantes du mélange. Cependant, il semble préférable de considérer que les classes étudiées regroupent plusieurs sous-classes, chacune décrite par une composante gaussienne. Cette assertion semble particulièrement pertinente dans le cas des feuilles et des symptômes foliaires qui présentent des différences entre les faces inférieures et supérieures. Ainsi, la distance de Mahalanobis est considérée pour la composante du mélange qui maximise la vraisemblance.

#### 5.4.3 Détermination des germes

La première étape de la reconstruction par hystérésis a pour objectif d'initialiser la détection des symptômes. En pratique cela consiste à définir un couple de seuils  $(\delta_\alpha, R_{min})$  permettant de déterminer des germes fiables et exhaustifs. Un germe est fiable s'il n'est composé que de pixels correspondant réellement à un symptôme de mildiou. Les germes sont exhaustifs s'il existe au moins un germe présent à l'intérieur de chaque symptôme identifié. La fiabilité du germe est donc directement décrite par la précision de l'affectation des pixels à la classe mildiou. En revanche, l'exhaustivité n'est qu'indirectement décrite par le rappel. Toutefois plus le rappel sera élevé, plus les chances que chaque symptôme contienne au moins un germe sont fortes. Il va donc falloir régler les seuils des critères de façon à maximiser la précision tout en maintenant un rappel suffisant pour espérer initialiser la reconstruction de chaque symptôme par au moins un germe.

La figure 34 présente l'évolution du rappel et de la précision de la classification en fonction du seuil de distance considéré pour le critère intra-classe. Les seuils  $\delta_\alpha$  varient tels que  $0.01 \leq \alpha \leq 0.3$  tandis que la valeur du seuil pour le critère inter-classes est ici fixée arbitrairement à  $R_{min} = 2.5$ . Pour un même seuil  $R_{min}$ , plus la valeur du seuil  $\delta_\alpha$  est faible, *i.e.* les pixels conservés sont proches du barycentre  $\mu_{mildiou}$  de la classe mildiou, et plus la précision augmente. Parallèlement, le rappel diminue lorsqu'une proportion plus grande de la population de pixels est rejetée de la classe mildiou. Pour déterminer des germes fiables, il faut donc fixer le seuil  $\delta_\alpha$  pour une valeur faible de  $\alpha$ . Toutefois, si cette valeur est trop faible, il est probable que certaines taches soient manquées. D'où l'importance du critère inter-classes, dont l'apport permet de conserver davantage de germes sans dégrader significativement leur fiabilité.




FIGURE 34: Évolution des performances de classification du mildiou selon le seuil  $\delta_\alpha$

La figure 35 présente un ensemble de courbes « rappel-précision » qui décrivent les performances de classification pour différentes combinaisons de seuils  $(\delta_\alpha, R_{min})$ . Chaque courbe montre l'évolution conjointe du rappel et de la précision pour  $\delta_\alpha$ ,  $\alpha \in [0.01, 0.3]$  et pour une valeur fixe de  $R_{min}$ . Cinq valeurs pour le seuil  $R_{min}$  sont proposées  $R_{min} \in \{1.0, 2.0, 2.5, 3.0, 3.5\}$ . Ces courbes ont été construites à partir d'une série de 9 courbes de rappel et de 9 courbes de précision pour des valeurs  $R_{min} \in [1, 11]$  (voir Annexe C). Les courbes les plus pertinentes ont été choisies pour être représentées figure 35. La courbe rouge en pointillés constitue une référence pour  $R_{min} = 1$  (i.e. pas de correction inter-classes du MV). Sur les courbes de la figure 35, on cherche un couple de seuils qui puissent satisfaire les conditions nécessaires à la formation des germes avec une priorité pour la fiabilité (i.e. pour des valeurs de précisions  $> 80\%$ ). Ainsi, l'une des courbes se distingue pour la valeur  $R_{min} = 2.5$ . Pour ce seuil inter-classes, la précision est maximisée quelle que soit la valeur de  $\alpha$ . De plus, pour une même valeur de précision, le rappel est toujours plus élevé que pour les autres valeurs du seuil  $R$ . En effet, lorsque  $R$  dépasse cette valeur, on obtient pour une même valeur  $\alpha$ , une précision similaire mais avec un rappel qui se dégrade significativement. De même, lorsque  $R$  décroît, pour obtenir une précision égale, il faut des valeurs  $\alpha$  plus restrictives et donc les rappels se dégradent également.





FIGURE 35: Évolution conjointe Rappel-Précision pour les combinaisons de seuils les plus pertinentes

Le choix du seuil pour le critère intra-classe est moins évident. Il s'agit de déterminer la valeur  $\alpha$  tel que le seuil  $\delta_\alpha$  permet de maximiser la précision sous la condition que les germes formés soient les plus exhaustifs possibles, c'est à dire qu'un maximum de symptômes puissent être retrouvés. Plusieurs seuils intra-classe semblent pouvoir répondre à la condition de fiabilité des germes. Les valeurs de  $\alpha$  comprises entre  $[0.01, 0.15]$ , permettent d'obtenir des précisions supérieures à 80% mais pour des rappels très variables compris entre 3% et 48%. Toutefois, le rappel, ne permet pas directement de retranscrire le caractère d'exhaustivité. Il faut donc dans ce cas évaluer les germes à l'aide d'une métrique « objet », à l'échelle des symptômes plutôt qu'à l'échelle pixellaire. Dans ce but, le tableau 5.3 recense à l'échelle des 100 images du jeu de données, le nombre de taches symptomatiques pour lesquelles il existe au moins un pixel de germe en fonction de la valeur  $\alpha$  pour le seuil fixe  $R_{min} = 2.5$ . On détermine ainsi le meilleur compromis pour le couple de seuils ( $R_{min} = 2.5, \alpha = 0.1$ ) qui permet d'obtenir des germes fiables (précision = 88%) et quasiment exhaustifs (rappel-objet par symptôme = 98%).

TABLE 5.3: Exhaustivité des germes en fonction de la valeur  $\alpha$  : pourcentage de symptômes contenant au moins un pixel de germe

$\alpha$	0.01	0.02	0.05	0.1	0.15	0.20
% symptômes avec germe	49	66	83	98.1	98.5	99.3

La figure 36 présente un résultat de détection de germes avec le couple de seuils ( $R_{min} = 2.5, \alpha = 0.1$ ) à partir des résultats du MV (cf figure 32a.) Les pixels éliminés par le critère intra-classe sont représentés en rouge, ceux éliminés par le critère inter-classes sont représentés en orange. Les pixels conservés pour constituer les germes sont représentés en jaune. Les cercles bleus repèrent les germes correspondant aux taches de mildiou annotées. Pour cet exemple, l'application du critère intra-classe correspond à conserver uniquement les 10% des individus (pixels) les plus centraux du modèle mildiou. Ce seuil permet d'éliminer la quasi-totalité des faux positifs, particulièrement sur les feuilles (voir effectifs « Germes mildiou » comparés à « MV mildiou »). Cependant, une grande partie de la surface des symptômes réels est éliminée et les erreurs présentes en périphérie de nécroses sur les tiges ne sont pas corrigées. Toutefois, si on compare ces résultats avec ceux obtenues par le MAP (cf. figure 32b), la précision obtenue est bien plus élevée. Le critère inter-classes pour le seuil  $R_{min} = 2.5$ , permet d'éliminer les résidus d'erreurs encore présents après l'application du critère intra-classe. Ce second critère est particulièrement pertinent pour éliminer les erreurs sur les tiges. Il possède aussi comme effet secondaire de diminuer encore un peu plus la surface des symptômes réels retrouvés, ce qui à ce stade n'est pas critique, le plus important étant que les germes ainsi obtenus soient fiables (pas ou peu de faux positifs) et exhaustifs (il y a bien au moins un germe dans chaque tache de mildiou).



■ Germes mildiou   ■ Rejet critère intra-classe   ■ Rejet critère inter-classes

FIGURE 36: Résultats de détection des germes pour le couple de seuils ( $R_{min} = 2.5, \alpha = 0.1$ ) à partir du MV. Les cercles bleus indiquent les germes correspondant aux symptômes de mildiou annotés.



TABLE 5.4: Correction des erreurs et performances obtenues en combinant les critères intra-classe ( $\alpha = 0.1$ ) et inter-classes ( $R_{min} = 2.5$ ) pour les 100 images du jeu de données

		Décision			
		MV mildiou	% Rejet intra-classe	% Rejet inter-classes	Germes mildiou
Classe réelle	Mildiou	547 380	33%	19%	268 216 (48%)
	Feuilles	10 152 353	89.2%	10.75%	5471 (0.05)%
	Grappes	1 116 203	71.28%	28.76%	648 (0.06)%
	Tiges	6 981 169	87.1%	12.3%	27 362 (0.4%)
	anomalies	9 662	69%	28%	321 (3%)

Performances mildiou		Contribution des classes aux faux positifs %			
Précision	0.88	Feuilles	Grappes	Tiges	Anomalies
Rappel	0.39	17%	1%	80%	2%

Ces propriétés se généralisent à l'ensemble des 100 images du jeu de données. Le tableau 5.4 présente les corrections apportées à la classification par MV après l'application des deux critères pour chacune des classes. Il présente aussi les performances de classification et la contribution de chaque classe aux faux positifs résiduels (*i.e.* non corrigés par l'application des critères). Au départ, les faux positifs issus du MV pour la classe mildiou sont beaucoup plus nombreux que les vrais positifs (*cf.* colonne « MV mildiou »). Cependant, après l'application des critères avec un couple de seuils très restrictifs ( $R_{min} = 2.5, \alpha = 0.1$ ), plus de 99% des faux positifs sont éliminés (*cf.* colonne « Germes mildiou », le pourcentage correspond à la fraction des erreurs du MV qui subsistent après l'application des critères). Finalement les faux positifs sont principalement dus à des erreurs présentes sur les tiges (80% des erreurs totales). Malgré ces difficultés, cette combinaison de critères pour les seuils ( $R_{min} = 2.5, \alpha = 0.1$ ) permet d'obtenir des germes fiables avec une précision de 88% qui sont présents dans plus de 98% des taches symptomatiques (*i.e.* exhaustifs).

A ce stade, si la détection des germes ne permet pas de détecter fidèlement les symptômes, elle permet néanmoins de dénombrer de manière fiable les symptômes présents sur un pied et donc d'estimer si un pied est sain ou malade. En revanche, la reconstruction des symptômes par croissance autour des germes permettra d'estimer la surface des zones symptomatiques et donc de décrire le stade de développement de la pathologie et le potentiel de contamination des pieds atteints. Ce paramètre est nécessaire pour estimer convenablement le risque sanitaire.



#### 5.4.4 Croissance des germes

Le calcul des germes constitue la phase d'initialisation du processus de détection des symptômes. La croissance autour des germes qui s'ensuit est un processus qui permet d'agréger de nouveaux pixels en périphérie des germes pour reconstruire les symptômes complets. L'objectif est de compléter chaque germe pour construire une composante connexe qui approche au mieux la surface réelle occupée par un symptôme en incluant le moins possible de pixels extérieurs au symptôme. Ce processus est itératif. Initialement la composante connexe représentant le symptôme est constituée par un germe. A chaque itération, les pixels au voisinage de la composante connexe et qui satisfont les critères de ressemblance au mildiou sont ajoutés à celle-ci. Pour la propagation des détections, les voisinages considérés autour des germes sont de connexité 8. Le processus s'arrête quand il n'y a plus de pixels voisins de la composante connexe qui soient suffisamment ressemblants au mildiou.

Dans notre cas, il est choisi de conserver pour la croissance des germes les mêmes critères intra-classe et inter-classes que pour leur initialisation, mais avec des seuils relaxés. Il s'agit de relaxer les seuils des critères suffisamment pour reconstruire les symptômes complètement sans trop dégrader la précision initiale obtenue pour les germes. Le degré de relaxation des seuils est déterminé expérimentalement à partir des performances de la reconstruction. La figure 37 présente un ensemble de courbes rappel-précision qui décrivent les performances obtenues selon les couples des seuils relaxés  $(R_{min}, \alpha)$  à partir des germes déterminés pour  $(R_{min} = 2.5, \alpha = 0.1)$ . Les courbes de rappel ainsi que les courbes de précision permettant de construire la figure 37 sont présentées à l'Annexe D. Le critère intra-classe est considéré pour des seuils relaxés correspondant à des valeurs de  $\alpha$  comprises dans  $[0.1, 0.3]$ , *i.e.* on considère une proportion plus importante des individus du modèle mildiou et on conserve des pixels dont la distance  $\delta_\alpha$  au barycentre peut être plus importante. Le critère inter-classes est considéré pour des seuils relaxés  $R_{min}$  compris entre 1.0 et 2.5.




FIGURE 37: Performances de la reconstruction des symptômes par hystérésis pour différents couples de seuils  $(R_{min}, \alpha)$  relaxés.

Sur la figure 37, on peut voir que la reconstruction la plus complète est obtenue pour la valeur  $R_{min} = 1$ . Dans ce cas, le critère inter-classes ne diffère pas de celui du MV (à ceci près qu'on ne conserve ici que les détections MV connexes aux germes) : cela revient à n'appliquer que le critère intra-classe. Pour des valeurs supérieures de  $R_{min}$  (donc plus restrictives), les précisions obtenues sont à peine supérieures mais pour des rappels qui se dégradent significativement. Concernant la relaxation du seuil pour le critère intra-classe, les valeurs de  $\alpha$  supérieures à 0.2 sont trop permissives. Un bon compromis peut être déterminé pour le seuil  $\alpha = 0.2$  qui permet d'obtenir une précision de 83% et un rappel de 76%.

La figure 38 présente un résultat représentatif de reconstruction des symptômes à partir des seuils ( $R_{min} = 1, \alpha = 0.2$ ) et des germes déterminés pour ( $R_{min} = 2.5, \alpha = 0.1$ ). Les 13 taches de mildiou présentes sur l'image sont détectées (encadrées en bleu). Trois erreurs (encadrées en rouge) sont également présentes sur des tiges autour de certaines nécroses. En termes de surface détectée et pour l'estimation du risque sanitaire, ces erreurs sont très faibles. Cependant, s'il s'agit de détecter les premiers symptômes précoces dans une parcelle, ces erreurs pourraient avoir une conséquence plus importante sur l'interprétation agronomique des résultats de l'analyse d'images.



FIGURE 38: Résultat de reconstruction des symptômes par hystérésis pour les seuils : (germes)  $[R = 2.5, \alpha = 0.1] \mapsto [R = 1, \alpha = 0.2]$  (croissance). Les cercles bleus indiquent les germes correspondant aux symptômes de mildiou annotés. Les cadres rouges indiquent les faux positifs.

La figure 39, présente plus en détail la reconstruction des symptômes. Les symptômes les plus gros ou les plus sévères sont généralement mieux reconstruits que les symptômes les plus petits ou les plus discrets et estompés. De plus, si la surface des symptômes est plutôt bien reconstruite, la morphologie des taches n'est pas fidèlement retranscrite. Pour le cas du mildiou, ce n'est pas un critère important, car cette morphologie n'est guère caractéristique. Le regroupement des taches par coalescence et le développement de chaque tache selon certains phénomènes locaux d'ombrage ou d'évacuation de l'humidité peut donner lieu à une grande variété de géométries des symptômes, même dans des cas précoces. Par ailleurs, le processus de reconstruction par hystérésis peut aboutir à ce qu'une tache de mildiou soit détectée comme un ensemble de taches non connexes. En effet, pour la plupart des taches, plusieurs germes sont détectés. Dans certains cas, la croissance de ces germes aboutit à leur coalescence. Ainsi, une tache est détectée comme un objet unique et continu [cf. figure 39 (1) et (2)]. Dans d'autres cas, la croissance des germes ne permet pas de lier les multiples germes d'une même tache, mais seulement de mieux retranscrire la surface atteinte par la pathologie [cf. figure 39 (3) et (4)]. Ce phénomène de multiples détections partielles peut toutefois constituer une difficulté pour l'interprétation épidémiologique des résultats qui prend en compte le dénombrement des taches élémentaires de mildiou.

Pour les 100 images évaluées, la reconstruction des symptômes est plutôt pertinente. Le tableau 5.5 présente la variabilité des performances de reconstruction au sein du jeu d'images. A l'échelle d'une estimation globale, les performances sont satisfaisantes. En effet, avec des seuils adéquats pour l'hystérésis, la reconstruction des symptômes s'effectue avec une précision de 83% et un rappel de 76%. Les variances de ces métriques de performances sont assez faibles à cette échelle. Cependant à l'échelle d'un pied, pour certaines images, la reconstruction peut manquer de fiabilité ou s'avérer incomplète avec des précisions dans certains cas inférieures à 70% et des rappels pouvant être inférieurs à 50%. Cependant ces contre performances extrêmes ne se produisent pas en même temps. En effet, le score  $F_1$  qui synthétise les deux métriques ( $F_1 = 2 \cdot \frac{precision \cdot rappel}{precision + rappel}$ ) est également peu variable et atteint son minimum à 75%.






FIGURE 39: Détails du résultat de reconstruction des symptômes par hystérésis : (germes)  $[R = 2.0, \alpha = 0.1] \mapsto [R = 1, \alpha = 0.2]$  (croissance), les germes sont représentés en jaune, les compléments issus de la croissance sont représentés en rose. Ces quatre exemples correspondent aux numéros indiqués sur la figure 38.

TABLE 5.5: Variabilité des performances de reconstruction des symptômes dans le jeu d'images : (germes)  $[R = 2.0, \alpha = 0.1] \mapsto [R = 1, \alpha = 0.2]$  (croissance)

	Min	Max	Moyenne	$\sigma^2$
Précision	0.68	0.91	0.83	0.08
Rappel	0.48	0.98	0.76	0.16
$F_1$ -score	0.75	0.89	0.79	0.10

#### 5.4.5 Influence des représentations structure-couleur et des échelles d'analyses sur la reconstruction.

Différentes représentations structure-couleur ont été proposées dans le chapitre 3. La méthode de reconstruction des symptômes par hystérésis n'a été analysée que dans le cas de la représentation  $TC - LEST$ , jugée la plus pertinente. Les performances de reconstruction obtenues avec les autres représentations à partir des seuils déterminés pour la représentation  $TC - LEST$  sont comparées à l'Annexe E en conservant les mêmes réglages que pour la méthode TC-LEST. Idéalement, il conviendrait de déterminer les couples de seuils optimaux pour chacune des représentations puis de comparer les performances de reconstruction obtenues avec chaque représentation.

Quant aux propriétés multi-échelles des structures des tissus étudiés, elles ont été évoqués et partiellement décrites dans la [partie 4.5.2](#). Précédemment, les représentations proposées ont été considérées pour décrire la structure à une seule échelle. On propose aussi pour la représentation *TC – LEST* de décrire la structure à plusieurs échelles. Pour cette représentation, la description multi-échelle consiste simplement à concaténer les formes vectorielles de plusieurs tenseurs de structure. Ainsi, pour chaque échelle  $S_k$ , on représente le tenseur par les logarithmes de ses deux valeurs propres :  $[\log(\lambda_{1S_k}), \log(\lambda_{2S_k})]$ . Une comparaison des résultats pour différents couples est présentée à l'[Annexe F](#).

Enfin, l'[Annexe G](#) propose de comparer les performances de reconstruction obtenues pour différentes échelles d'analyse de la couleur, pour une échelle d'analyse de la structure fixe .

## 5.5 Conclusion du chapitre

La détection des symptômes du mildiou présente de multiples difficultés. Elle nécessite de retrouver un phénomène rare disséminé dans un arrangement complexe de textures. De plus, ces symptômes sont difficiles à modéliser, du fait de la variabilité de tailles et de faciès des symptômes, mais également à cause de nombreuses ressemblances entre certains pixels des symptômes et les tissus sains. De ce fait, la stratégie de classification pixellaire basée sur le MAP se montre insuffisante pour ce type de tissus particuliers. Ainsi, une approche prenant en compte le voisinage des pixels dans la prise de décision a été proposée. Cela permet d'intégrer des critères de cohérence spatiale de plus haut-niveau pour mieux reconnaître les symptômes. Aussi, en associant cohérence spatiale, représentations structure-couleur et modèles paramétriques, il devient possible de détecter et de mesurer la surface des symptômes assez fidèlement, voire de les dénombrer. La segmentation de « croissance de germes » par hystérésis, s'est montrée capable de détecter dans un premier temps les pixels les plus remarquables des symptômes avec une grande fiabilité puis de reconstruire par propagation presque complètement l'ensemble des symptômes. L'information produite par la reconstruction des symptômes est encore incomplète et probablement moins fiable que les estimations réalisées par les experts en phytopathologie. Cependant, à l'échelle d'une centaine de pieds, c'est à dire quelques rangs dans une parcelle, il est déjà possible d'obtenir des résultats fiables et pertinents pour estimer l'état sanitaire à l'échelle intra-parcellaire.



---

## Conclusion et Perspectives

---

L'objectif de ces travaux est d'évaluer le potentiel de l'imagerie couleur embarquée haute-résolution pour le suivi épidémiologique des principales pathologies fongiques de la vigne avec le mildiou (*Plasmopara viticola*) comme cas d'étude. Il s'agit de déterminer s'il est possible, dans ce contexte, d'extraire des images les informations permettant de détecter, discriminer et quantifier automatiquement les symptômes du mildiou.

Pour répondre à ce problème, une stratégie de classification pixellaire a été proposée et évaluée, reposant sur la modélisation de variables décrivant conjointement la structure locale et la couleur dans le voisinage d'un pixel. Ces descripteurs ont été construits en combinant le tenseur local de structure (LST), un outil bien connu de l'analyse de texture, avec des statistiques colorimétriques locales. Dans un premier temps nous avons montré à travers le [chapitre 3](#) la pertinence du tenseur de structure pour décrire et discriminer partiellement les tissus symptomatiques du mildiou et les différentes classes de tissus sains. Puis, nous avons proposé différentes méthodes de combinaison du tenseur de structure et de l'information colorimétrique, en considérant différents espaces de couleurs. Il a été montré que grâce à une transformation logarithmique, il devenait possible (i) : d'exprimer pour chacune des combinaisons, la représentation structure-couleur vectorielle équivalente dans l'espace log-Euclidien, (ii) de modéliser dans cet espace la distribution statistique des représentations structure-couleur de chacune des classes de tissus étudiées par des lois gaussiennes multivariées ainsi que par des lois de mélanges gaussiens. Seuls les symptômes du mildiou sur les grappes n'ont pas pu être correctement modélisés par les distributions proposées. Généralement les modèles de mélange décrivent mieux les distributions des représentations structure-couleur dans les classes considérées. Il faut noter que pour certains pixels, il est parfois difficile de calculer les descripteurs structure-couleur dans les représentations *LEEST* et *LEGEST*. Ainsi, ces deux méthodes de représentation ne permettent pas de décrire rigoureusement et en totalité les classes étudiées.



Ces premières contributions, d'ordre méthodologique, permettent d'extraire, de représenter et de modéliser certaines propriétés caractéristiques des classes de tissus étudiées. En pratique, les représentations structure-couleur développées et les modèles correspondants ont été appliqués et validés au sein de deux chaînes de traitement. La première, développée dans le [chapitre 4](#), permet de décomposer une image en classes d'organes. Elle consiste à classer chaque pixel de l'image par l'estimation du MAP, puis à appliquer une relaxation probabiliste au moyen d'un algorithme ICM pour homogénéiser spatialement les décisions locales. Les résultats obtenus sont très satisfaisants pour les trois stades phénologiques considérés. Cette chaîne de traitement permet également de comparer deux stratégies de combinaison de la structure et de la couleur. Une première stratégie consiste à « décrire des relations conjointes entre texture et colorimétrie » avec la représentation *LEEST*. La seconde stratégie consiste à « analyser indépendamment la structure et la couleur » avec la représentation *CELEST*. Finalement, la seconde stratégie aboutit à des représentations plus compactes et plus performantes en classification.

La seconde chaîne de traitement, développée dans le [chapitre 5](#), est dédiée à la détection et à la quantification des symptômes foliaires du mildiou. Elle repose sur le même principe de vraisemblance entre une représentation structure-couleur et un modèle probabiliste mais avec un processus de décision plus élaboré. En effet l'estimation du MAP se révèle plus délicate à mettre en œuvre dans le cas de la classe mildiou et l'estimateur produit est peu performant. La solution proposée est de réaliser une reconstruction des symptômes par hystérésis. Ainsi, deux critères basés sur la distance de Mahalanobis ont été proposés, un critère intra-classe et un critère inter-classes. Dans un premier temps, en appliquant ces critères avec des seuils très restrictifs, il a été possible de détecter des germes très fiables au sein de chaque symptôme. Puis, en relaxant ces critères et en agrégeant de nouveaux pixels sous condition de connexité aux germes, on parvient à reconstruire une grande partie de la surface symptomatique totale, tout en limitant l'apparition de faux positifs.

---

Les outils et la stratégie développés montrent un fort potentiel pour extraire, à partir des images, les informations essentielles à l'estimation d'un risque sanitaire. Cependant, il semble encore difficile d'exploiter ces résultats pour produire une estimation directement utilisable sur le terrain. Aussi, plusieurs pistes sont proposées dans la suite pour : (i) renforcer la fiabilité des résultats obtenus, (ii) produire des résultats interprétables agronomiquement et (iii) valider les résultats dans un contexte agronomique étendu.

**(i) renforcer la fiabilité des résultats obtenus :** La chaîne de traitement dédiée à la reconnaissance des symptômes ([chapitre 5](#)) requiert le réglage de plusieurs paramètres. Le comportement des paramètres relatifs à l'échelle d'analyse de la structure et de la couleur, aux propriétés multi-échelles des textures ainsi qu'aux seuils optimaux des critères de la reconstruction ont été étudiés. Cette étude a toutefois été réalisée seulement pour la représentation  $TC - LEST$ . Afin de comparer les performances des différentes représentations structure-couleur, il faudrait réaliser une étude similaire pour chaque représentation dans les différents espaces couleurs compatibles.

De plus, la composante couleur de chaque représentation se limite pour l'instant à une moyenne locale de la colorimétrie pondérée de manière gaussienne. Pour améliorer le pouvoir discriminant de la méthode, on peut envisager de décrire la colorimétrie par des statistiques plus élaborées en considérant des expressions plus formalistes de la couleur. Par exemple différents descripteurs colorimétriques compactes ont été formulés à partir de représentations ou de décompositions tensorielles de la couleur (Rittner *et al.*, 2010 ; Cirillio *et al.*, 2019). Il est aussi possible d'envisager de décrire la texture directement dans l'espace colorimétrique plutôt que de le faire uniquement sur la luminance. Des tenseurs de structure couleur peuvent également être formulés grâce à la définition des opérations différentielles spécifiques aux images couleurs. Ainsi, il existe des tenseurs de structure couleur définis à partir des canaux de couleur (Weijer et Gevers, 2004), de représentations quaternioniques (Angulo, 2009) ou elliptiques (Rittner *et al.*, 2010) de la couleur.

Des améliorations peuvent aussi être envisagées pour l'étape de décision, notamment en ce qui concerne la définition du critère inter-classes. Ce critère a été défini comme le ratio de deux distances de Mahalanobis au carré. Les seuils évalués pour ce ratio ont été déterminés empiriquement à partir de valeur arbitraires. On peut envisager d'écrire ce critère comme un rapport de log-vraisemblance puis l'utiliser pour réaliser un test statistique, à la manière d'un test de Neyman-Pearson (Neyman et Pearson, 1933), en s'appuyant sur des estimations empiriques des lois suivies par les populations étudiées.

**(ii) produire des résultats interprétables agronomiquement :** Les résultats de la reconstruction s'expriment à l'échelle du pixel. Il faudrait être en mesure de réaliser une synthèse à l'échelle du pied afin de produire des informations comparables aux indicateurs de fréquence et d'intensité utilisés en épidémiologie. Pour réaliser cette synthèse, l'expression de métriques « objet » pourrait se révéler pertinente.

Pour l'estimation de l'intensité, le nombre d'objets connexes de la classe mildiou, leur proximité, leur distribution spatiale ou la variabilité des tailles des taches unitaires sont des critères à examiner. De plus, on a considéré jusqu'ici une unique classe de symptômes foliaires, alors que l'intensité dépend aussi de la sévérité des faciès rencontrés. On peut ainsi envisager de scinder les symptômes du mildiou en plusieurs sous-classes de faciès, précoces, sévères ou tardifs.

La fréquence correspond à la proportion de pieds atteints. A l'aide de métriques probabilistes, produites par des décisions issues de tests statistiques, il serait possible d'associer à chaque tache un niveau de confiance. En synthétisant ces probabilités à l'échelle de l'image, on pourrait estimer la probabilité qu'un pied soit malade et donc estimer la fréquence.

Plus généralement, la question des échelles d'observation et d'interprétation des résultats reste ouverte. Les analyses géostatistiques utilisées en épidémiologie consistent à comparer les phénomènes observés à l'échelle d'un pied, d'une piquetée et d'un rang ou d'une parcelle. Ces phénomènes sont également interprétés entre deux dates, ou deux événements météorologiques. On pourrait alors analyser des séries temporelles d'images, soit pour estimer une probabilité a priori pour les séries suivantes, soit pour estimer un risque en fonction d'une augmentation des indicateurs d'intensités entre deux dates. D'un point de vue opérationnelle, il semble délicat de prendre des décisions sur la base d'une dynamique spatiale et temporelle. Cependant, d'un point de vue expérimental, la considération de ces dimensions supplémentaires semble pertinente pour valider des modèles de prédiction ou des stratégies de lutte.

**(iii) valider les résultats dans un contexte agronomique étendu :** Pour attester de la robustesse de la méthode dans des conditions d'exploitation réalistes, il semble nécessaire, de répliquer l'étude pour d'autres modalités de culture, d'autres cépages, voire d'autres maladies fongiques aux propriétés similaires (*e.g.* Oïdium et Blackrot) et sur une plus grande échelle spatiale.

---

Ces trois ensembles de perspectives sont des pré-requis afin d'aboutir à un service viable de détection et de cartographie automatique des maladies fongiques de la vigne, susceptible d'être proposé à la profession viticole.



# Annexes







## Annexe A :

### Adéquation des représentations structure-couleur aux modèles gaussiens et modèles de mélange pour la classe « mil-diou foliaire »


Dans le cas de la représentation *CELEST*, ce sont les adéquations des distributions des différentes composantes colorimétriques qui sont observées. Dans la représentation *LEEST*, c'est l'adéquation de la distribution des log-déterminants de la forme matricielle qui est observée.




(a) Adéquation gaussienne pour «  $g'$  » de  $CELEST_{RGB}$



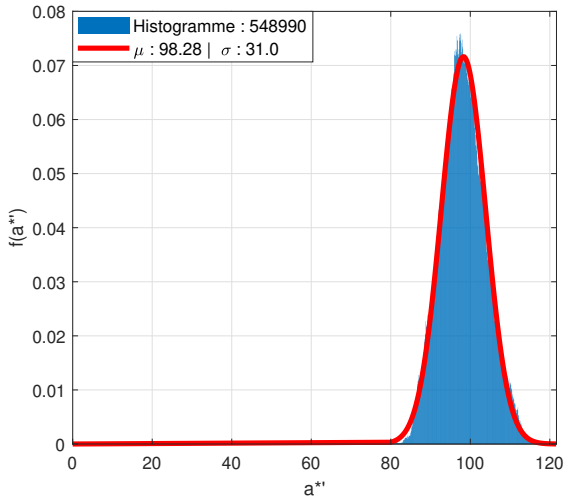
(b) Adéquation au mélange pour «  $g'$  » de  $CELEST_{RGB}$




(c) Adéquation gaussienne pour «  $b'$  » de  $CELEST_{RGB}$




(d) Adéquation au mélange des «  $b'$  » de  $CELEST_{RGB}$




(a) Adéquation gaussienne pour «  $a^*$  » de  $CELEST_{Lab}$




(b) Adéquation au mélange pour «  $a^*$  » de  $CELEST_{Lab}$




(c) Adéquation gaussienne pour «  $b^*$  » de  $CELEST_{Lab}$



(d) Adéquation au mélange pour «  $b^*$  » de  $CELEST_{Lab}$



(e) Adéquation gaussienne des tenseurs  $LEEST_{Lab}$



(f) Adéquation au mélange des tenseurs  $LEEST_{Lab}$

## Annexe B :

### Exemple de performances de classification du mildiou.

Les classifications sont réalisées au sens du MV (Maximum de Vraisemblance) et du MAP (Maximum A Posteriori) pour l'exemple d'une image représentative de la variabilité des symptômes au sein du jeu données (partie 5.3).


Matrice de confusion et performances de classification du mildiou pour l'exemple fig.32.

(a) MV

		Classe prédite			
		Mildiou	Sain	Total	Rappel
Classe réelle	Mildiou	5193	293	5486	0.95
	Sain	135	293 3467 031	3 597 324	0.92
Total		140 486	3 467 324		
Précision		0.036	0.999		

(b) MAP :  $P_{mildiou} = 5\%$

		Classe prédite			
		Mildiou	Sain	Total	Rappel
Classe réelle	Mildiou	4927	559	5486	0.90
	Sain	17	374 3 579 950	3 597 324	0.99
Total		22 301	3 580 509		
Précision		0.22	0.999		



(a)



(b)


FIGURE 42: Influence des probabilités a priori pour la classification des symptômes foliaires du mildiou : comparaison MV / MAP. (a) présente les résultats dans le cas où toutes les classes sont équiprobables (MV). (b) représente un cas où la probabilité *a priori*  $P_{mildiou} = 5\%$  de la surface foliaire. Les symptômes réels sont repérés par des cercles rouges.

## Annexe C :


### Performances de classification du mildiou selon les seuils $\delta$ et $R_{min}$

Les performances de classification sont calculées au cours de la phase de détection des germes (paragraphe 5.4.3) pour différentes combinaisons de seuils ( $\delta, R_{min}$ ). Ces performances décrivent l'ensemble du jeu de données.

(a) Précision



(b) Rappel




Évolution des performances de classification des germes du mildiou selon les seuils conjoints  $\delta_\alpha$  et  $R$  : Précision (a), Rappel (b)

## Annexe D :


### Performances de reconstruction des symptômes du mildiou selon les seuils $\delta$ et $R_{min}$

Les performances de reconstruction sont calculées au cours de la phase de croissance autour des germes par hystérésis (paragraphe 5.4.4) pour différentes combinaisons de seuils  $(\delta, R_{min})$ . Ces performances décrivent l'ensemble du jeu de données.

(a) Précision



(b) Rappel



Évolution des performances de reconstruction des symptômes du mildiou selon les seuils relaxés  $\delta_\alpha$  et  $R$  : Précision (a), Rappel (b)



## Annexe E :

### Impact des représentations des descripteurs structure-couleur sur les performances de reconstruction des symptômes du mildiou

Le tableau 6 compare les performances de reconstruction obtenues avec les représentations  $LEGEST_{RGB}$ ,  $LEGEST_{Lab}$ ,  $LEEST_{RGB}$ ,  $LEEST_{Lab}$ ,  $CELEST_{RGB}$ ,  $CELEST_{Lab}$  et  $TC - LEST$  à partir des seuils déterminés pour la représentation  $TC - LEST$ . Ces performances décrivent l'ensemble du jeu de données.

TABLE 6: Comparaison des différentes représentations des descripteurs structure-couleur : (germes)  $[R = 2.0, \alpha = 0.1] \mapsto [R = 1, \alpha(0.2)]$  (croissance)

Représentation	$LEGEST_{RGB}$	$LEGEST_{Lab}$	$LEEST_{RGB}$	$LEEST_{Lab}$	$CELEST_{RGB}$	$CELEST_{Lab}$	$TC - LEST$
Précision	0.59	0.62	0.63	0.66	0.75	0.79	0.83
Rappel	0.27	0.29	0.36	0.39	0.48	0.56	0.76

## Annexe F :

### Impact des échelles du gradient et du tenseur sur les performances de reconstruction des symptômes du mildiou

Le tableau 7 compare, pour l'ensemble du jeu de données, les performances de classification après reconstruction par hystérésis pour différentes combinaison d'échelles dans la représentation  $TC - LEST$  (paragraphe 5.4.5). On considère les trois échelles suivantes :

$S_0 : (\sigma_g = 3.5, \sigma_t = 5.5)$ , l'échelle optimale de référence

$S_1 : (\sigma_g = 1.5, \sigma_t = 3.5)$

$S_2 : (\sigma_g = 5.5, \sigma_t = 8.5)$

TABLE 7: Analyse multi-échelle comparaison performances de classification pour la représentation  $TC - LEST$  multi-échelle après reconstruction par hystérésis

	Ref	combinaison d'échelles			
	$S_0$	$(S_0, S_1)$	$(S_0, S_2)$	$(S_1, S_2)$	$(S_0, S_1, S_2)$
Précision	0.83	0.81	0.79	0.67	0.74
Rappel	0.76	0.76	0.73	0.67	0.69



## Annexe G :

### Impact de l'échelle de l'information colorimétrique sur les performances de reconstruction des symptômes du mildiou

Le tableau 8 compare, pour l'ensemble du jeu de données, les performances de classification après reconstruction par hystérésis pour différentes échelles dans la représentation  $TC - LEST$  (paragraphe 5.4.5). On considère ici les échelles de 1 à 7 pour  $\sigma_{couleur}$ .

TABLE 8: Analyse de l'impact de l'échelle de l'information colorimétrique :  $\sigma_{couleur}$  pour  $TC - LEST$

$\sigma_{couleur}$	1.0	1.5	2.0	2.5	3.0	3.5	4.0	4.5	5.0	5.5	6.0	6.5	7.0
Précision	0.63	0.65	0.67	0.69	0.71	0.75	0.78	0.81	0.81	0.83	0.80	0.79	0.76
Rappel	0.66	0.66	0.67	0.67	0.68	0.70	0.71	0.73	0.75	0.76	0.74	0.74	0.35

---

## Bibliographie

---

- Abdel-Hakim, A. E. and Farag, A. A. (2006). CSIFT : A SIFT Descriptor with Color Invariant Characteristics. In *2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR06)*, volume 2, pages 1978–1983. (Cited on page 66.)
- Abdelghafour, F., Keresztes, B., Germain, C., and Da Costa, J. P. (2017). Potential of on-board colour imaging for in-field detection and counting of grape bunches at early fruiting stages. *Advances in Animal Biosciences*, 8(2) :505–509. (Cited on page 25.)
- Abdelghafour, F., Rançon, F., Keresztes, B., Germain, C., and Da Costa, J.-P. (2019a). On-board colour imaging for the detection of downy mildew. In *proceedings of the 12th ECPA conference*, pages 195–202. Wageningen Academic Publishers. (Cited on pages 25, 26, and 82.)
- Abdelghafour, F., Rosu, R., Keresztes, B., Germain, C., and Costa, J. P. D. (2019b). A Bayesian framework for joint structure and colour based pixel-wise classification of grapevine proximal images. *Computers and Electronics in Agriculture*, 158 :345 – 357. (Cited on page 82.)
- Agreste (2016). Pratiques culturales en viticulture 2013. Technical report. (Cited on pages 7 and 32.)
- Aitouda, H. (2012). *Estimation des variables biophysiques des cultures et étude de l’effet du changement d’échelle sur leur variabilité spatiale*. Mémoire, Université du Québec à Chicoutimi. (Cited on page 22.)
- Akl, A. (2016). *Analyse / synthèse de champs de tenseurs de structure : application à la synthèse d’images et de volumes texturés*. Thèse, Université de Bordeaux. (Cited on page 48.)
- Al Saddik, H., Laybros, A., Billiot, B., and Cointault, F. (2018). Using Image Texture and Spectral Reflectance Analysis to Detect Yellowness and Esca in Grapevines at Leaf-Level. *Remote Sensing*, 10 :618. (Cited on page 24.)

- Al Saddik, H., Laybros, A., Simon, J.-C., and Cointault, F. (2019). Protocol for the Definition of a Multi-Spectral Sensor for Specific Foliar Disease Detection : Case of “Flavescence Dorée” : Methods and Protocols. In *Methods in Molecular Biology*, pages 213–238. (Cited on pages [16](#), [19](#), [20](#), [21](#), [22](#), and [23](#).)
- Albetis de la Cruz, J. L. (2018). *Potentiel des images multispectrales acquises par drone dans la détection des zones infectées par la flavescence dorée de la vigne*. Thèse, Université de Toulouse, Université Toulouse III - Paul Sabatier. (Cited on pages [16](#), [19](#), [21](#), [22](#), and [23](#).)
- Allen, W. A., Gausman, H. W., Richardson, A. J., and Thomas, J. R. (1969). Interaction of Isotropic Light with a Compact Plant Leaf. *J. Opt. Soc. Am.*, 59(10) :1376–1379. (Cited on page [18](#).)
- Angulo, J. (2009). Structure Tensor of Colour Quaternion Image Representations for Invariant Feature Extraction. In Trémeau, A., Schettini, R., and Tominaga, S., editors, *Computational Color Imaging*, volume 5646, pages 91–100. Springer Berlin Heidelberg, Berlin, Heidelberg. (Cited on page [133](#).)
- Arseneau, S. and Cooperstock, J. R. (2006). An improved representation of junctions through asymmetric tensor diffusion. In *Proceedings of the Second International Conference on Advances in Visual Computing - Volume Part I*, ISVC’06, pages 363–372, Berlin, Heidelberg. Springer-Verlag. (Cited on page [44](#).)
- Arsigny, V., Fillard, P., Pennec, X., and Ayache, N. (2006). Log-Euclidean metrics for fast and simple calculus on diffusion tensors. *Magnetic Resonance in Medicine*, 56(2) :411–421. (Cited on pages [46](#) and [47](#).)
- Ash, G. (2000). Downy mildew of grape. *The Plant Health Instructor*. (Cited on page [12](#).)
- Baggiolini, M. (1952). Les stades repères dans le développement annuel de la vigne et leur utilisation pratique. 8 :4–6. (Cited on page [6](#).)
- Bakhshipour, A., Jafari, A., Nassiri, S. M., and Zare, D. (2017). Weed segmentation using texture features extracted from wavelet sub-images. *Biosystems Engineering*, 157 :1–12. (Cited on page [25](#).)
- Bellman, R. E. (2003). *Dynamic Programming*. Dover Publications, Inc., New York, NY, USA. (Cited on page [21](#).)
- Bertamini, M., Grando, M., and Nedunchezian, N. (2003). Effects of Phytoplasma Infection on Pigments, Chlorophyll-Protein Complex and Photosynthetic Activities in Field Grown Apple Leaves. *Biologia Plantarum*, 47(2) :237–242. (Cited on page [20](#).)

- Bertamini, M., Muthuchelian, K., and Nedunchezian, N. (2004). Effect of Grapevine Leafroll on the Photosynthesis of Field Grown Grapevine Plants (*Vitis vinifera* L. cv. Lagrein). *Journal of Phytopathology*, 152(3) :145–152. (Cited on page 20.)
- Bertamini, M., Nedunchezian, N., Tomasi, F., and Grando, M. (2002). Phytoplasma [Stolbur-subgroup (Bois Noir-BN)] infection inhibits photosynthetic pigments, ribulose-1,5-bisphosphate carboxylase and photosynthetic activities in field grown grapevine (*Vitis vinifera* L. cv. Chardonnay) leaves. *Physiological and Molecular Plant Pathology*, 61 :357–366. (Cited on page 20.)
- Besag, J. (1986). On the Statistical Analysis of Dirty Pictures. *Journal of the Royal Statistical Society : Series B (Methodological)*, 48(3) :259–279. (Cited on page 87.)
- Bigün, J., Granlund, G. H., and Wiklund, J. (1991). Multidimensional orientation estimation with applications to texture analysis and optical flow. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, (8) :775–790. (Cited on page 44.)
- Bigun, J. (1987). *Optimal Orientation Detection of Linear Symmetry*. Linköping University Electronic Press. (Cited on pages 44 and 45.)
- Bilmes, J. (2000). A Gentle Tutorial of the EM Algorithm and its Application to Parameter Estimation for Gaussian Mixture and Hidden Markov Models. *Technical Report ICSI-TR-97-021, University of Berkeley*, 4. (Cited on page 58.)
- Blondlot, A., Gate, P., and Poilvé, H. (2005). Providing operational nitrogen recommendations to farmers using satellite imagery. In *proceedings of the 5th ECPA conference*. (Cited on page 22.)
- Bois, B., Zito, S., and Calonnet, A. (2017). Climate vs grapevine pests and diseases worldwide : the first results of a global survey. *OENO One*, 51(2) :133–139. (Cited on page 9.)
- Bosch, A., Zisserman, A., and Muñoz, X. (2006). Scene Classification Via pLSA. In Leonardi, A., Bischof, H., and Pinz, A., editors, *Computer Vision – ECCV 2006*, pages 517–530, Berlin, Heidelberg. Springer Berlin Heidelberg. (Cited on page 66.)
- Boulent, J., Beaulieu, M., St-Charles, P.-L., Théau, J., and Foucher, S. (2019). Deep learning for in-field image-based grapevine downy mildew identification. In *proceedings of the 12th ECPA conference*, pages 141–148. Wageningen Academic Publishers. (Cited on pages 25 and 26.)
- Bouquet, A., Torregrosa, L., Iocco, P., and R. Thomas, M. (2009). Grapes. In *Compendium of Transgenic Crop Plants*. (eds C. Kole and T. C. Hall). (Cited on page 32.)

- Burghouts, G. J. and Geusebroek, J.-M. (2009). Performance Evaluation of Local Colour Invariants. *Comput. Vis. Image Underst.*, 113(1) :48–62. (Cited on page [66](#).)
- Carter, G. A. and Knapp, A. K. (2001). Leaf optical properties in higher plants : linking spectral characteristics to stress and chlorophyll concentration. *American Journal of Botany*, 88(4) :677–684. (Cited on page [17](#).)
- Cerovic, G. Z., Goutouly, J.-P., Hilbert, G., Destrac Irvine, A., and Moise, N. (2009). Mapping winegrape quality attributes using portable fluorescence-based sensors. In *FRUTIC 09*. (S. Best, ed.). (Cited on page [17](#).)
- Chuche, J. and Thiery, D. (2014). Biologie et ecologie de *Scaphoideus titanus*, cicadelle vectrice de la flavescence dorée. *Phytoma*, pages 25–29. (Cited on page [8](#).)
- Cirillo, M. D., Mirdell, R., Sjöberg, F., and Pham, T. D. (2019). Tensor Decomposition for Colour Image Segmentation of Burn Wounds. *Scientific Reports*, 9(1) :3291. (Cited on page [133](#).)
- Cocquerez, J.-P. and Bolon, P., editors (1995). *Analyse d'images : filtrage et segmentation*. Enseignement de la physique traitement du signal. Masson, Paris. (Cited on pages [43](#) and [116](#).)
- Cointault, F., Journaux, L., Rabatel, G., Germain, C., Ooms, D., Destain, M., Gorretta, N., Grenier, G., Laviolle, O., and Marin, A. (2012). Texture, color and frequential proxy-detection image processing for crop characterization in a context of precision agriculture. In *Agricultural Science*, pages p. 49 – p. 70. InTech. (Cited on page [25](#).)
- Coquin, D., Bolon, P., and Ionescu, B. (2002). Dissimilarity measures in color spaces. In *Object recognition supported by user interaction for service robots*, volume 1, pages 612–615 vol.1. (Cited on page [63](#).)
- Curran, P. J. (1988). The semivariogram in remote sensing : An introduction. *Remote Sensing of Environment*, 24(3) :493 – 507. (Cited on page [43](#).)
- Da Costa, J., Weisbecker, P., Farbos, B., Leyssale, J.-M., Vignoles, G., and Germain, C. (2015). Investigating carbon materials nanostructure using image orientation statistics. *Carbon*, 84 :160–173. (Cited on page [44](#).)
- Davis, L. S. (1975). A survey of edge detection techniques. *Computer Graphics and Image Processing*, 4(3) :248 – 270. (Cited on page [45](#).)

- De Luis-Garcia, R., Deriche, R., and Alberola-Lopez, C. (2008). Texture and color segmentation based on the combined use of the structure tensor and the image components. *Signal Processing*, 88(4) :776–795. (Cited on page 72.)
- Delalieux, S., Aardt, J. V., Keulemans, W., Schrevens, E., and Coppin, P. (2007). Detection of biotic stress (*Venturia inaequalis*) in apple trees using hyperspectral data : Non-parametric statistical approaches and physiological implications. *European Journal of Agronomy*, 27(1) :130 – 143. (Cited on page 21.)
- Deliere, L., Cartolaro, P., Goutouly, J.-P., Barbier, J. M., Bonicel, L., Forget, D., Leroy, P., Naud, O., Ugaglia, A., Del’homme, C., Davy, A. L., Davidou, L., Guilbault, P., Guisset, M., and Guillois, F. (2013). Conception et transfert de systèmes décisionnels pour la réduction des traitements en viticulture : le projet SyDÉRÉT. *Innovations Agronomiques* (28), 155-168 . (2013). (Cited on page 33.)
- Denis, P. (2007). *Quaternions et Algèbres Géométriques, de nouveaux outils pour les images numériques couleur*. Thèse, Université de Poitiers. (Cited on page 67.)
- Doghraji, S. (2017). *Caractérisation de la géométrie locale et globale de textures directionnelles par reconstruction d’hypersurfaces et transformations d’espace : application à l’analyse stratigraphique des images sismiques*. Thèse, Université de Bordeaux. (Cited on page 44.)
- Donias, M., David, C., Berthoumieu, Y., Lavialle, O., Guillon, S., and Keskes, N. (2007). New fault attribute based on robust directional scheme. *GEOPHYSICS*, 72(4) :P39–P46. (Cited on page 44.)
- DRAAF Nouvelle-Aquitaine. Bulletin de Santé végétal Nord Aquitaine : bilan 2018. Technical report, Chambre d’agriculture Nouvelle-Aquitaine, DRAAF Nouvelle-Aquitaine. (Cited on page 31.)
- Drimbarean, A. and Whelan, P. F. (2001). Experiments in colour texture analysis. *Pattern Recognition Letters*, 22(10) :1161 – 1167. (Cited on page 65.)
- Dubos, B. (2002). *Maladies cryptogamiques de la vigne : champignons parasites des organes herbacés et du bois de la vigne*. Ed. Féret, Bordeaux, 2. éd. revue et augmentée edition. (Cited on page 10.)
- Dyrmann, M., Karstoft, H., and Midtiby, H. S. (2016). Plant species classification using deep convolutional neural network. *Biosystems Engineering*, 151 :72 – 80. (Cited on page 25.)

- Farlow, W. G. (1882). *American Grape Mildew in Europe*. Botanical Gazette. (Cited on page 11.)
- Feret, J.-B., Gitelson, A., Noble, S., and Jacquemoud, S. (2017). PROSPECT-D : Towards modeling leaf optical properties through a complete lifecycle. *Remote Sensing of Environment*, 193 :204–215. (Cited on page 23.)
- Förstner, W. and Gülch, E. (1987). A fast operator for detection and precise location of distinct points, corners and centres of circular features. In *Proc. ISPRS intercommission conference on fast processing of photogrammetric data*, pages 281–305. Interlaken. (Cited on page 45.)
- Gagalowicz, A. (1983). *Vers un modèle de textures*. Thèse, Université Pierre et Marie Curie. (Cited on page 42.)
- Germain, C., Da Costa, J., Laviaille, O., and Baylou, P. (2003). Multiscale estimation of vector field anisotropy application to texture characterization. *Signal Processing*, 83(7) :1487–1503. (Cited on page 44.)
- Germain, C., Keresztes, B., Grenier, G., Laviaille, O., and Da Costa, J.-P. (2016). System and method for estimating a harvest volume in a vineyard operation. Brevet n° wo/2016/193602. (Cited on page 35.)
- Han, S. and Cointault, F. (2013). Détection précoce de maladies sur feuilles par traitement d’images. In *Orasis, Congrès des jeunes chercheurs en vision par ordinateur*, Cluny, France. (Cited on pages 14 and 25.)
- Haralick, R. (1979). Statistical and structural approaches to texture. *Proceedings of the IEEE*, 67(5) :786–804. (Cited on pages 42 and 43.)
- Haralick, R. M., Shanmugam, K., and Dinstein, I. (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6) :610–621. (Cited on pages 25 and 43.)
- Harris, C. and Stephens, M. (1988). A combined corner and edge detector. In *In Proc. of Fourth Alvey Vision Conference*, pages 147–151. (Cited on page 44.)
- Haug, S., Michaels, A., Biber, P., and Ostermann, J. (2014). Plant classification system for crop /weed discrimination without segmentation. In *IEEE Winter Conference on Applications of Computer Vision*, pages 1142–1149. (Cited on page 25.)



- Hering, E. (1920). *Grundzüge der Lehre vom Lichtsinn (Caractéristiques de base de la théorie du sens de la lumière)*. Berlin : Springer. (Cited on page 66.)
- Himeno, M., Kitazawa, Y., Yoshida, T., Maejima, K., Yamaji, Y., Oshima, K., and Namba, S. (2014). Purple top symptoms are associated with reduction of leaf cell death in phytoplasma-infected plants. *Scientific Reports*, 4 :4111. (Cited on page 20.)
- Hoffer, R. and Johannsen, C. J. (1969). 'Ecological Potential in Spectral Signatures Analysis'. *Ecological Potential in Spectral Signatures Analysis. Remote Sensing in Ecology*. (Cited on page 18.)
- Hou, J., Li, L., and He, J. (2016). Detection of grapevine leafroll disease based on 11-index imagery and ant colony clustering algorithm. *Precision Agriculture*, 17(4) :488–505. (Cited on page 22.)
- Ilea, I., Bombrun, L., Said, S., and Berthoumieu, Y. (2018). Fisher Vector Coding for Covariance Matrix Descriptors Based on the Log-Euclidean and Affine Invariant Riemannian Metrics. *Journal of Imaging*, 4 :85. (Cited on page 54.)
- Ilea, I., Bombrun, L. B., Said, S., and Berthoumieu, Y. (2018). Covariance matrices encoding based on the log-euclidean and affine invariant riemannian metrics. In *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, pages 506–50609. (Cited on page 47.)
- Jackson, R. S. (2008). 4 - Vineyard Practice. In Jackson, R. S., editor, *Wine Science (Third Edition)*, pages 108–238. Academic Press, San Diego. (Cited on page 11.)
- Jacquemoud, S. and Baret, F. (1990). PROSPECT : A model of leaf optical properties spectra. *Remote Sensing of Environment*, 34(2) :75 – 91. (Cited on page 23.)
- Jeger, M., Bragard, C., Caffier, D., Candresse, T., Chatzivassiliou, E., Dehnen-Schmutz, K., Gilioli, G., Anton Jaques Miret, J., Macleod, A., Navajas, M., Niere, B., Parnell, S., Potting, R., Rafoss, T., Rossi, V., Urek, G., van Bruggen, A., Van der Werf, W., West, J., and Grégoire, J.-C. (2016). Risk to plant health of Flavescence dorée for the EU territory. *EFSA Journal*, 14. (Cited on page 8.)
- Julesz, B. (1962). Visual Pattern Discrimination. *IRE Transactions on Information Theory*, 8(2) :84–92. (Cited on pages 42 and 43.)
- Kass, M. and Witkin, A. (1987). Analyzing oriented patterns. *Computer Vision, Graphics, and Image Processing*, 37(3) :362 – 385. (Cited on page 45.)

- Keresztes, B., Abdelghafour, F., Randriamanga, D., Da Costa, J.-P., and Germain, C. (2018). Real-time Fruit Detection Using Deep Neural Networks. In *proceedings of the 14th ICPA conference*, Montréal, Canada. Monticello, IL : International Society of Precision Agriculture. (Cited on page 25.)
- Kneizys, X. F., Shettle, E., W. Abreu, L., Chetwynd, H. J., and Anderson, P. G. (1988). *User guide to LOWTRAN 7*. Air Force Geophysics Laboratory. (Cited on page 23.)
- Knipling, E. B. (1970). Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation. *Remote Sensing of Environment*, 1(3) :155 – 159. (Cited on page 18.)
- Knutsson, H. (1989). Representing local structure using tensors. Technical report, Computer Vision Laboratory, Linköping University. (Cited on pages 44 and 45.)
- Kumar, A. (2019). Leaf Disease Detection using Image Processing Technique- A Survey. *International Journal of Computer Sciences*, 07(11) :94–97. (Cited on page 25.)
- Kumar, J. P. and Domnic, S. (2019). Image based leaf segmentation and counting in rosette plants. *Information Processing in Agriculture*, 6(2) :233 – 246. (Cited on page 25.)
- Lacaze, R., Frederic, B., Camacho de Coca, F., d’Andrimont, R., C Freitas, S., Pacholczyk, P., Poilvé, H., Smets, B., Tansey, K., Wagner, W., Calvet, J.-C., Balsamo, G., Kidd, R., Makhmara, H., Weiss, M., and Bradley, A. (2011). geoland2–Towards an operational GMES Land Monitoring Core Service : the Biogeophysical Parameter Core Mapping Service. *Third recent advances in quantitative remote sensing*, pages 416–421. (Cited on page 23.)
- Le Grand, Y. (1972). *Optique physiologique. Tome II, Lumière et couleurs*. Masson et Cie, Paris (France), France. (Cited on page 61.)
- Lee, U., Chang, S., Putra, G. A., Kim, H., and Kim, D. H. (2018). An automated, high-throughput plant phenotyping system using machine learning-based plant segmentation and image analysis. *PLOS ONE*, 13(4) :1–17. (Cited on page 25.)
- Lenglet, C., Rousson, M., Deriche, R., and Faugeras, O. (2006). Statistics on the manifold of multivariate normal distributions : Theory and application to diffusion tensor mri processing. *Journal of Mathematical Imaging and Vision*, 25(3) :423–444. (Cited on page 46.)
- Levkowitz, H. (2007). *Color Theory and Modeling for Computer Graphics, Visualization, and Multimedia Applications*. Springer. (Cited on page 62.)

- Lin, J. (2011). The effect of texture on perception and measurement of whiteness. *American Association of Textile Chemists and Colorists International Conference 2011, AATCC 2011*, pages 20–29. (Cited on page [64](#).)
- Lorenz, D., Eichhorn, K., Bleiholder, H., Klose, R., Meier, U., and Weber, E. (1994). Phänologische Entwicklungs-stadien der Weinrebe (*Vitis vinifera* L. ssp. *Vinifera*). *Vitic. Enol. Sci.*, 49 :66–70. (Cited on page [6](#).)
- Louargant, M., Jones, G., Faroux, R., Paoli, J.-N., Maillot, T., Gée, C., and Villette, S. (2018). Unsupervised Classification Algorithm for Early Weed Detection in Row-Crops by Combining Spatial and Spectral Information. *Remote Sensing*, 10 :761. (Cited on page [25](#).)
- Lyvers, E. P. and Mitchell, O. R. (1988). Precision edge contrast and orientation estimation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 10(6) :927–937. (Cited on page [45](#).)
- Mahalanobis, P. C. (1936). On the Generalised Distance in Statistics. *Proceedings of the National Institute of Sciences of India*, 2 :49–55. (Cited on page [116](#).)
- Mahlein, A.-K., Kuska, M., Thomas, S., Bohnenkamp, D., Alisaac, E., Behmann, J., Wahabzada, M., and Kersting, K. (2017). Plant disease detection by hyperspectral imaging : from the lab to the field. *Advances in Animal Biosciences*, 8 :238–243. (Cited on page [16](#).)
- Mahlein, A.-K., Steiner, U., Dehne, H.-W., and Oerke, E.-C. (2010). Spectral signatures of sugar beet leaves for the detection and differentiation of diseases. *Precision Agriculture*, 11(4) :413–431. (Cited on page [22](#).)
- Mahlein, A.-K., Steiner, U., Hillnhütter, C., Dehne, H.-W., and Oerke, E.-C. (2012). Hyperspectral imaging for small-scale analysis of symptoms caused by different sugar beet diseases. *Plant Methods*, 8(1) :3. (Cited on page [16](#).)
- Mallat, S. (1989). A theory for multiresolution signal decomposition : the wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(7) :674–693. (Cited on page [43](#).)
- Manjunath, B. and Ma, W. (1996). Texture features for browsing and retrieval of image data. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18(8) :837–842. (Cited on page [43](#).)
- Materka, A. and Strzelecki, M. (1998). Texture Analysis Methods - A Review. *COST B11 report*. (Cited on page [43](#).)

- Mathiassen, J. R., Skavhaug, A., and Bø, K. (2002). Texture Similarity Measure Using Kullback-Leibler Divergence between Gamma Distributions. In Heyden, A., Sparr, G., Nielsen, M., and Johansen, P., editors, *Computer Vision — ECCV 2002*, pages 133–147, Berlin, Heidelberg. Springer Berlin Heidelberg. (Cited on page 44.)
- Mestre, H. (2019). The absorption of radiation by leaves and algae. *Cold Spring Harbor Symposia on Quantitative Biology*, 3 :191–209. (Cited on page 18.)
- Michel, L. (2016). Mieux valoriser les réseaux d'épidémiosurveillance lors de l'élaboration du Bulletin de Santé du Végétal. (Cited on page 15.)
- Mojsilovic, A., Hu, J., and Safranek, R. J. (1999). Perceptually based color texture features and metrics for image retrieval. In *Proceedings 1999 International Conference on Image Processing (Cat. 99CH36348)*, volume 3, pages 588–592 vol.3. (Cited on page 65.)
- Montag, E. and Berns, R. (2000). Lightness dependencies and the effect of texture on suprathreshold lightness tolerances. *Color Research & Application*, 25 :241–249. (Cited on page 64.)
- Mueller, J. P. and Massaron, L. (2016). *Machine learning for dummies*. For dummies. John Wiley & Sons, Inc, Hoboken, NJ. (Cited on page 43.)
- Nammalwar, P., Ghita, O., and Whelan, P. F. (2003). Experimentation on the Use of Chromaticity Features, Local Binary Pattern, and Discrete Cosine Transform in Colour Texture Analysis. In *Image Analysis*, pages 186–192. Springer, Berlin, Heidelberg. (Cited on page 65.)
- Neyman, J. and Pearson, E. S. (1933). On the Problem of the Most Efficient Tests of Statistical Hypotheses. *Philosophical Transactions of the Royal Society of London. Series A, Containing Papers of a Mathematical or Physical Character*, 231 :289–337. (Cited on page 133.)
- Nouri, M. (2018). *Détection précoce d'une maladie fongique « la tavelure du pommier » par imagerie hyperspectrale*. Thèse, Montpellier SupAgro. (Cited on page 16.)
- Nouri, M., Gorretta, N., Vaysse, P., Giraud, M., Germain, C., Keresztes, B., and Roger, J.-M. (2017). Near infrared hyperspectral dataset of healthy and infected apple tree leaves images for the early detection of apple scab disease. *Data in Brief*, 16. (Cited on pages 16, 19, 21, 23, and 24.)
- Oberti, R., Marchi, M., Tirelli, P., Calcante, A., Iriti, M., and Borghese, A. N. (2014). Automatic detection of powdery mildew on grapevine leaves by image analysis : Optimal

- view-angle range to increase the sensitivity. *Computers and Electronics in Agriculture*, 104 :1 – 8. (Cited on pages [15](#) and [16](#).)
- Ojala, T., Pietikäinen, M., and Harwood, D. (1996). A comparative study of texture measures with classification based on featured distributions. *Pattern Recognition*, 29(1) :51–59. (Cited on page [43](#).)
- Palm, C. (2004). Color texture classification by integrative Co-occurrence matrices. *Pattern Recognition*, 37(5) :965 – 976. (Cited on page [66](#).)
- Panjwani, D. K. and Healey, G. (1995). Markov random field models for unsupervised segmentation of textured color images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 17(10) :939–954. (Cited on page [66](#).)
- Paschos, G. and Valavanis, F. P. (1999). A color texture based visual monitoring system for automated surveillance. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 29(2) :298–307. (Cited on page [65](#).)
- Pedneault, K. and Provost, C. (2016). Fungus resistant grape varieties as a suitable alternative for organic wine production : Benefits, limits, and challenges. *Scientia Horticulturae*, 208 :57 – 77. (Cited on page [9](#).)
- Pei, S.-C. and Cheng, C.-M. (1997). Novel block truncation coding of image sequences for limited-color display. In Del Bimbo, A., editor, *Image Analysis and Processing*, pages 164–171, Berlin, Heidelberg. Springer Berlin Heidelberg. (Cited on page [67](#).)
- Pennec, X., Fillard, P., and Ayache, N. (2006). A riemannian framework for tensor computing. *International Journal of Computer Vision*, 66 :41–66. (Cited on page [46](#).)
- Pham, M., Mercier, G., and Michel, J. (2015). Covariance-based texture description from weighted coherency matrix and gradient tensors for polarimetric sar image classification. In *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pages 2469–2472. (Cited on page [44](#).)
- Picon, A., Alvarez-Gila, A., Seitz, M., Ortiz-Barredo, A., Echazarra, J., and Johannes, A. (2019). Deep convolutional neural networks for mobile capture device-based crop disease classification in the wild. *Computers and Electronics in Agriculture*, 161 :280 – 290. (Cited on page [14](#).)
- Pietikäinen, M., Mäenpää, T., and Viertola, J. (2002). Color Texture Classification with Color Histograms and Local Binary Patterns. *Workshop on Texture Analysis in Machine Vision*. (Cited on page [64](#).)

- Polder, G., van Evert, F., Lamaker, A., , J., van der Heijden, G., Lotz, B., Zalm, T., and Kempenaar, C. (2007). Weed Detection Using Textural Image Analysis. (Cited on page 25.)
- Rançon, F., Bombrun, L., Keresztes, B., and Germain, C. (2018). Comparison of SIFT Encoded and Deep Learning Features for the Classification and Detection of Esca Disease in Bordeaux Vineyards. *Remote Sensing*, 11 :1. (Cited on pages 16, 25, and 26.)
- Rao, A. R. and Schunck, B. G. (1991). Computing oriented texture fields. *CVGIP : Graphical Model and Image Processing*, 53 :157–185. (Cited on page 45.)
- Rayapati, N., Perry, E., Pierce, F., and Mekuria, T. (2009). The potential of spectral reflectance technique for the detection of Grapevine leafroll-associated virus-3 in two red-berried wine grape cultivars. *Computers and Electronics in Agriculture*, 66 :38–45. (Cited on page 22.)
- Regniers, O. (2014). *Texture analysis approach for soil occupation mapping using very high resolution remote sensing data : application to forest, vineyards and oyster parks*. Thèse, Université de Bordeaux. (Cited on pages 25 and 44.)
- Rey, P., Bertsch, C., Fontaine, F., and Larignon, P. (2016). Maladies du bois de la vigne avancées en France depuis 2010. *Phytoma*, (693) :7–10. (Cited on page 8.)
- Reynier, A. (2011). *Manuel de viticulture : Guide technique du viticulteur*. Lavoisier. (Cited on page 6.)
- Rittner, L., Flores, F. C., and Lotufo, R. A. (2010). A tensorial framework for color images. *Pattern Recognition Letters*, 31(4) :277–296. (Cited on pages 70 and 133.)
- Roorda, A., Metha, A. B., Lennie, P., and Williams, D. R. (2001). Packing arrangement of the three cone classes in primate retina. *Vision Research*, 41(10) :1291 – 1306. (Cited on page 61.)
- Rosu, R., Donias, M., Bombrun, L., Said, S., Regniers, O., and Da Costa, J.-P. (2017). Structure Tensor Riemannian Statistical Models for CBIR and Classification of Remote Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing*, 55(1) :248–260. (Cited on pages 44, 46, and 47.)
- Rosu, R. G. (2018). *Parametric approaches for modelling local structure tensor fields with applications to texture analysis*. Thèse, Université de Bordeaux. (Cited on pages 44, 46, and 54.)



- Rosu, R.-G., Da Costa, J.-P., and Donias, M. (2016). Structure tensor Log-Euclidean statistical models for texture analysis. In *Proc. IEEE International Conference on Image Processing (ICIP)*, pages 3553–3557. (Cited on pages 25 and 47.)
- Roumiguié, A., Jacquin, A., Poilvé, H., Hagolle, O., Daydé, J., and Sigel, G. (2015). Validation of a Forage Production Index (FPI) Derived from MODIS fCover Time-Series Using High-Resolution Satellite Imagery : Methodology, Results and Opportunities. *Remote Sensing*, 7 :11525–11550. (Cited on page 23.)
- Rousson, M., Brox, T., and Deriche, R. (2003). Active unsupervised texture segmentation on a diffusion based feature space. In *Proc. CVPR IEEE*, volume 2, pages II – 699. (Cited on page 44.)
- Said, S., Bombrun, L., Berthoumieu, Y., and Manton, J. H. (2017). Riemannian Gaussian Distributions on the Space of Symmetric Positive Definite Matrices. *IEEE Transactions on Information Theory*, 63(4) :2153–2170. (Cited on pages 46, 47, 54, and 55.)
- Sangwine, S. (1996). Fourier transforms of colour images using quaternion or hypercomplex numbers. *Electronics Letters*, 32(21) :1979. (Cited on page 67.)
- Sankaran, S., Mishra, A., Ehsani, R., and Davis, C. (2010). A review of advanced techniques for detecting plant diseases. *Computers and Electronics in Agriculture*, 72(1) :1 – 13. (Cited on page 17.)
- Santoso, H., Gunawan, T., Jatmiko, R. H., Darmosarkoro, W., and Minasny, B. (2011). Mapping and identifying basal stem rot disease in oil palms in North Sumatra with QuickBird imagery. *Precision Agriculture*, 12(2) :233–248. (Cited on page 22.)
- Schwartz, W. and Pedrini, H. (2007). Color Textured Image Segmentation Based on Spatial Dependence Using 3d Co-occurrence Matrices and Markov Random Fields. In *International Conference in Central Europe on Computer Graphics, Visualization and Computer Vision*. (Cited on page 66.)
- Serra, J. (1986). Introduction to mathematical morphology. *Computer Vision, Graphics, and Image Processing*, 35(3) :283 – 305. (Cited on pages 83 and 88.)
- Sims, D. A. and Gamon, J. A. (2002). Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sensing of Environment*, 81(2) :337 – 354. (Cited on page 17.)



- Singh, V. and Misra, A. K. (2017). Detection of plant leaf diseases using image segmentation and soft computing techniques. *Information Processing in Agriculture*, 4(1) :41 – 49. (Cited on page [25](#).)
- Song, X. (2011). *Descripteurs couleur locaux invariants aux conditions d'acquisition*. Thèse, Université de Poitiers. 2011STET4033. (Cited on page [66](#).)
- Soulard, R. (2012). *Ondelettes analytiques et monogènes pour la représentation des images couleur*. Thèse, Université de Poitiers. (Cited on page [67](#).)
- Thanwerdas, Y. and Pennec, X. (2019). Is affine invariance well defined on SPD matrices? A principled continuum of metrics. In *Geometric Science of Information*, Proceedings of Geometric Science of Information, Toulouse, France. (Cited on page [47](#).)
- Tona, E., Calcante, A., and Oberti, R. (2018). The profitability of precision spraying on specialty crops : a technical–economic analysis of protection equipment at increasing technological levels. *Precision Agriculture*, 19(4) :606–629. (Cited on pages [2](#) and [15](#).)
- Tremblay, N., Wang, Z., and Cerovic, Z. G. (2012). Sensing crop nitrogen status with fluorescence indicators. A review. *Agronomy for Sustainable Development*, 32(2) :451–464. (Cited on page [17](#).)
- Trussell, H. J., Lin, J., and Shamey, R. (2011). Effects of texture on color perception. In *2011 IEEE 10th IVMSWP Workshop : Perception and Visual Signal Analysis*, pages 7–11. (Cited on page [64](#).)
- Tuceryan, M. and K., J. A. (1993). Texture Analysis. In *Handbook of Pattern Recognition and Computer Vision*, pages 235–276. (Cited on page [43](#).)
- Turner, M. R. (1986). Texture discrimination by Gabor functions. *Biological Cybernetics*, 55(2) :71–82. (Cited on page [43](#).)
- Verhoef, W. (1984). Light scattering by leaf layers with application to canopy reflectance modeling : The SAIL model. *Remote Sensing of Environment*, 16(2) :125 – 141. (Cited on page [23](#).)
- Vine, M. F., Degnan, D., and Hanchette, C. (1997). Geographic information systems : their use in environmental epidemiologic research. *Environmental Health Perspectives*, 105(6) :598–605. (Cited on page [16](#).)
- Vitali, M., Chitarra, W., Galetto, L., Bosco, D., Marzachi, C., Gullino, M., Spanna, F., and Lovisolo, C. (2013). Flavescence dorée phytoplasma deregulates stomatal control of

- photosynthesis in *Vitis vinifera*. *Annals of Applied Biology*, 162(3) :335–346. (Cited on page 20.)
- Wei, L.-Y., Lefebvre, S., Kwatra, V., and Turk, G. (2009). State of the Art in Example-based Texture Synthesis. *Eurographics 2009, State of the Art Report, EG-STAR - 2009*. (Cited on page 42.)
- Weickert, J. and Hagen, H., editors (2006). *Visualization and Processing of Tensor Fields*. Mathematics and Visualization. Springer-Verlag, Berlin Heidelberg. (Cited on page 48.)
- Weijer, J. and Gevers, T. (2004). Tensor Based Feature Detection for Color Images. In *Final Program and Proceedings - IS and T/SID Color Imaging Conference*, pages 100–105. (Cited on page 133.)
- West, J. S., Bravo, C., Oberti, R., Lemaire, D., Moshou, D., and McCartney, H. A. (2003). The potential of optical canopy measurement for targeted control of field crop diseases. *Annual Review of Phytopathology*, 41(1) :593–614. (Cited on page 15.)
- Whelan, P. F. and Ghita, O. (2008). Colour Texture analysis. In Mirmehdi, M., Xie, X., and Suri, J., editors, *Handbook of Texture Analysis*. Imperial College Press. (Cited on page 64.)
- Xin, J. H., Shen, H.-L., and Chuen Lam, C. (2005). Investigation of texture effect on visual colour difference evaluation. *Color Research & Application*, 30(5) :341–347. (Cited on page 64.)
- Zhou, F., Fu Feng, J., and Yun Shi, Q. (2001). Texture feature based on local Fourier transform. In *IEEE International Conference on Image Processing*, volume 2, pages 610–613. (Cited on page 43.)



---

## Publications et actes de communication

---

### Revue internationale à comité de lecture

- Abdelghafour, F., Rosu, R., Keresztes, B., Germain, C., and Da Costa, J. -P. (2019). A Bayesian framework for joint structure and colour based pixel-wise classification of grapevine proximal images. *Computers and Electronics in Agriculture*, 158 :345 – 357.

### Conférences avec acte de communication publié

- Abdelghafour, F., Rançon, F., Keresztes, B., Germain, C., and Da Costa, J.-P. (2019). On-board colour imaging for the detection of downy mildew. In *proceedings of the 12th ECPA conference*, pages 195–202. Wageningen Academic Publishers.
- Abdelghafour F., Rosu R., Keresztes B., Germain C., and Da Costa, J.-P. (2018). Joint structure and colour based parametric classification of grapevine organs from proximal images through several critical phenological stages. In *proceedings of the 14th ICPA conference*. Monticello, IL : International Society of Precision Agriculture.
- B. Keresztes, F. Abdelghafour, D. Randriamanga, J. Da Costa, C. Germain. (2018). Real-Time Fruit Detection Using Deep Neural Networks. n *proceedings of the 14th ICPA conference*. Monticello, IL : International Society of Precision Agriculture.
- Abdelghafour, F., Keresztes, B., Germain, C., and Da Costa, J. -P. (2017). Potential of onboard colour imaging for in-field detection and counting of grape bunches at early fruiting stages. *Advances in Animal Biosciences*, 8(2) :505–509.

---

## Résumé

---

Le mildiou de la vigne est une phytopathologie d'origine fongique particulièrement inquiétante pour la filière viticole. L'objectif de cette thèse est d'étudier les potentialités de l'imagerie couleur embarquée pour estimer l'état sanitaire des vignobles affectés par le mildiou à l'échelle intra-parcellaire. La solution proposée vise à assister les réseaux de surveillance épidémiologique dans l'estimation des risques sanitaires et dans la préconisation de plans de lutte chimique. En pratique, deux chaînes de traitement d'images sont proposées, l'une dédiée à la segmentation des classes d'organes de la vigne, et l'autre à la détection, au dénombrement et à la mesure des tissus symptomatiques du mildiou. Ces deux chaînes sont conçues autour d'une stratégie de modélisation commune et s'adressent à des images acquises directement à la parcelle dans les conditions de travail viticole. La stratégie proposée s'appuie des représentations structure-couleur et des modèles probabilistes des classes des tissus présents dans les vignes étudiées. Elle opère en trois étapes : Formuler des descripteurs pour extraire les propriétés caractéristiques et discriminantes de chaque classe ; Modéliser les distributions statistiques de ces descripteurs dans chacune des classes ; Affecter chaque pixel à une des classes selon son adéquation à leurs modèles. Les descripteurs combinent le Tenseurs Local de Structure (LST) avec des statistiques colorimétriques calculées dans le voisinage du pixel considéré. Pour tenir compte de la nature spécifique des LST, les descripteurs font l'objet de transformations pour être représentés dans l'espace log-euclidien. Dans cet espace, il devient possible de modéliser les classes de tissus d'intérêt par des distributions de mélanges de gaussiennes. Cette stratégie est appliquée dans un premier temps à des images de vigne saine. Il s'agit de partitionner une image en classes d'organes (feuillage, grappes ou inflorescences et tiges). Une classification est réalisée par Maximum A Posteriori (MAP) puis régularisée par relaxation stochastique et morphologie mathématique. Les résultats obtenus pour trois stades phénologiques se montrent très convaincants. De plus, la chaîne de traitement s'avère robuste au réglage des principaux hyper-paramètres. Dans un second temps, la chaîne de traitement précédente est adaptée pour traiter des images comportant des symptômes du mildiou ainsi que certaines nécroses, décolorations, carences, plaies mécaniques, qui constituent des facteurs confondants. Une nouvelle méthode de décision est utilisée. Elle s'appuie sur une reconstruction des symptômes par croissance autour de germes. Les critères utilisés reposent sur les représentations structure-couleur et les modèles probabilistes déjà définis. La nouvelle chaîne de traitement permet de détecter de façon fiable les symptômes du mildiou et d'estimer la surface des tissus affectés.

---

## Abstract

---

The downy mildew of the vine is a phytopathology of fungal origin particularly worrying for the wine industry. The aim of this thesis is to study the potentialities of on-board color imaging to estimate the health status of vineyards affected by downy mildew on an intra-plot scale. The proposed solution aims at assisting epidemiological monitoring networks in the estimation of health risks and in the recommendation of chemical control plans. In practice, two image processing chains are proposed, one dedicated to the segmentation of vine organs, and the other to the detection, counting and measurement of symptomatic tissues of downy mildew. These two chains are designed on a common strategy and are aimed at images acquired directly at the plot under the conditions of viticultural work. The proposed strategy is based on structure-color representations and probabilistic models of the tissue classes present in the vines. It operates in three steps : Formulating descriptors to extract the characteristic and discriminating properties of each class ; Modelling the statistical distributions of these descriptors in each class ; Assigning each pixel to one of the classes according to its suitability to their models. The descriptors combine the Local Structure Tensors (LST) with colorimetric statistics calculated in the neighborhood of the pixel considered. To account for the specific nature of LSTs, the descriptors are transformed to be represented in the Log-Euclidean space. In this space, it becomes possible to model the classes of interest by distributions of multivariate Gaussian mixtures of structure-color representations. This strategy is first applied to healthy vine images. It involves the partitioning of an image into organ classes (foliage, bunches or inflorescences and stems). A pixel-wise MAP (Maximum A Posteriori) classification is carried out and regularized by stochastic relaxation and mathematical morphology operations. The results obtained for three phenological stages are very convincing. In addition, the processing chain is robust to the setting of the main hyperparameters. In a second step, the previous methodological chain is adapted to process images with symptoms of downy mildew as well as necrosis, discolorations, deficiencies, mechanical wounds, which are confounding factors. The decision method is based on a reconstruction of symptoms by propagation around germs. The criteria used are based on the previously defined color-structure representations and probabilistic models. The new processing chain reliably detects downy mildew symptoms and estimates the area of the affected tissues.