
Etablissement d'un protocole d'acquisition par rotation d'images pour le suivi du développement d'épis de froment d'hiver et la proxidétection de la fusariose au champ

Auteur : Godechal, Francois

Promoteur(s) : Mercatoris, Benoît; 8562

Faculté : Gembloux Agro-Bio Tech (GxABT)

Diplôme : Master en bioingénieur : sciences et technologies de l'environnement, à finalité spécialisée

Année académique : 2020-2021

URI/URL : <http://hdl.handle.net/2268.2/12933>

Avertissement à l'attention des usagers :

Tous les documents placés en accès ouvert sur le site le site MatheO sont protégés par le droit d'auteur. Conformément aux principes énoncés par la "Budapest Open Access Initiative"(BOAI, 2002), l'utilisateur du site peut lire, télécharger, copier, transmettre, imprimer, chercher ou faire un lien vers le texte intégral de ces documents, les disséquer pour les indexer, s'en servir de données pour un logiciel, ou s'en servir à toute autre fin légale (ou prévue par la réglementation relative au droit d'auteur). Toute utilisation du document à des fins commerciales est strictement interdite.

Par ailleurs, l'utilisateur s'engage à respecter les droits moraux de l'auteur, principalement le droit à l'intégrité de l'oeuvre et le droit de paternité et ce dans toute utilisation que l'utilisateur entreprend. Ainsi, à titre d'exemple, lorsqu'il reproduira un document par extrait ou dans son intégralité, l'utilisateur citera de manière complète les sources telles que mentionnées ci-dessus. Toute utilisation non explicitement autorisée ci-avant (telle que par exemple, la modification du document ou son résumé) nécessite l'autorisation préalable et expresse des auteurs ou de leurs ayants droit.

**ETABLISSEMENT D'UN PROTOCOLE
D'ACQUISITION PAR ROTATION D'IMAGES POUR
LE SUIVI DU DÉVELOPPEMENT D'ÉPIS DE
FROMENT D'HIVER ET LA PROXIDÉTECTION DE
LA FUSARIOSE AU CHAMP**

FRANÇOIS GODECHAL

**TRAVAIL DE FIN D'ÉTUDES PRÉSENTÉ EN VUE DE L'OBTENTION DU DIPLÔME DE
MASTER BIOINGÉNIEUR EN SCIENCES ET TECHNOLOGIES DE L'ENVIRONNEMENT**

ANNÉE ACADÉMIQUE 2020-2021

CO-PROMOTEURS: BENOÎT MERCATORIS, DAMIEN VINCKE

Toute reproduction du présent document, par quelque procédé que ce soit ne peut être réalisée qu'avec l'autorisation de l'auteur et de l'autorité académique de Gembloux Agro-Bio Tech.

Le présent document n'engage que son auteur.

**ETABLISSEMENT D'UN PROTOCOLE
D'ACQUISITION PAR ROTATION D'IMAGES POUR
LE SUIVI DU DÉVELOPPEMENT D'ÉPIS DE
FROMENT D'HIVER ET LA PROXIDÉTECTION DE
LA FUSARIOSE AU CHAMP**

FRANÇOIS GODECHAL

**TRAVAIL DE FIN D'ÉTUDES PRÉSENTÉ EN VUE DE L'OBTENTION DU DIPLÔME DE
MASTER BIOINGÉNIEUR EN SCIENCES ET TECHNOLOGIES DE L'ENVIRONNEMENT**

ANNÉE ACADÉMIQUE 2020-2021

CO-PROMOTEURS: BENOÎT MERCATORIS, DAMIEN VINCKE

Remerciements

Ce travail a été réalisé au sein de l'unité qualité et authentification des produits du Centre wallon de Recherches agronomiques (CRA-W). Il a été rendu possible grâce à leur collaboration avec l'unité productions végétales.

Je tiens tout d'abord à remercier mes deux co-promoteurs, Benoît Mercatoris et Damien Vincke, pour leurs conseils et leur encadrement au cours de chacune des étapes de ce travail de fin d'études.

J'aimerais ensuite remercier le personnel du CRA-W qui m'a accueilli pendant toute la durée de mon stage. J'ai fait des rencontres très enrichissantes. J'aimerais tout particulièrement remercier Damien Vincke, qui a toujours été présent, aussi bien sur le plan professionnel que personnel. Les innombrables discussions que nous avons tenues m'ont fait grandir. Je remercie aussi Benoît Scaut pour son aide, son écoute et ses conseils concernant le matériel, Philippe Vermeulen pour ses idées sur le projet ainsi que Damien Eylenbosch et son équipe pour la mise en place de l'essai. Merci également à Gauthier Lepage qui nous a rejoint sur la fin, pour son entrain et son aide sur le champ. Finalement, je remercie encore Maxime Joissains pour ses blagues plus improbables les unes que les autres, sa bonne humeur et pour le temps qu'il a passé à m'expliquer son travail ; cela m'a beaucoup intéressé.

Mes remerciements vont aussi à Hélène Soyeurt, Sébastien Franceschini et Charles Nickmilder pour leurs conseils concernant la partie apprentissage automatique du travail.

Je remercie finalement toute ma famille pour m'avoir soutenu pendant toutes mes études.

Résumé

La fusariose de l'épi est une maladie fongique qui peut avoir des conséquences ravageuses sur les rendements des céréales. Bien qu'elle ait été discrète ces dernières années, le changement climatique pourrait changer la tendance. Plusieurs capteurs sont capables de détecter cette maladie aussi bien en laboratoire que sur le terrain. Dans cette étude, trois systèmes d'acquisition d'image sont utilisés pour identifier la brûlure de l'épi sur un champ de froment d'hiver : un appareil photo numérique, un capteur hyperspectral dans le domaine du visible et infrarouge proche (VPIR, 400 - 1 000 nm) et un autre dans la gamme de l'infrarouge proche (PIR, 900 - 1 700 nm). Afin de segmenter les épis et d'identifier ceux qui sont malades, six modèles supervisés sont entraînés : une analyse discriminante quadratique (QDA), une analyse discriminante par les moindres carrés partiels (PLS-DA), une forêt aléatoire (RF), un cartographe d'angle spectral (SAM), une machine à vecteurs de support (SVM) et un perceptron multicouches (MLP). Les données sont auparavant prétraitées par différentes méthodes. Les segmentations des épis sur les données hyperspectrales sont très bien réalisées (exactitudes supérieures à 99 %). Les meilleurs modèles pour les données couleurs sont corrects à près de 94 %. Toutes ces valeurs sont rendues possibles par l'utilisation de MLPs ; le prétraitement dépend quant à lui du système de vision. La plus faible quantité de données à disposition rend la détection de la fusariose plus complexe. Le domaine de l'infrarouge proche est le plus pertinent pour cette tâche, alors que pour la segmentation, cela dépend de la date à laquelle les données sont collectées. Les modèles de détection atteignent une justesse de plus de 99 % dans cette gamme, mais il est difficile de les comparer. Les résultats montrent donc qu'il est possible de segmenter les épis et de détecter la fusariose au champ avec des performances variables en fonction des capteurs et de la période d'acquisition.

Mots clés : épi - *Triticum aestivum* - *Fusarium* - phénotypage - infrarouge proche - apprentissage automatique

Abstract

Fusarium head blight (FHB) is a fungal disease that can lead to devastating losses on grain yields. Although it has been quite in recent years, climate change could change this trend. This disease can be identify both in the laboratory and the field with the help of various sensors. In this study, three of them are used to detect head blight on a winter wheat field : a digital camera, a hyperspectral camera in the visible and near infrared range (VNIR, 400 - 1 000 nm) and another in the near infrared range (NIR, 900 - 1 700 nm). In order to segment the ears and identify the diseased ones, six supervised models are trained : a quadratic discriminant analysis (QDA), a partial least squares discriminant analysis (PLS-DA), a random forest (RF), a spectral angle mapper (SAM), a support vector machine (SVM) and a multilayer perceptron (MLP). Prior to that, the data are pre-processed by different methods. Ears segmentations on hyperspectral data are vey well done (accuracies above 99 %). For the color ones, the best models are nearly 94 % correct. All these values are reachable through the use of MLPs. There is no general agreement on pre-processing, which is therefore camera dependent. The smaller amount of data available makes the detection of FHB more complex. The NIR domain is the most relevant for this task while it depends on when the data are acquired for segmentation. Detection models reach an accuracy of more than 99 % in this range, but it is difficult to compare them. The results therefore show that it is possible to segment ears and to detect head blight in the field with varying performances depending on the sensors and the acquisition period.

Keywords : ear - *Triticum aestivum* - *Fusarium* - phenotyping - near infrared - machine learning

Table des matières

1	Introduction	1
1.1	Notions d'imagerie	1
1.2	Le froment d'hiver	3
1.2.1	Importance agronomique	3
1.2.2	Les stades de croissance	3
1.3	La fusariose	4
1.4	Le phénotypage de la fusariose par imagerie	5
1.4.1	En conditions contrôlées	6
1.4.2	En conditions semi-contrôlées	7
1.4.3	En conditions non contrôlées	7
1.5	Les algorithmes d'apprentissage automatique pour le phénotypage de la fusariose	8
2	Objectifs	9
3	Matériel et méthodes	10
3.1	Site expérimental	10
3.2	Acquisitions des données	12
3.2.1	Système d'acquisition	12
3.2.2	Marquage des épis fusariés	14
3.2.3	Calendrier des acquisitions	15
3.3	Traitements des images	16
3.3.1	Annotation	17
3.3.2	Prétraitements	20
3.3.3	Détection des valeurs aberrantes	21
3.4	Modèles de discrimination	21
3.4.1	Entraînement des modèles	21
3.4.2	Validation des modèles	22

3.4.3	Prédiction d'images	23
4	Résultats et discussion	24
4.1	Etablissement des paramètres pour le filtre de Savitzky-Golay	24
4.2	Segmentation des images	25
4.2.1	3 et 4 JAI	25
4.2.2	18 JAI	25
4.2.3	26 JAI	26
4.2.4	39 JAI	27
4.3	Détection de la fusariose	27
4.3.1	26 JAI	27
4.3.2	39 JAI	28
4.4	Comparaison temporelle des capteurs	29
4.5	Solutions globales pour la segmentation des épis	30
4.6	Comparaison avec les conditions contrôlées	31
5	Conclusions	32
6	Perspectives	33
7	Bibliographie	35
8	Annexes	39

Liste des tableaux

1	Gammes spectrales	5
2	Plan de l'essai	10
3	Dates d'inoculation pour les variétés suivies	12
4	Evènements majeurs survenus sur l'essai	12
5	Description du matériel photographique	13
6	Informations relatives aux acquisitions d'image	15
7	Sélection des variétés pour la construction des librairies	17
8	Taille des librairies d'entraînement selon l'avancement de la saison	19
9	Taille des librairies de validation selon l'avancement de la saison	20
10	Algorithmes de discrimination	22
11	Moyennes et écart-types des exactitudes des modèles selon le prétraitement - FX10 - 3 JAI	24
12	Moyennes et écart-types des exactitudes des modèles selon le prétraitement - FX17 - 4 JAI	24
13	Tests de McNemar - FX10 - 3 JAI	25
14	Tests de McNemar - FX17 - 4 JAI	25
15	Tests de McNemar - FX10 - 18 JAI	26
16	Tests de McNemar - FX17 - 18 JAI	26
17	Test de McNemar - FX10 - 26 JAI	26
18	Test de McNemar - FX17 - 26 JAI	27
19	Test de McNemar - FX10 - 39 JAI	27
20	Test de McNemar - FX17 - 39 JAI	27
21	Exactitudes des modèles de détection de la fusariose selon les capteurs et la date d'acquisitions	29
22	Sommes des écarts entre le meilleur modèle et chaque combinaison de modèle-prétraitement pour FX10	30
23	Sommes des écarts entre le meilleur modèle et chaque combinaison de modèle-prétraitement pour FX17	30
24	Différences d'exactitude en pourcents entre le modèle global et le meilleur modèle pour chaque séance d'acquisitions	30

25	Exactitudes des modèles selon les paramètres du filtre de Savitzky-Golay - FX10 - 3 JAI	39
26	Exactitudes des modèles selon les paramètres du filtre de Savitzky-Golay - FX17 - 4 JAI	39
27	Exactitudes des modèles de segmentation des épis - FX10 - 3 JAI	40
28	Exactitudes des modèles de segmentation des épis - FX17 - 4 JAI	40
29	Exactitudes des modèles de segmentation des épis - D5200 - 3 JAI	40
30	Exactitudes des modèles de segmentation des épis - FX10 - 18 JAI	41
31	Exactitudes des modèles de segmentation des épis - FX17 - 18 JAI	41
32	Exactitudes des modèles de segmentation des épis - D5200 - 18 JAI	41
33	Exactitudes des modèles de segmentation des épis - FX10 - 26 JAI	41
34	Exactitudes des modèles de segmentation des épis - FX17 - 26 JAI	42
35	Exactitudes des modèles de segmentation des épis - D5200 - 26 JAI	42
36	Exactitudes des modèles de segmentation des épis - FX10 - 39 JAI	42
37	Exactitudes des modèles de segmentation des épis - FX17 - 39 JAI	42
38	Exactitudes des modèles de segmentation des épis - D5200 - 39 JAI	42
39	Exactitudes des modèles de détection de la fusariose - FX10 - 26 JAI	43
40	Exactitudes des modèles de détection de la fusariose - FX17 - 26 JAI	43
41	Exactitudes des modèles de détection de la fusariose - D5200 - 26 JAI	43
42	Exactitudes des modèles de détection de la fusariose - FX10 - 39 JAI	43
43	Exactitudes des modèles de détection de la fusariose - FX17 - 39 JAI	43
44	Exactitudes des modèles de détection de la fusariose - D5200 - 39 JAI	44

Liste des figures

1	Mosaïque de Bayer	1
2	Spectre électromagnétique	1
3	Réponse spectrale du Nikon D300s	2
4	Différentes approches d'imagerie hyperspectrale	2
5	Largeur totale à mi-hauteur	3
6	Epi fusarié et épi sain à la fin du stade laiteux	4
7	Gamme de sensibilité des capteurs CMOS et InGaAs	5
8	Inoculation	13
9	Le chariot équipé d'un capteur hyperspectral et de l'appareil photo numérique	14
10	Marquage des épis fusariés lors des acquisitions	15
11	Traitements d'images	16
12	Affichages pour l'annotation de KWS Extase (images du 07/07/2021)	18
13	Exemple de bibliothèques pour une image RVB	19
14	Exactitudes des modèles de segmentation selon le capteur au cours de la saison	29
15	Valeurs de la table de distribution Chi-carrée	44
16	Image originale et segmentations pour les différents capteurs - RGT Gravity inoculé - 3 et 4 JAI	45
17	Image originale et segmentations pour les différents capteurs - RGT Gravity inoculé - 18 JAI .	46
18	Image originale et segmentations pour les différents capteurs - RGT Gravity non inoculé - 26 JAI	47
19	Image originale et segmentations pour les différents capteurs - RGT Gravity inoculé - 26 JAI .	48
20	Image originale et segmentations pour les différents capteurs - bordure (non inoculée) - 39 JAI	49
21	Image originale et segmentations pour les différents capteurs - RGT Gravity inoculé - 39 JAI .	50
22	Image originale et détection de la fusariose pour les différents capteurs - RGT Gravity non inoculé - 26 JAI	51
23	Image originale et détection de la fusariose pour les différents capteurs - RGT Gravity inoculé - 26 JAI	52

24	Détection de la fusariose pour FX10 et FX17 avec d'autres modèles - RGT Gravity non inoculé - 26 JAI	53
25	Détection de la fusariose pour FX10 et FX17 avec d'autres modèles - RGT Gravity inoculé - 26 JAI	54
26	Image originale et détection de la fusariose pour les différents capteurs - bordure (non inoculée) - 39 JAI	55
27	Image originale et détection de la fusariose pour les différents capteurs - RGT Gravity inoculé - 39 JAI	56

Liste des abréviations

ab	Jeu de données dépourvus de valeurs aberrantes
auto	Standardisation des variables
BBCH	Echelle développée par BASF, Bayer, Ciba-Geigy et Hoechst
CECI	Consortium des Equipements de Calcul Intensif
CMOS	Semi-conducteur à oxyde métallique complémentaire - <i>Complementary Metal Oxide Semiconductor</i>
CO ₂	Dioxyde de carbone
CRA-W	Centre wallon de Recherches agronomiques
colspa	Calcul d'autres espaces colorimétriques
DON	Déoxynivalénol
FHB	<i>Fusarium Head Blight</i>
FWHM	Largeur totale à mi-hauteur - <i>Full Width at Half Maximum</i>
GASVM	SVM optimisé par un algorithme génétique - <i>SVM optimized by Genetic Algorithm</i>
HSV	Teinte, saturation, valeur - <i>Hue, Saturation, Value</i>
InGaAs	Arséniure d'indium et de gallium - <i>Indium Gallium Arsenide</i>
ISV	Indice Spectral de Végétation
JAI	Jour(s) Après Inoculation
JPG	<i>Joint Photographic Group</i>
MLP	Perceptron multicouches - <i>Multilayer Perceptron</i>
MSR	<i>Modified Simple Ratio</i>
NDVI	Indice de végétation par différence normalisée - <i>Normalized difference vegetation index</i>
NIR	Near Infrared
PIR	Infrarouge Proche
PLS	Régression des moindres carrés partiels - <i>Partial Least Squares Regression</i>
PLS-DA	Analyse discriminante par les moindres carrés partiels - <i>Partial Least Squares Discriminant Analysis</i>
plsda	Transformation de variables par PLS-DA
PSSR	<i>Pigment-Specific Simple Ratio</i>
PTFE	Polytétrafluoroéthylène
QDA	Analyse discriminante quadratique - <i>Quadratic Discriminant Analysis</i>
ret5	Retirer cinq longueurs d'onde extrêmes
RF	Forêt aléatoire - <i>Random Forest</i>
RVB	Rouge, Vert, Bleu
rf	Sélection de variables par RF
SAM	Cartographe d'angle spectral - <i>Spectral Angle Mapper</i>
sgXY	Dérivée de Savitzky-Golay d'ordre Y sur une fenêtre de X données
SNV (ou snv)	Variable standard normale - <i>Standard Normal Variate</i>
SVM	Machine à vecteurs de support (ou séparateur à vaste marge) - <i>Support Vector Machine</i>
SWIR	Infrarouge à ondes courtes - <i>Short Wave Infrared</i>
VIS	Visible
VNIR	<i>Visible and Near Infrared</i>
VPIR	Visible et Infrarouge Proche
YCrCb	Luminance, chrominance rouge, chrominance bleue - <i>Luma, Chroma Red, Chroma Blue</i>

1 Introduction

Cette section présente brièvement le fonctionnement des systèmes d'acquisition utilisés dans cette recherche. Elle résume ensuite les principaux éléments connus intervenant dans ce travail. Elle aborde ainsi le froment, avant de s'attarder sur une de ses maladies : la fusariose. Ensuite, les différents outils permettant sa détection sont passés en revue. Finalement, un aperçu des techniques d'apprentissage automatique est donné.

1.1 Notions d'imagerie

Une image est une représentation en deux dimensions d'une scène quelconque. Elle peut être représentée sous la forme d'une matrice dont chaque élément est un pixel. Les valeurs prises par ces pixels sont liées à l'intensité lumineuse reçue par les cellules photosensibles disposées sur le capteur de l'appareil. Une telle image est dite monochrome et est représentée en nuances de gris. Pour obtenir une image couleurs, il faut placer une mosaïque de Bayer devant le capteur (figure 1). Elle est composée de filtres qui permettent de laisser passer la partie du spectre électromagnétique (figure 2) correspondant au rouge, vert et bleu (RVB). Ces bandes sont cependant larges et se recouvrent partiellement (figure 3). En mélangeant ces trois couleurs primaires, il est possible d'en reformer d'autres : toutes celles visibles par l'être humain.




Figure 1 – Mosaïque de Bayer (source : researchgate.net, consulté le 13/08/2021)




Figure 2 – Spectre électromagnétique (source : lewebpedagogique.com, consulté le 26/02/2021)

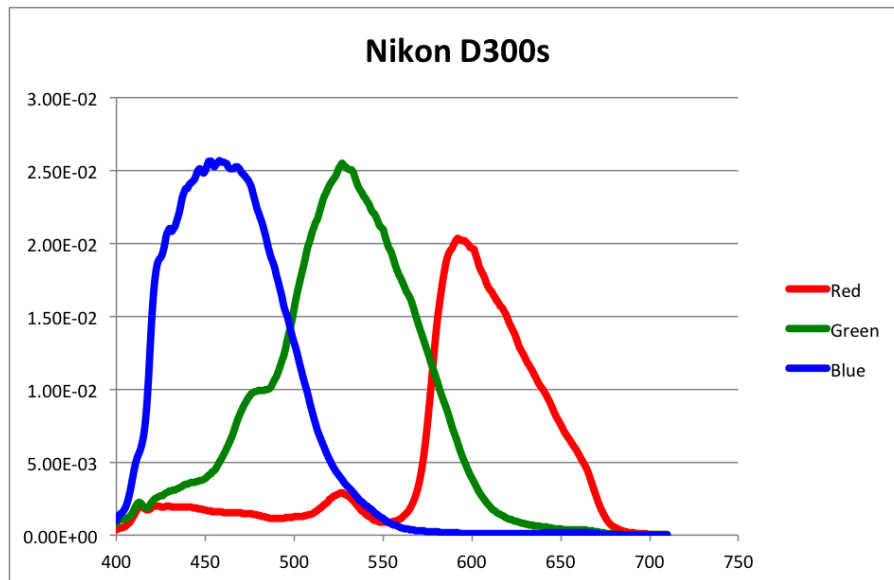


Figure 3 – Réponse spectrale du Nikon D300s; en ordonnée : réponse relative du signal, en abscisse : longueur d’onde (nm) (source : vitabin.blogspot.com, consulté le 13/08/2021)

Le fonctionnement des capteurs hyperspectraux est différent. Il existe plusieurs approches pour ce type d’acquisition (figure 4). Celle utilisée dans le cadre de cette recherche est un balayage linéique. Cette méthode consiste à réfracter la lumière incidente grâce à un élément d’optique dispersif. L’information spectrale est ainsi répartie sur le capteur, en fonction de sa longueur d’onde. Ce mode de fonctionnement propose une meilleure résolution spectrale. Celle-ci peut se mesurer via la largeur totale à mi-hauteur (FWHM) de sa distribution (figure 5). A titre d’exemples, les résolutions spectrales de FX10 et de FX17 (les deux systèmes de vision hyperspectrale utilisés dans cette étude) valent respectivement 5,5 et 8 nm. Les deux dimensions du capteur témoignent d’une information spatiale et d’une autre spectrale. Il faut donc induire un déplacement relatif entre le système d’acquisition et la scène (le balayage) pour enregistrer la deuxième dimension spatiale.

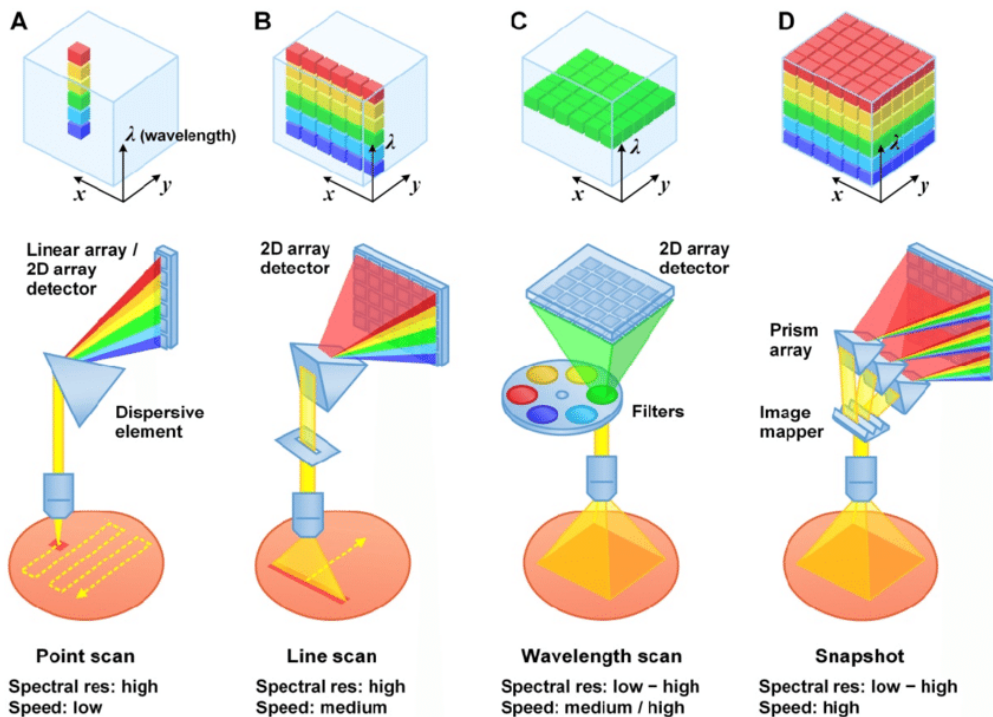


Figure 4 – Différentes approches d’imagerie hyperspectrale; A : balayage ponctuel, B : balayage linéique, C : balayage de longueurs d’onde, D : instantané (source : researchgate.net, consulté le 14/08/2021)




Figure 5 – Largeur totale à mi-hauteur (source : bdnyc.org.net, consulté le 14/08/2021)

Les systèmes d’acquisition multispectrale classiques fonctionnent également par un balayage linéique ou par un balayage des longueurs d’onde. A la différence des images hyperspectrales, ce ne sont pas des bandes spectrales contiguës qui sont acquises mais des parties du spectre électromagnétique, en fonction des filtres utilisés.

1.2 Le froment d’hiver

1.2.1 Importance agronomique

Le froment (*Triticum aestivum* L.) est l’une des trois plus grandes céréales appartenant à la famille des Poaceae (Shewry, 2009). La diversité génétique qui règne au sein de cette espèce lui permet d’être cultivée sous une large variété de climat. Cette caractéristique, ainsi que les propriétés de ses grains (permettant la cuisson de pâtes diverses), lui confèrent toute son importance. Il est ainsi cultivé depuis des centaines d’années aux quatre coins du globe. En 2019, plus de 750 millions de tonnes de froment ont été récoltées à travers le monde dont près de 2 millions en Belgique (Food and Agriculture Organization of the United Nations, 2021). Actuellement en Wallonie, 21 variétés de froment d’hiver sont recommandées pour leur rendement et leur bonne résistance face à certains stress (Bodson et al., 2020); 52 autres variétés sont encore à l’étude pour rejoindre leur rang.

1.2.2 Les stades de croissance

Le développement du blé tendre est caractérisé par des stades clés communs aux céréales. Plusieurs échelles sont couramment utilisées comme repères : Zadoks, Keller et Baggiolini, Keekes et Large ou encore BBCH améliorée "céréales". Elles divergent par leur degré de précision et leur format d’écriture (Lancashire et al., 1991). Les échelles de Zadoks et BBCH sont les principales utilisées en Europe (Wise et al., 2011). Dans le cadre de ce travail, c’est l’échelle BBCH améliorée "céréales", s’inspirant de celle de Zadoks (Lancashire et al., 1991), qui est utilisée. Pour la description complète de cette échelle, le lecteur est référé aux pages jaunes du Libre Blanc Céréales (Bodson et Watillon, 2017, pp. 340 - 344).

1.3 La fusariose

La fusariose (aussi appelée brûlure de l'épi) est provoquée par 19 pathogènes différents (Stepien et Chelkowski, 2010) appartenant aux genres *Microdochium* et *Fusarium* (Dumont et al., 2021). Cette maladie cryptogamique s'attaque notamment aux épis de froment et de maïs. Elle a pour principales conséquences une diminution des rendements et un affaiblissement de la qualité sanitaire des récoltes. En effet, *Fusarium spp.* produisent plusieurs mycotoxines appartenant au groupe des Tricothécènes (Pirgozliev et al., 2003) dont la plus connue est le déoxynivalénol (DON) (Dumont et al., 2021). Ces métabolites toxiques présentent un risque autant pour l'homme que pour les animaux ou encore les écosystèmes naturels (Figuroa et al., 2018). La Commission Européenne fixe le seuil de concentration en DON autorisée dans les produits alimentaires à destination de l'homme à 750 µg/kg (European Commission, 2006).

Cette maladie se manifeste à la floraison si les conditions météorologiques sont chaudes et humides dès l'épiaison (Prescott et al., 1986). Elle apparaît sous la forme de taches beiges, brun clair ou orange au niveau de l'épillet (figure 6). Les grains peuvent aussi prendre une couleur blanche ou rose (De Wolf et al., 2011). Lorsque ces symptômes sont présents, il est déjà trop tard pour lutter contre la fusariose. Il faudra donc écarter la récolte compromise lors de la moisson (Dumont et al., 2021).

Ces quatre dernières années en Wallonie, la fusariose n'a pas menacé les récoltes à cause des conditions météorologiques chaudes mais sèches (Bodson et al., 2020; Dumont et al., 2021). La saison 2016 a quant à elle beaucoup souffert de cette maladie (Bodson et Watillon, 2017). Les dégâts provoqués sont cependant difficiles à évaluer puisqu'elle a agi de paire avec la septoriose, fortement présente cette année. Pirgozliev et al. (2003) relèvent certaines grandes épidémies de fusariose à travers le monde au XXe siècle. Les pertes en redement s'élèvent couramment autour des 50 %. Les pertes économiques, quant à elles, peuvent monter jusqu'à 2,6 milliards de dollars, comme cela a été le cas entre 1991 et 1996 dans neuf états aux États-Unis.

Le changement climatique pourrait cependant renverser la tendance puisque selon West et al. (2012), le climat est un des facteurs qui a le plus d'importance sur le développement de la brûlure de l'épi. Il impacte non seulement le développement des maladies, mais aussi la croissance des plantes de manière générale. Ainsi, Madgwick et al. (2011) alertent quant à l'attention qu'il faudrait porter sur le contrôle de la fusariose. Les modèles qu'ils construisent pour le Royaume-Uni prévoient que la floraison serait plus précoce et que les épidémies seraient plus sévères d'ici 2050. En effet, même si le Royaume-Uni connaîtra sans doute des étés plus secs, la précocité de l'anthèse coïnciderait avec une période de précipitations. Au-delà de ce risque, un climat plus sec durant l'inter-saison serait favorable à la survie de certaines espèces de *Fusarium* (Bateman et al., 2007). Celles-ci pourraient ainsi constituer l'inoculum de la saison suivante. Néanmoins, des températures trop élevées (supérieures à 32°C) de 3 à 6 jours après l'épiaison diminuent la production de DON (Hooker et al., 2002). L'élévation de la concentration atmosphérique en dioxyde de carbone (CO₂) présente quant à elle deux conséquences majeures (Melloy et al., 2010). La première est une augmentation de la production de biomasse du champignon pour une même quantité de tissu végétal. Ceci facilite la transmission de l'inoculum d'une saison à l'autre. Le deuxième impact qu'implique cette hausse de CO₂ atmosphérique concerne les variétés de froment résistantes à la fusariose. Celles-ci étaient capables, sous les concentrations atmosphériques du début du XXIe siècle, de réduire la quantité de biomasse fongique. Melloy et al. (2010) affirment qu'elles ne pourront dorénavant plus agir de la sorte.



Figure 6 – Epi fusarié (à gauche) et épi sain (à droite) à la fin du stade laiteux

Plusieurs possibilités sont envisageables pour lutter contre la brûlure de l'épi. L'utilisation de variétés peu sensibles à ce champignon est la première recommandée. Aussi, puisque la maladie peut se transmettre par la semence, il faut privilégier l'utilisation de semences saines ou préalablement désinfectées (Bodson et al., 2020). La fusariose peut être également véhiculée par le sol. Ainsi, si la culture précédente est du maïs ou du froment, un labour permet de diminuer le risque de contamination pour la saison culturale à venir. Le recours aux fongicides est également possible, avec notamment le *prothioconazole*, le plus efficace à ce jour (Dumont et al., 2021). La fenêtre d'application est cependant courte : dès la fin de l'épiaison jusqu'à six jours après le début de l'anthèse (Dumont et al., 2021; Bolanos-Carriel et al., 2020). Il est cependant avéré que combattre la fusariose en appliquant ce traitement assure des bons rendements et donc une viabilité économique (Bodson et Watillon, 2017). Pour d'avantage d'informations sur le contrôle de la fusariose, le lecteur est référé à l'article de Pirgozliev et al. (2003).

1.4 Le phénotypage de la fusariose par imagerie

La détection de la brûlure de l'épi peut se réaliser grâce à plusieurs capteurs et dans différents environnements. Les points suivants présentent les travaux effectués en conditions contrôlées ou au contraire, directement sur le champ. Un paragraphe intermédiaire survole les travaux entre ces deux extrêmes.

Les acquisitions hyperspectrales peuvent être conduites dans plusieurs domaines du spectre électromagnétique. Cela dépend de la technologie du capteur utilisée par l'appareil. Par exemple, les capteurs CMOS (semi-conducteur à oxyde métallique complémentaire) sont sensibles aux longueurs d'onde comprises entre 300 et 1 100 nm ; les capteurs InGaAs (arséniure d'indium et de gallium) sont efficaces de 900 à 1 700 nm (figure 7). Les gammes spectrales ainsi que les abréviations utilisées par la suite sont présentées dans le tableau 1. Celles-ci ne sont pas toujours exactement les mêmes que celles utilisées dans les différents documents, mais elles permettent ici de regrouper ensemble les articles suffisamment similaires.

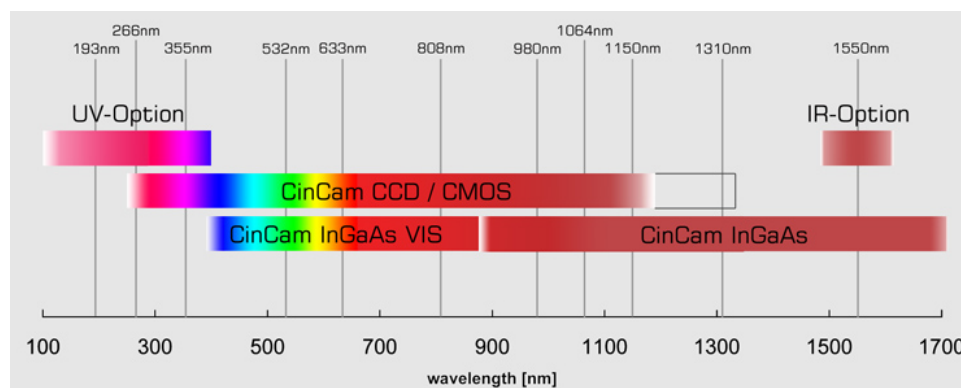


Figure 7 – Gamme de sensibilité des capteurs CMOS et InGaAs (source : cinogy.com, consulté le 13/08/2021)

Tableau 1 – Gammes spectrales

Nom	Abréviation	Gamme spectrale
Visible	VIS	400 - 750 nm
Visible et infrarouge proche	VPIR	400 - 1 000 nm
Infrarouge proche	PIR	900 - 1 700 nm
Infrarouge à ondes courtes	SWIR	1 000 - 2 500 nm

1.4.1 En conditions contrôlées

Les termes "conditions contrôlées" signifient qu'il est possible de fixer certains paramètres, comme par exemple l'orientation des épis, la luminosité et l'humidité. Cela implique une destruction du matériel végétal, qui est alors bien souvent étudié en laboratoire, en l'absence de vent, de poussière et des vibrations des machines agricoles.

En reconstruisant une image RVB sur base d'acquisitions hyperspectrales, Huang et al. (2020a) parviennent à identifier la zone fusariée d'un épis. Pour ce faire, ils changent l'espace colorimétrique de leurs images et seuillent la composante H de l'espace HSV (teinte, saturation, valeur). He et al. (2021), de leur côté, indiquent que les images couleurs ne permettent pas de discriminer différentes concentrations de contamination en DON. Quatre paramètres texturaux (l'énergie, l'entropie, le contraste et la corrélation) issus de ces images, n'ont pas amélioré leurs résultats.

Les différents domaines spectraux permettent d'obtenir des résultats à des dates variables. Ainsi, d'après Mahlein et al. (2019), le visible n'est capable d'identifier les épis malades qu'à partir de 7 jours après inoculation (JAI), soit le stade 73 BBCH. Le VPIR, quant à lui, montre des résultats dès 3 JAI (69 BBCH), grâce à deux indices spectraux : les PSSRa et PSSRb (*Pigment-Specific Simple Ratio*). Le SWIR se situe entre les deux, en détectant déjà la maladie au cinquième jour (71 BBCH). Finalement, les auteurs indiquent que le VPIR atteint ses performances maximales entre les stades 75 et 79 BBCH, ce qui est confirmé par Bauriegel et al. (2011b). Cela étant dit, la fusariose reste détectable entre les stades 71 et 85 BBCH (Bauriegel et al., 2011a).

Les bandes spectrales du VPIR identifiées pour différencier les épis sains des infectés sont les suivantes : 430 - 533, 560 - 675, 682 - 733 et 927 - 931 nm (Bauriegel et al., 2011a; Alisaac et al., 2018). Elles témoignent des teneurs en caroténoïdes et en chlorophylle ainsi que du stress en eau. Ce dernier est également reflété dans la gamme SWIR du spectre électromagnétique (Alisaac et al., 2018). Les indices spectraux de végétation (ISVs) sont largement utilisés dans ces études. Il en existe à profusion, mettant en avant diverses propriétés grâce à quelques longueurs d'onde seulement. La région PIR du spectre électromagnétique est mise à profit par Delwiche et al. (2019) pour différencier des grains sains et malades. Seules quatre longueurs d'onde sont nécessaires pour réaliser cette discrimination, d'après les auteurs de cette étude : 1 100, 1 197, 1 308 et 1 394 nm. Barbedo et al. (2015) obtiennent une précision de 91 % pour cette même tâche, et ce, uniquement avec la bande spectrale à 1411 nm. Les auteurs expliquent cet exploit par le fait que les bandes acquises ont le même comportement, mais que celle sélectionnée permet la meilleure séparation.

Le VPIR est suffisant à lui seul pour distinguer les épis sains des épis fusariés, et c'est d'autant plus vrai que la concentration en DON est importante (He et al., 2021). Ces auteurs obtiennent un taux de discrimination augmentant jusqu'à 91,36 % lorsqu'ils ajoutent quatre caractéristiques texturales (énergie, entropie, contraste et corrélation) à leur modèle (contre 86,42 % sans). Huang et al. (2020a) ont envisagé aussi cet apport, mais ils obtiennent leurs meilleurs résultats en laissant de côté ces paramètres texturaux au profit uniquement des composantes spectrales et colorimétriques retenues dans leur modèle. Huang et al. (2019) détectent la fusariose sur l'épi de froment d'hiver grâce à un dispositif spectral analytique combinant le VPIR et le SWIR. Les auteurs ont notamment mis en avant qu'un angle de vue de profil permet d'identifier au mieux la fusariose (88,6 %), devant un angle de face (85,7 %) et finalement une vue du dessus de l'épi (68,6 %).

D'autres capteurs, moins couramment utilisés pour la détection de la fusariose, peuvent aussi être employés. C'est le cas de l'imagerie par fluorescence chlorophyllienne. Cette méthode présente l'avantage d'être sensible à de faibles niveaux d'infection (Bauriegel et al., 2011b). Mahlein et al. (2019) utilisent cette technologie et mettent également à profit la thermographie infrarouge pour détecter la fusariose dès 5 JAI (71 BBCH). Ce sont respectivement l'impact du champignon sur le métabolisme et la diminution de la teneur en eau dans les épis malades qui permettent cette distinction. Les meilleurs résultats sont offerts par l'imagerie thermique (78 %) tandis que la fluorescence n'atteint que 56 %.

1.4.2 En conditions semi-contrôlées

Qiu et al. (2019) utilisent un appareil photo numérique pour photographier des lignes de froment directement au champ. La plateforme empruntée crée de l'ombre sur les cultures, ce qui leur permet d'avoir une certaine constance au niveau de l'éclairage. Un paramètre colorimétrique est issu des images. Il segmente efficacement les zones fusariées des épis. Les auteurs pointent néanmoins quelques problèmes. Un de ceux-ci est l'apparence mature que prennent rapidement certains épis sains, qui est très semblable à celles des épis malades, ce qui conduit inévitablement à des erreurs de discrimination.

Certains préfèrent isoler les épis en plaçant un tissu noir derrière eux. C'est ce que font Zhang et al. (2020a) dans leur recherche sur l'efficacité de fongicides pour le contrôle de la fusariose. Ils ne réalisent qu'une séance d'acquisitions avec un appareil photo numérique lors du développement des graines. Leurs comptages de tous les épis d'un côté et uniquement des épis malades de l'autre présentent tous deux une exactitude autour de 93 %. L'utilisation d'un tissu noir est également envisagée par Jin et al. (2018) et par Huang et al. (2020b). Ces derniers identifient l'indice de végétation MSR (*Modified Sample Ratio*) comme étant le plus efficace pour identifier la fusariose dans le domaine du VPIR. En coupant les épis au champ et en les étalant sur un tissu noir, Zhang et al. (2020b) concluent que la réflectivité (proportion de lumière réfléchi par un matériau) des épis moyennement malades peut varier suivant la face observée. Ces auteurs distinguent efficacement les épis fusariés des épis sains grâce au VIS. Ils n'utilisent en effet que cette région du spectre (moyennant quelques manipulations supplémentaires) pour estimer la sévérité des dégâts avec une exactitude de 97 %. Grâce à leur système d'acquisition d'image dans le domaine SWIR, et un protocole similaire, Ma et al. (2019) identifient avec succès l'infection du champignon au travers de 6 longueurs d'onde : 471, 696, 841, 963, 1 069 et 2 272 nm. Les quatre premières témoignent des variations de concentrations en pigments, tels que les chlorophylles ou la caroténoïde, tandis que les deux dernières reflètent les changements de teneur en eau et de structure interne des cellules. Finalement, les auteurs parviennent à la conclusion que la marge rouge (*red edge*) est la zone du spectre SWIR la plus sensible à la fusariose.

Il est également possible d'entrevoir les acquisitions par fluorescence chlorophyllienne directement au champ. Ceci a été concrétisé par Bauriegel et al. (2011b) au stade BBCH 77. Les auteurs indiquent cependant que les épis doivent être protégés de la lumière directe du soleil et que leur protocole de mesure nécessite des améliorations.

1.4.3 En conditions non contrôlées

Lorsque l'identification de la fusariose se déroule sur des données acquises en conditions non contrôlées, il faut s'attendre à ce que la performance des modèles soit plus faible. C'est d'ailleurs ce que montrent Menesatti et al. (2013). L'environnement naturel complique l'analyse d'images en proposant un arrière plan souvent semblable aux objets d'intérêt. Zhang et al. (2019) mettent au point un algorithme de segmentation d'images couleurs qui identifie les épis de façon très performante (justesse de 98,1 %). Sur base de ces fragments d'images, la sévérité de la fusariose est évaluée avec une exactitude de 92,5 %.

Whetton et al. (2018) parviennent à discriminer correctement les épis fusariés dans le VIS aux stades BBCH 61 et 71. L'outil est accroché et déplacé sur un tracteur et sert à la création de cartes pour visualiser l'importance de la maladie sur une parcelle. L'utilisation d'un capteur multispectral est également de mise avec notamment Dammer et al. (2011) qui capturent les longueurs d'onde autour de 670 et 800 nm. Ils couplent ce dispositif à un appareil photo numérique pour détecter la fusariose au champ. Le système de vision multispectral leur permet de calculer le NDVI (indice de végétation par différence normalisée), plus robuste pour ce travail. En effet, les images couleurs détectent entre autres trop d'épis malades dans les parcelles saines. Un travail supplémentaire doit être réalisé pour connaître les dates auxquelles la détection de la maladie est possible. Une estimation de celles-ci est cependant proposée par Dammer et al. (2011) : dès l'apparition des symptômes jusqu'à la maturation de l'épi.

1.5 Les algorithmes d'apprentissage automatique pour le phénotypage de la fusariose

Les paragraphes qui suivent ont pour objectif de confronter les techniques d'apprentissage automatique qui sont utilisées dans les études phénotypant la fusariose en milieu extérieur. Cet environnement favorise les disparités en terme de réflectivité au sein des images. Des algorithmes robustes à ces variations sont donc privilégiés.

La comparaison des performances de détection de la fusariose entre le laboratoire et le champ indique qu'une PLS-DA (analyse discriminante par les moindres carrés partiels) avance de bons résultats : une exactitude autour des 100 % et des 85 % respectivement (Menesatti et al., 2013). Leurs images hyperspectrales sont acquises dans la gamme 400 - 790 nm. Un travail similaire est proposé par Whetton et al. (2018) puisqu'ils travaillent dans la même région avec une régression des moindres carrés partiels (PLS). Celle-ci présente un coefficient de détermination R^2 de 85 %. Ma et al. (2019) identifient la fusariose sur des images hyperspectrales (350 - 2500 nm) au moyen d'une analyse discriminante linéaire de Fisher. Cette-dernière est alimentée par 6 composantes issues d'une analyse en ondelettes continues (*continuous wavelet analysis*). L'ensemble du processus présente de bons résultats puisque l'exactitude du modèle de discrimination de la fusariose est de 88,7 %. Bauriegel et al. (2011b) utilisent la méthode du cartographe d'angle spectral (SAM) sur des images acquises dans le VPIR. Leur résultat indique une corrélation à la hauteur de 96,4 % entre la discrimination proposée par l'algorithme et la sévérité de la maladie. Les auteurs déclarent cependant que les prédictions proposées sont fortement dépendantes des données utilisées comme référence. Huang et al. (2020b) alimentent une machine à vecteurs de support (SVM) ainsi qu'un SVM optimisé par un algorithme génétique (GASVM) avec des caractéristiques issues d'images VPIR. Leur GASVM présente une meilleure exactitude que leur SVM : 75 % contre 66,7 % en utilisant uniquement l'indice de végétation MSR. Selon les auteurs, l'algorithme génétique présente un avantage dans l'optimisation de l'espace des solutions. De son côté, le SVM surpasse certains algorithmes d'apprentissage qui convergent facilement vers des minima locaux. En plus de cela, il présente une grande stabilité et est robuste au niveau des prédictions.

Ces dernières années, l'émergence de l'apprentissage profond (*deep learning*) profite aussi au phénotypage. Cette technologie prometteuse annonce bien souvent de meilleurs résultats que les méthodes d'analyses d'images ordinaires (Kamilaris et Prenafeta-Boldú, 2018). Zhang et al. (2020b) comparent un réseau de neurones convolutionnel profond avec une forêt aléatoire (RF), une PLS et une régression SVM pour prédire la sévérité de la fusariose. L'exactitude de ces modèles sont respectivement de 97, 89, 86 et 81 %. Leur jeu de données sont des images hyperspectrales dans la gamme VPIR. Un SVM ainsi que différents réseaux de neurones profonds sont exploités par Jin et al. (2018) pour effectuer une discrimination dans la même région du spectre électromagnétique. L'exactitude du SVM vaut 61 % alors que les huit autres réseaux de neurones ont tous une exactitude environ 10 % plus élevée. Enfin, il est possible d'utiliser cette nouvelle technologie pour détecter la fusariose sur des images couleurs (Zhang et al., 2019). Les auteurs segmentent les zones infectées des épis avec une exactitude de 92,5 %.

Bien que l'apprentissage profond semble être la meilleure méthode pour identifier des épis fusariés, elle n'est pas mise en place dans le présent travail. En effet, ces réseaux de neurones requièrent une grande quantité de données annotées et une importante puissance de calcul lors de l'entraînement des modèles (Kamilaris et Prenafeta-Boldú, 2018). C'est pourquoi le recours aux méthodes d'apprentissage automatique plus "traditionnelles" est privilégié ici.

2 Objectifs

L'état de l'art met en avant le risque que présente la fusariose vis-à-vis du changement climatique. Cette menace doit d'autant plus être prise au sérieux dans un contexte de croissance démographique. En effet, selon les Nations Unies (United Nations, Department of Economic and Social Affairs, Population Division, 2019), la population mondiale passerait de 7,7 milliards de personnes en 2019 à 9,7 milliards en 2050. Des techniques pour détecter cette maladie en laboratoire sont maintenant au point. Quelques études parviennent également à de bons résultats en milieu extérieur, moyennant quelques arrangements pour limiter les aléas lors des acquisitions d'image. Très peu d'études se déroulent en conditions non contrôlées "totales". Elles ne réalisent en général que quelques séances d'acquisitions sur la saison, voire qu'une seule. De plus, différents outils de gammes spectrales variables semblent pertinents pour la détection de la fusariose. Finalement, il n'y a pas de consensus quant à la méthode d'apprentissage à utiliser pour détecter la fusariose de façon automatisée ; elle dépend évidemment du jeu de données initial que possèdent les chercheurs.

La finalité de ce travail est d'établir un protocole d'acquisition d'image pour détecter la brûlure de l'épi en conditions non contrôlées. Pour ce faire, il est nécessaire de segmenter les épis pour laisser de côté les objets non pertinents. Plusieurs algorithmes sont évalués afin de mettre en avant celui qui performe le mieux pour répondre à chacun de ces travaux. L'efficacité des capteurs est également comparée tout au long de la saison culturale.

3 Matériel et méthodes

3.1 Site expérimental

Les acquisitions d’image se déroulent sur un essai variétal (tableau 2) mis en place par le Centre wallon de Recherches agronomiques (CRA-W). Il se situe à Gembloux (50,56 N - 4,70 E) sur un sol limoneux à horizon B textural tacheté, à horizon A épais (Service Public de Wallonie, 2015). Le champ est semé le 4 novembre 2020 à une densité de 300 grains/m². Les parcelles sont larges de 1,5 m pour 8 m de longueur.

Tableau 2 – Plan de l’essai

Début du plan					
	Fusariose	Récolte tardive	Verse		Fusariose
	Bloc 1				Bloc 2
	6 m	3 m	3 m	6 m	6 m
Bordure	Bordure Bordure Avignon Bennington Campesino Crossway Cubitus Hyacinth Himalaya Hyvega Informer KWS Dag KWS Donovan KWS Dorset KWS Extase KWS Keitum KWS Smart KWS Sverre LG Apollo LG Keramik LG Spotlight Porthus Positiv RGT Gravity RGT Perkussio LG Skyscraper Socade CS Solange CS SU Ecusson SU Fiete SY Insitor Winner WPB Monfort SO1900				Bordure

Suite du plan					
	Fusariose	Récolte tardive	Verse		Fusariose
	Bloc 1				Bloc 2
	6 m	3 m	3 m	6 m	6 m
Bordure	LG Cambria Sorbet CS Broadway LG Mondial LG Tapestry Catalyst 77429 77431 77433 77435 77437 77526 77532 77534 Marly RGT Saki FDN17WW0053 FDN18WW0183 FDN18WW0240 SY118762 SY 118608 Garfield Spearhead				Bordure

Quinze variétés de froment d'hiver sont choisies pour l'expérimentation. Elles couvrent a priori des résistances plus ou moins prononcées face à la fusariose ; des cotations ont été réalisées par le CRA-W durant les dernières années. Elles sont inoculées deux fois en l'espace d'une semaine, lorsqu'elles entament leur floraison (tableau 3). Le pathogène, *Fusarium graminearum*, est aspergé sur les deux blocs prévus à cet effet à l'aide d'une rampe de pulvérisation (figure 8). La solution contient 0,3 L d'inoculum à raison d'environ 100 000 spores/mL pour 4,7 L d'eau. Elle est préparée en suffisance de sorte à arroser les parcelles d'environ 250 L/ha. Les inoculations se déroulent en début de matinée, à partir de 7 heures. Préalablement, l'essai est arrosé en soirée afin de garantir un taux d'humidité propice à l'infection du champignon.

Pour la suite du document, certains évènements sont exprimés en jours après inoculations (JAI). La date correspondante au 0 JAI est le 11/06/2021.

Il est nécessaire de préciser que les conditions climatiques rencontrées au début de l'été 2021 ont été favorables au développement du champignon. Les pluies et les vents lui ont permis de se déplacer jusqu'aux parcelles saines (le bloc de récolte tardive), servant de témoins dans le cadre de ce travail. Il est aussi envisageable que le champignon soit survenu naturellement dans l'essai. D'autres évènements ont eu un impact majeur sur l'essai au cours de la saison. Un récapitulatif est présenté dans le tableau 4. Ces aléas ont impliqué divers changements dans les données utilisées lors des traitements d'images. Ils seront décrits dans la partie "Traitements des images".

Tableau 3 – Dates d’inoculation pour les variétés suivies

Variété	09/06/2021	11/06/2021	15/06/2021
KWS Dorset		x	x
KMS Extase	x	x	
KWS Keitum	x	x	
KWS Smart		x	x
KWS Sverre	x	x	
LG Apollo		x	x
LG Keramik	x	x	
LG Spotlight		x	x
Porthus	x	x	
Positiv	x	x	
RGT Gravity		x	x
RGT Perkussio	x	x	
LG Skyscraper		x	x
Socade CS	x	x	
Solange CS		x	x

Tableau 4 – Evènements majeurs survenus sur l’essai

Date	JAI	Bloc	Variété(s) concernée(s)	Evènement
29/06/2021	18	2	Quelques variétés	Présence des premiers symptômes de fusariose (quelques épis par parcelle)
07/07/2021	26	2	KWS Dorset, KWS Keitum, KWS Smart et KWS Sverre	Verse
		Récolte tardive	Toutes les variétés	Contamination par la fusariose
12/07/2021	31	2	Socade CS et Solange CS	Verse
20/07/2021	38	2	Porthus	Verse
		1	KWS Dorset, KWS Keitum, KWS Smart, KWS Sverre, Socade CS et Solange CS	Verse
		Récolte tardive	Toutes les variétés	Verse

3.2 Acquisitions des données

3.2.1 Système d’acquisition

La matériel photographique utilisé se compose d’un appareil photo Nikon D5200 pour les images couleurs et deux systèmes d’acquisition de la marque Specim pour les images hyperspectrales (FX10 et FX17). Leurs caractéristiques sont présentées dans le tableau 5.



Figure 8 – Inoculation (photo du 08/06/2021)

Tableau 5 – Description du matériel photographique

	D5200	FX10	FX17
Gamme spectrale	RVB	400 - 1000 nm	PIR 900 - 1700 nm
Capteur	CMOS	CMOS	InGaAs
Pas de mesure	/	2,7 nm (224 bandes)	7 nm (112 bandes)
Largeur des images (nombre de pixels)	4000	512	640
Hauteur des images (nombre de pixels)	6000	Fonction du balayage	Fonction du balayage
Champ de vision horizontal	47°	38°	38°
Profondeur de couleur (bits)	8	12	12
Format d'enregistrement	JPG	RAW et DAT	RAW et DAT

Ces capteurs sont élevés approximativement à 1,4 m du sol. Puisque les systèmes de vision hyperspectrale sont linéiques, c'est-à-dire qu'ils acquièrent une ligne de pixels à la fois, un déplacement relatif entre la scène et le capteur est nécessaire. Ceci est assuré par le plateau tournant RS10, également de la marque Specim. Il confère à ces systèmes une rotation autour d'un axe horizontal. Les acquisitions sont gérées informatiquement par le programme Lumo Scanner, paramétré par un opérateur. Les images sont acquises de sorte à avoir un maximum de la surface de la microparcelle visible. Le focus des appareils Specim est optimisé à une distance horizontale d'environ 1 m au niveau des épis. L'appareil Nikon est quant à lui fixé de l'autre côté du RS10. Il est également orienté de manière à maximiser la surface visible de la microparcelle. Son déclenchement est réalisé manuellement à chaque fois qu'une acquisition hyperspectrale est menée. Le tout est déplacé au champ par un chariot élaboré pour cet usage (figure 9). L'alimentation électrique du matériel est fournie par un groupe électrogène.

La configuration du capteur hyperspectral est réalisée au début de chaque séance d'acquisitions. Cette étape peut éventuellement être répétée si les conditions de luminosité varient. Elle implique, dans un premier



Figure 9 – Le chariot équipé d'un capteur hyperspectral et de l'appareil photo numérique

temps, une maximisation du temps d'intégration tout en évitant la saturation du capteur. Ceci est évalué sur un matériau servant de référence blanche. Il s'agit du polytétrafluoroéthylène (PTFE), présentant une densité de $1,5 \text{ g/cm}^3$ dont les propriétés réfléchissantes sont garanties entre 250 et 2 500 nm. Ensuite, la fréquence d'images (le nombre de lignes acquises par seconde) est maximisée afin d'obtenir une durée d'acquisition courte. Le rapport hauteur/largeur (le format de l'image) permet finalement de fixer la vitesse de rotation afin d'éviter que les objets ne soient déformés. En effet, si celle-ci est trop rapide, les objets apparaissent aplatis alors que si elle est trop lente, ils semblent allongés. Parallèlement à cela, les paramètres du Nikon (ISO, ouverture et vitesse d'obturation) sont estimés automatiquement par l'appareil, et ce, lors de chaque capture d'image.

Lors de chaque acquisition hyperspectrale, l'appareil Specim ferme l'obturateur et scanne 100 lignes pour calculer une valeur moyenne de "noir". Elle passe ensuite sur la référence blanche pour enregistrer le "blanc". Enfin, le signal brut de la scène est enregistré au format RAW. La balance "blanc/noir" convertit enfin cette image brute en réflectivité, au format DAT. Cet hypercube de données constitue l'image de base pour les analyses. La conversion est donnée par l'équation suivante :

$$\text{réflectivité} = 10^4 \frac{(\text{signal} - \text{noir})}{(\text{blanc} - \text{noir})}$$

3.2.2 Marquage des épis fusariés

Le suivi de la maladie est réalisé dès l'apparition des premiers symptômes jusqu'à la récolte. Puisque les épis contaminés prennent l'apparence d'épis matures, il est nécessaire de trouver un moyen de les marquer avant qu'ils n'atteignent ce stade. Il faut cependant déployer un système qui influence le moins possible le spectre reflété par les épis. Si cette précaution n'est pas mise en place, la distinction entre épis malades et sains ne repose plus sur les caractéristiques propres de la maladie mais celles du marquage. Le dispositif doit aussi être capable de résister aux intempéries afin d'assurer son utilité jusqu'à la fin de la saison. Pour répondre à ces critères, des bouts de laines bleus et roses entourent respectivement les épis faiblement et fortement fusariés depuis le 2 et 6 juillet 2021 (21 et 25 JAI). Ce marquage n'est cependant pas très efficace pour l'annotation des images : les bouts de laine peuvent passer inaperçus à cause de l'angle de vue et de la résolution des systèmes de

vision hyperspectrale. De plus, ils ne sont pas toujours facilement distinguables sur les images fausses-couleurs formées par FX17 (cfr figure 12c). Pour reconnaître plus facilement les épis malades lors de l'analyse d'images, un second système est mis en place avec des boules de polystyrène. Celles-ci sont accrochées aux épis au moyen d'un fil de fer et se positionnent au dessus d'eux (figure 10). Seules les boules sont enlevées après une séance d'acquisitions, pour être remises en place lors de la suivante.



Figure 10 – Marquage des épis fusariés lors des acquisitions

3.2.3 Calendrier des acquisitions

Le récapitulatif des sorties d'acquisitions est présenté dans le tableau 6. La sortie du 15 juin complète celle du 14. Ces deux dates sont analysées ensemble par la suite. Les données collectées le 8 juillet sont aussi groupées avec celles du 7, puisque les acquisitions n'ont pas pu se terminer ce jour-là.

Tableau 6 – Informations relatives aux acquisitions d'image

Date	JAI	Bloc(s) et capteur(s)	Météo
14/06/2021 matinée	3	2 : FX10, D5200	Ensoleillé, léger vent intermittent
15/06/2021 matinée	4	2 : FX17	Ensoleillé, faible voile nuageux, vent intermittent
29/06/2021 matinée	18	2 : FX10, FX17, D5200	Ensoleillé, vent et nuages intermittents
07/07/2021 journée	26	2 : FX10, FX17, D5200 Récolte tardive : FX10, FX17	Faiblement ensoleillé, vent régulier, nuages hétérogènes impliquant de nombreux reparamétrages
08/07/2021 après-midi	27	Récolte tardive : D5200	Ensoleillé, peu de nuages et de vent
20/07/2021 matinée	39	1 : FX10, FX17, D5200 Bordure : FX10, FX17, D5200	Ensoleillé, pas à peu de nuages, peu de vent

3.3 Traitements des images

L'analyse des images est conduite sous Python 3.8.8 à l'exception de l'entraînement des modèles pour les images hyperspectrales. Cette étape est réalisée sur les machines mises à disposition par le Consortium des Equipements de Calcul Intensif (CECI), sur lesquelles est installé Python 3.7.4. La chaîne de traitements (figure 11) est décrite dans les paragraphes qui suivent.

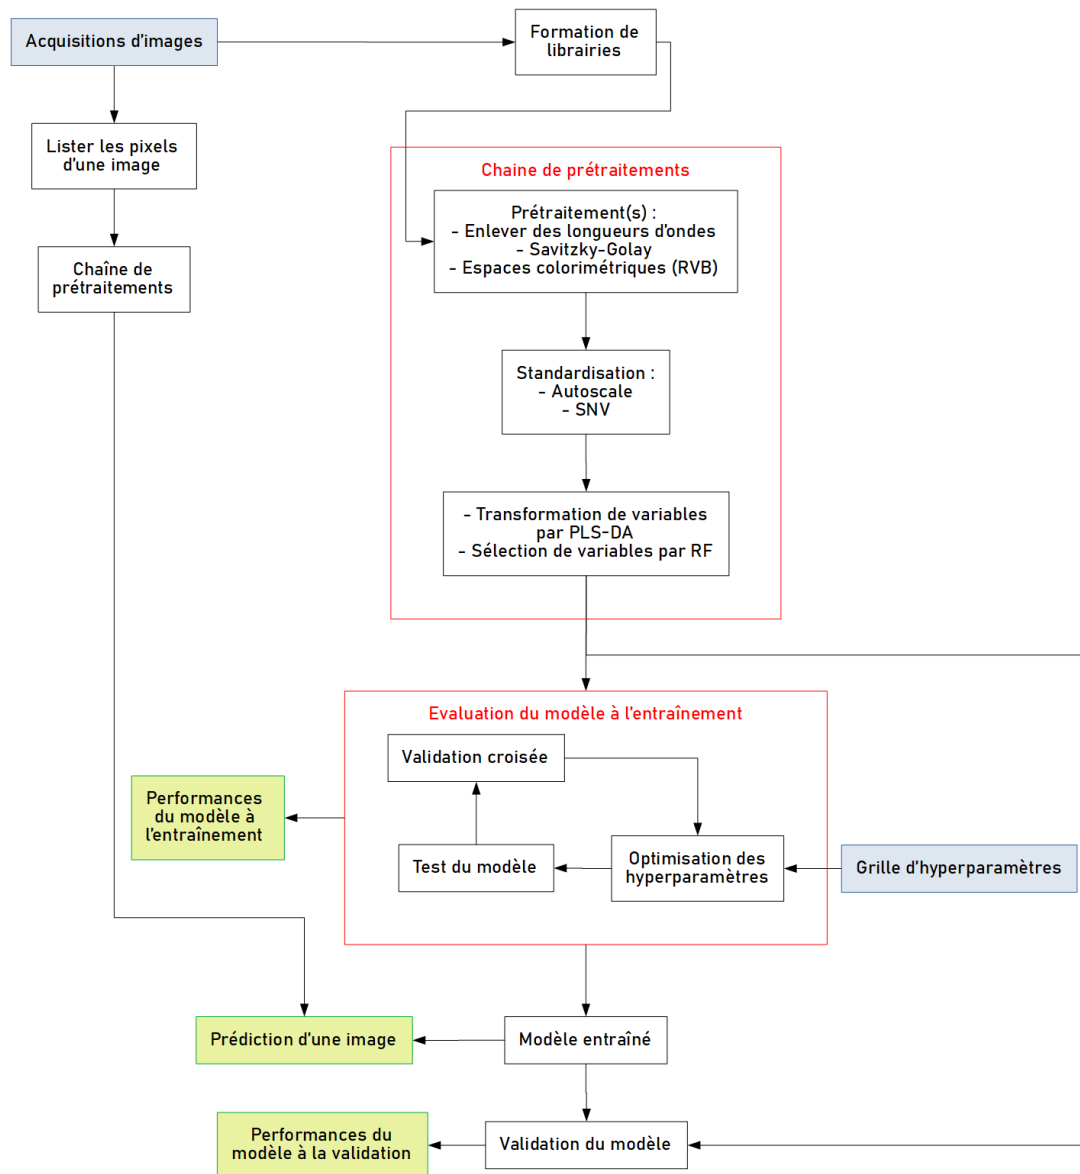


Figure 11 – Traitements d'images ; en bleu : les entrées et en vert : les sorties du processus

Parmi les quinze parcelles suivies pour l'expérimentation, cinq sont sélectionnées pour l'entraînement des modèles tandis que trois servent à la validation de ceux-ci. Initialement, des variétés présentant des niveaux de résistance variés sont placées dans chacun de ces groupes. Les cotations ont été menées par le CRA-W au cours des cinq dernières années. Leur valeur varie entre un et neuf et décrit le degré de résistance à la fusariose (plus le score est faible, plus la variété est sensible). Le tableau 7 reprend les variétés sélectionnées pour l'élaboration des bibliothèques. Les aléas (cfr tableau 4) qui ont modifié cette répartition pendant la saison culturale sont aussi incrits. Les parcelles de récolte tardive les moins attaquées par le champignon sont considérées comme étant les références saines pour l'acquisition du 26 dai.

Tableau 7 – Sélection des variétés pour la construction de bibliothèques d'entraînement (en vert) et de validation (en rouge) en fonction des événements survenus sur l'essai ; "Réc. tard." : récolte tardive, "Mi-versé" : faible verse qui permet les acquisitions si nécessaire

Variété	Cotation	Initial	A partir du 26 JAI		A partir du 38 JAI			
		Bloc 2	Bloc 2	Réc. tard.	Bloc 2	Bloc 1	Réc. tard.	Bordure
KWS Dorset	7,1		Versé	Versé	Versé	Versé	Versé	
KMS Extase	6,1						Versé	
KWS Keitum	5,9		Versé	Versé	Versé	Versé	Versé	
KWS Smart	7,3		Versé	Versé	Versé	Versé	Versé	
KWS Sverre	7,0		Versé	Versé	Versé	Versé	Versé	
LG Apollo	7,0				Mi-versé		Versé	
LG Keramik	4,5					Mi-versé	Versé	
LG Spotlight	6,3						Versé	
Porthus	7,7				Versé		Versé	
Positiv	5,7						Versé	
RGT Gravity	3,7						Versé	
RGT Perkussio	9,0				Mi-versé		Versé	
LG Skyscraper	5,8				Mi-versé		Versé	
Socade CS	7,9				Versé	Versé	Versé	
Solange CS	3,2				Versé	Versé	Versé	
Bordure								x3 x2

3.3.1 Annotation

Les modèles d'apprentissage automatique développés sont supervisés, c'est-à-dire qu'ils requièrent des données d'entraînement. Celles-ci sont contenues dans la dimension spectrale des images : les intensités RVB dans le cas des images couleurs ou le spectre pour les acquisitions hyperspectrales. Une des catégories suivantes est attribuée en certains pixels des images, indiquant ce que l'information spectrale contenue en ce point représente :

1. épi sain : épi provenant des images acquises dans les microparcelles saines
2. épi fusarié : épi identifié comme étant malade
3. matériel végétal : autre organe du froment (feuilles et tige), pouvant a priori présenter des caractéristiques similaires aux épis
4. autre : restant des éléments qui peuvent apparaître sur les images mais qui n'appartiennent pas aux catégories ci-dessus. Ils diffèrent a priori suffisamment des épis que pour ne pas interférer dans les discriminations (comme par exemple le sol et les boules de polystyrène)

Le travail d'annotation est réalisé manuellement. La photo capturée (dans le cas des images RVB) ou une image fausses-couleurs (dans le cas des acquisitions hyperspectrales) sert d'intermédiaire pour rendre cette tâche plus aisée. Les longueurs d'onde utilisées pour les matrices rouge, verte et bleue sont respectivement 680, 562 et 482 nm pour FX10 et 986, 1076 et 1166 nm pour FX17. Une représentation de ces images est présentée à la figure 12. L'information spectrale des pixels annotés est enregistrée dans deux fichiers différents. La bibliothèque "segmentation" regroupe les deux classes épis pour n'en former qu'une, alors nommée "épi", peu importe leur état de santé. Les deux dernières catégories sont ensuite ajoutées à ce jeu de données. Il a pour objectif de servir à la segmentation des épis présents sur les images. Le second fichier (bibliothèque "fusariose") comporte uniquement les deux classes épis, bien distinctes cette fois. Il est donc utile pour discriminer les épis contaminés de ceux en bonne santé. Ces fichiers se présentent sous la forme de tableau avec en premières colonnes, la classe et le numéro de classe du pixel annoté, et ensuite, l'information spectrale en ce point (figure 13).




Figure 12 – Affichages pour l’annotation de KWS Extase (images du 07/07/2021) ; le rapport hauteur/largeur original est respecté pour chaque image

Le perceptron multicouches (MLP) utilisé dans cette recherche (cfr section Modèles de discrimination) requiert un certain nombre de données lors de son entraînement (Soyeurt, 2019). Parmi ceux utilisés, cet algorithme est le plus contraignant sur cet aspect (les autres modèles n’ayant pas de prérequis connus). La quantité d’observations minimale est proportionnelle à la taille de ces réseaux de neurones. Elle permet d’estimer correctement les poids au sein de ceux-ci et peut être calculée par la relation suivante :

$$n_{obs} = 5 \cdot m \cdot (n + k)$$

avec :

- n_{obs} : nombre d’observations minimal
- m : le nombre de noeuds dans la couche cachée
- n : le nombre de noeuds dans la couche d’entrée
- k : le nombre de noeuds dans la couche de sortie

La taille des bibliothèques formées pour l’entraînement et la validation des modèles varie selon les séances d’acquisitions (tableaux 8 et 9 respectivement). Les premières valeurs seront justifiées dans la partie "Entraînement des modèles". Par la suite, le nombre d’informations spectrales intégré dans chacune des classes n’est plus constant. Sont en cause les faibles quantités de pixels pour la classe "épi fusarié". En effet, seuls deux ou trois épis sont marqués au champ pour chaque variété. Sur les images acquises, il faut que ceux-ci soient au premier plan (non cachés par un autre objet) et facilement reconnaissable sur l’image fausses-couleurs affichée pour l’annotation. En plus de cela, il faudrait qu’ils soient proches du système d’acquisition afin de bénéficier d’une meilleure résolution spatiale, offrant alors plus de pixels pour un même objet. Toutes ces contraintes ont provoqué la construction de jeux de données de taille inégale aussi bien entre les dates d’acquisitions qu’entre les différents capteurs utilisés. Les bibliothèques contiennent environ le même nombre d’observations dans chaque classe. Une exception est parfois accordée pour la catégorie "autre" lorsqu’il n’est pas possible d’intégrer plus de données pour atteindre le minimum requis.

Index	Class	class num	Rouge	Vert	Bleu
1	Epi	1	162	191	221
2	Epi	1	162	191	221
3	Epi	1	162	191	221
4	Epi	1	213	227	230
5	Epi	1	213	228	235
6	Epi	1	213	228	235
7	Materiel vegetal	3	81	121	68
8	Materiel vegetal	3	83	122	69
9	Materiel vegetal	3	85	124	71
15	Autre	4	168	164	127
16	Autre	4	168	163	125

(a) Librairie "segmentation"

Index	Class	class num	Rouge	Vert	Bleu
1	Epi	1	162	191	221
2	Epi	1	162	191	221
3	Epi	1	162	191	221
4	Epi fusarie	2	213	227	230
5	Epi fusarie	2	213	228	235
6	Epi fusarie	2	213	228	235

(b) Librairie "fusariose"

Figure 13 – Exemple de librairies pour une image RVB

Tableau 8 – Taille des librairies d'entraînement selon l'avancement de la saison

JAI	Capteur	Librairie	Nombre de données			
			Epi	Epi fusarié	Matériel végétal	Autre
3	FX10	segmentation	26 885		26 679	
	D5200	segmentation	29 894		29 795	12 046
4	FX17	segmentation	27 411		28 015	
18	FX10	segmentation	28 194		27 724	
	FX17	segmentation	27 872		27 440	
	D5200	segmentation	32 342		29 257	56 437
26	FX10	segmentation	18 343		15 480	3 357
	FX17	segmentation	18 856		15 638	5 085
	D5200	segmentation	31 197		31 885	15 967
	FX10	fusariose	899	899		
	FX17	fusariose	1 058	1 058		
	D5200	fusariose	15 844	15 353		
39	FX10	segmentation	15 245		14 980	3 934
	FX17	segmentation	15 990		15 087	3 736
	D5200	segmentation	20 986		21 125	16 091
	FX10	fusariose	419	419		
	FX17	fusariose	1 188	1 188		
	D5200	fusariose	10 394	10 592		

Tableau 9 – Taille des bibliothèques de validation selon l’avancement de la saison

JAI	Capteur	Bibliothèque	Nombre de données			
			Epi	Epi fusarié	Matériel végétal	Autre
3	FX10	segmentation	16 208		16 422	
	D5200	segmentation	20 359		21 193	176
4	FX17	segmentation	14 872		15 301	
18	FX10	segmentation	16 589		16 905	
	FX17	segmentation	16 331		15 908	
	D5200	segmentation	19 042		19 411	52 005
26	FX10	segmentation	12 775		9 370	946
	FX17	segmentation	12 292		10 189	1 759
	D5200	segmentation	17 967		20 456	10 069
	FX10	fusariose	196	196		
	FX17	fusariose	84	84		
	D5200	fusariose	10 304	7 663		
39	FX10	segmentation	9 976		9 761	1 604
	FX17	segmentation	10 302		8 905	2 339
	D5200	segmentation	9 153		9 198	9 073
	FX10	fusariose	116	116		
	FX17	fusariose	477	477		
	D5200	fusariose	3 638	3 638		

3.3.2 Prétraitements

A ce stade ci, les bibliothèques issues d’images différentes sont regroupées. Un seul jeu de données est ainsi constitué pour l’entraînement des modèles alors qu’un autre bien distinct est formé pour leur validation.

Cette étape permet de normaliser les données selon les deux dimensions du jeu de données. Ainsi, la standardisation de chaque variable retire la moyenne et divise par l’écart-type pour chaque colonne considérée séparément tandis que la variable standard normale (SNV) réalise la même opération pour chaque ligne. Pour les images hyperspectrales, cela permet aussi de supprimer un effet de pente dans le spectre et de faire ressortir les pics se superposant en utilisant une dérivée de Savitzky-Golay. Une autre bonne pratique concernant ces images est de supprimer quelques longueurs d’onde extrêmes, souvent très bruitées. En ce qui concerne les images couleurs, les prétraitements permettent d’explorer d’autres espaces colorimétriques : le RVB normalisé, le HSV et le YCrCb (luminance, chrominance rouge, chrominance bleue). Pour plus d’informations sur ces espaces colorimétriques, le lecteur est référé au site "LearnOpenCV". Finalement, le nombre de variables explicatives peut être réduit par deux algorithmes différents : soit en sélectionnant les variables les plus importantes dans un modèle RF, soit en ne gardant que quelques variables latentes dans une PLS-DA.

Ces prétraitements peuvent être combinés entre eux du moment qu’ils respectent le type de données (hyperspectrale ou couleurs) passé en entrée. Ainsi, seul le calcul d’autres espaces colorimétriques suivi d’une standardisation de chaque variable est réalisé pour les données RVB. Pour les bibliothèques hyperspectrales, quatre prétraitements sont systématiquement appliqués :

- Retirer les cinq longueurs d’onde extrêmes et ensuite normaliser chaque variable
- Retirer les cinq longueurs d’onde extrêmes, suivi d’un SNV
- Appliquer un filtre de Savitzky-Golay (fenêtre de cinq longueurs d’onde, polynôme du second degré, dérivée première) avant de normaliser chaque variable
- Appliquer un filtre de Savitzky-Golay (paramètres identiques) et puis un SNV

Le prétraitement le plus approprié est évalué grâce aux performances obtenues lors de la validation des modèles. Le meilleur d’entre eux est gardé et une réduction de variables est alors opérée. Deux nouveaux jeux

de données sont ainsi formés en ajoutant pour le premier une transformation de variables via une PLS-DA et pour le second une sélection de variables via une RF. Ces deux prétraitements supplémentaires indiquent si des modèles plus parcimonieux permettent d'atteindre des performances semblables à ceux entraînés sur l'entièreté du spectre acquis. Le nombre de variables latentes gardées dans le nouveau jeu de données est évalué par une validation croisée stratifiée en 5 groupes. Il est souvent égal au nombre de classes à prédire ou ce chiffre augmenté d'une unité. La RF sélectionnant les longueurs d'onde est construite avec ses paramètres par défaut (cfr Scikit-learn).

3.3.3 Détection des valeurs aberrantes

Les valeurs aberrantes au sein des jeux de données sont des valeurs erronées qui pourraient survenir suite à un défaut lors de l'acquisition ou à une mauvaise annotation. Il est donc utile de vérifier que les pixels appartenant à une même classe sont suffisamment semblables. Ceci peut être chiffré au moyen de la distance de Mahalanobis. Elle se calcule sur les composantes principales (issues d'une analyse en composantes principales) dans le cas de variables corrélées, sinon directement sur les variables elles-mêmes. Cette dernière éventualité ne concerne que les images couleurs. En effet, les longueurs d'onde du rouge, vert et bleu sont supposées être suffisamment distinctes. Une valeur supérieure à cinq à la distance de Mahalanobis normalisée (ou distance globale H) témoigne de valeurs aberrantes. Si une grande quantité de pixels sont détectés comme tels au sein d'une classe, l'annotation est très probablement erronée et est par conséquent réitérée. Par contre, si peu des valeurs aberrantes sont présentes, elles peuvent être exclues ou non du jeu de données.

Pour les images hyperspectrales, la distance globale H est calculée sur les données prétraitées par une dérivée première suivie d'une standardisation des variables. Ceci permet d'éviter de trouver trop de valeurs erronées alors qu'elles résultent d'un simple effet de pente.

3.4 Modèles de discrimination

Plusieurs modèles supervisés sont envisagés, que ce soit pour la segmentation des images ou pour discriminer les épis fusariés des épis sains. L'analyse discriminante quadratique (QDA), sans hyperparamètres à optimiser, donne une idée des performances qu'il est possible d'atteindre. Ensuite, des modèles plus complexes comme la PLS-DA, la RF, le SVM linéaire, et le MLP sont mis en place. Tous ces modèles conviennent pour tous les types de données. Pour les bibliothèques hyperspectrales uniquement, le SAM vient s'ajouter à cette liste.

3.4.1 Entraînement des modèles

Certains modèles possèdent des paramètres permettant de contrôler leur entraînement, les hyperparamètres. Leurs valeurs (tableau 10) sont choisies de sorte à obtenir un compromis entre les performances proposées par les modèles et la durée nécessaire à leur apprentissage. Pour la PLS-DA, cela prend la forme d'une boucle itérative qui incrémente le nombre de variables latentes. Un arrêt automatique de l'incrémenter stoppe la recherche lorsque l'exactitude du modèle n'augmente plus durant l'ajout de dix variables latentes supplémentaires. En ce qui concerne la RF, le nombre d'individus minimal dans chaque branche est fixé à une seule valeur. Ce paramètre exprime le mieux le compromis décrit au début de ce paragraphe. En-dessous de cette valeur, les modèles sont de plus en plus performants, mais exigent d'autant plus de temps lors de leur entraînement. Il en est de même pour le nombre de variables envisagées à chaque séparation. Au niveau du SVM, puisque cet algorithme converge rapidement, un plus grand nombre de paramètres peut être testé. Ceci permet d'ajuster au mieux le modèle à un jeu de données particulier. Le MLP présente moins de valeurs pour son paramètre de régularisation mais, en contrepartie, il essaie différentes tailles de groupe pour les optimisateurs stochastiques. Les valeurs des hyperparamètres sont choisies pour être autour de celles proposées par défaut par Scikit-learn. Par la suite, les valeurs retenues lors des entraînements des premiers modèles sont relevées. Si elles sont sys-

tématiquement trop proches des limites explorées, une nouvelle gamme plus adaptée remplace l'ancienne. Les modèles sont alors à nouveau entraînés.

Tableau 10 – Algorithmes de discrimination ; min : minimum, n_var : nombre de variables, n_obs : nombre d'observations

Algorithme	Hyperparamètres	Valeurs
QDA	/	/
PLS-DA	n : nombre de variables latentes	n = 1 à min(n_var, n_obs)
SAM	/	/
RF	s : nombre d'individus minimal dans chaque branche m : nombre maximal de variables à considérer à chaque séparation	s = 10 m = $\lceil \sqrt{n_var}, n_var/5 \rceil$
SVM	c : paramètre de régularisation	c = [0.01, 0.1, 0.5, 1, 2, 10, 25, 50, 100]
MLP	a : paramètre de régularisation b : taille des groupes pour les optimiseurs stochastiques	a = [0.00001, 0.0001, 0.001] b = [200, 500, 1000]

L'architecture des MLPs est assez simple. Les couches d'entrées et de sorties comportent autant de noeuds que de variables explicatives et de classes, respectivement. Une seule couche intermédiaire est insérée, avec le même nombre de noeuds que la couche d'entrée. Cette structure détermine donc le nombre de données nécessaires à l'entraînement des modèles (cfr section "Annotation"). Ainsi, lorsque cinq longueurs d'onde sont retirées à chaque extrémité du spectre et que deux classes sont à prédire, un MLP entraîné sur des images de FX17 nécessiterait 26 520 observations par classe. L'équivalent pour FX10 en demanderait 115 560. Cette quantité est trop importante pour être mise en place ; il faudrait alors beaucoup plus d'images ou une meilleure résolution spatiale. Par conséquent, les bibliothèques formées ont environ 26 500 spectres par catégorie, quelque soit le capteur hyperspectral. Pour les images RVB, c'est le problème inverse qui se pose. Annoter quelques objets fait rapidement grimper le nombre d'observations, à cause de leur résolution spatiale. Ainsi, il est commun d'atteindre une taille de bibliothèque équivalente à celles des images hyperspectrales, alors que seulement 420 données par classe seraient suffisantes.

L'évaluation des performances de chaque modèle lors de son apprentissage se fait par une validation croisée (CV) en 5 groupes. Cette dernière est dite stratifiée car les observations au sein d'une classe sont réparties équitablement dans chacun des groupes. Pour chaque itération, les meilleurs hyperparamètres sont estimés grâce à une recherche exhaustive. Celle-ci est également sujette à une CV stratifiée en 5 groupes. Ce mode de fonctionnement permet d'évaluer la stabilité des performances des modèles tout en séparant bien les jeux de calibration et de validation utilisés dans ces calculs. Finalement, le modèle définitif est entraîné sur l'entièreté des données à disposition. L'optimisation de ses hyperparamètres est réalisée toujours via la même validation croisée.

3.4.2 Validation des modèles

Afin d'évaluer la performance des algorithmes, ceux-ci sont validés sur une bibliothèque indépendante. Ces données de validation suivent le même processus de prétraitements que celui appliqué sur la bibliothèque d'entraînement. L'exactitude des modèles sert de référence pour comparer les prétraitements ainsi que les algorithmes entre eux. Eventuellement, dans le cas de la segmentation d'images, le nombre de pixels d'épi qui sont correctement prédits en tant que tel permet de compléter la comparaison.

Puisque ce sont les mêmes observations initiales qui servent à la validation des modèles, il est possible de comparer la qualité de leurs prédictions grâce au test de McNemar (McNemar, 1947). Ce dernier est mis en place lorsqu'il est intéressant de savoir si deux modèles sont significativement différents l'un de l'autre. Il ne s'applique cependant qu'aux prédictions présentant deux catégories différentes. L'hypothèse nulle de ce test est

l'égalité entre deux prédictions. Elle est rejetée lorsque la p-valeur obtenue est inférieure à 0,05. Cette dernière est déterminée grâce à une table Chi-carré avec un degré de liberté (annexe 15).

A ce stade, la réduction du nombre de variables est envisagée. En effet, le meilleur prétraitement n'est défini que lors de la validation. Comme expliqué précédemment (cfr partie "Prétraitements"), deux nouveaux jeux de données sont formés en combinant le prétraitement retenu avec une transformation de variables par PLS-DA ou avec une sélection de variables par RF.

3.4.3 Prédiction d'images

L'attribution d'une classe à chaque pixel d'une image est un moyen plus visuel de vérifier la qualité des modèles. Cela consiste premièrement à transformer les deux dimensions spatiales des images pour n'en obtenir qu'une seule. Cet artifice simplifie l'application des prétraitements. Cette liste d'informations spectrales est alors soumise au modèle pour prédiction. Finalement, l'image en deux dimensions est reconstruite et une couleur est attribuée pour chaque classe.

4 Résultats et discussion

4.1 Etablissement des paramètres pour le filtre de Savitzky-Golay

De nombreux prétraitements différents sont appliqués sur les premières images collectées. Ils permettent de tester plusieurs valeurs de taille de fenêtre et d'ordre de dérivée pour le filtre de Savitzky-Golay. Les meilleurs paramètres sont conservés pour la suite des analyses, afin d'économiser les ressources.

Pour FX10, les résultats détaillés de ce test sont présentés à l'annexe 25. Afin de fixer les paramètres retenus pour les traitements suivants, les moyennes et écart-types des exactitudes des modèles sont comparés (tableau 11). Au plus la moyenne est élevée et l'écart-type est petit, au mieux cette combinaison de paramètres convient pour l'ensemble des modèles testés. Ces résultats indiquent qu'une fenêtre de cinq points avec une dérivée première conviennent globalement pour les données acquises avec FX10.

	sg51_auto	sg51_snv	sg52_auto	sg52_snv
Moyenne	0,8892	0,8932	0,8635	0,8777
Ecart-type	0,0890	0,0955	0,1022	0,0937
	sg71_auto	sg71_snv	sg72_auto	sg72_snv
Moyenne	0,8480	0,8738	0,8707	0,8420
Ecart-type	0,1553	0,1266	0,1008	0,1519
	sg91_auto	sg91_snv	sg92_auto	sg92_snv
Moyenne	0,8613	0,8614	0,8608	0,8495
Ecart-type	0,1336	0,1532	0,1224	0,1462

Tableau 11 – Moyennes et écart-types des exactitudes des modèles selon le prétraitement - FX10 - 3 JAI; sgXY : dérivée de Savitzky-Golay d'ordre Y sur une fenêtre de X données, auto : standardisation des variables (moyenne nulle et écart-type unitaire), snv : standardisation des observations (moyenne nulle et écart-type unitaire), les prétraitements séparés par un "_" sont appliqués successivement de gauche à droite

La même analyse est conduite sur FX17. Les résultats complets sont décrits à l'annexe 26 et la comparaison des prétraitements est donnée au tableau 12. Cette fois, deux tailles de fenêtre différentes peuvent être envisagées (cinq et neuf) avec une dérivée d'ordre un. Pour éviter des confusions avec FX10 lors du traitement manuel des jeux de données, la fenêtre de cinq longueurs d'onde est choisie pour la suite des analyses.

	sg51_auto	sg51_snv	sg52_auto	sg52_snv
Moyenne	0,9362	0,8530	0,9307	0,8167
Ecart-type	0,0768	0,1478	0,0667	0,1585
	sg71_auto	sg71_snv	sg72_auto	sg72_snv
Moyenne	0,9241	0,8480	0,9027	0,8307
Ecart-type	0,1047	0,1526	0,1345	0,1549
	sg91_auto	sg91_snv	sg92_auto	sg92_snv
Moyenne	0,9293	0,8535	0,9426	0,8350
Ecart-type	0,0932	0,1479	0,0516	0,1540

Tableau 12 – Moyennes et écart-types des exactitudes des modèles selon le prétraitement - FX17 - 4 JAI

4.2 Segmentation des images

La première étape de l'analyse d'images est l'isolation des épis. La librairie "segmentation" est utilisée pour l'entraînement des modèles, tel que décrit dans la partie "Annotation". Les données de chacune des séances d'acquisitions sont traitées séparément. Celles des 3 et 4 JAI sont cependant regroupées pour comparer les trois capteurs dès les premiers jours après les inoculations.

4.2.1 3 et 4 JAI

Dès le début de la saison, les modèles parviennent à segmenter correctement les épis pour les images hyperspectrales (annexes 27 et 28). Ils ont plus de difficultés quand il s'agit des images couleurs (annexe 29).

Globalement, tous les modèles à l'exception du SAM atteignent une exactitude de 90 % pour FX10, quelque soit le prétraitement. Les réductions du nombre de variables ne permettent pas d'atteindre les mêmes performances que celles proposées sur l'ensemble des longueurs d'onde acquises. Le jeu de données dépourvus des valeurs aberrantes donne des résultats très semblables au jeu de données complet. Le MLP entraîné sur les données prétraitées par Savitzky-Golay suivi d'un SNV est le modèle le plus adapté. Il est significativement différent du SVM proposé pour le même prétraitement mais ce n'est pas le cas vis-à-vis du MLP sans les valeurs aberrantes (tableau 13). Le capteur FX17 avoisine l'efficacité proposée par FX10. Le meilleur modèle est également le MLP (justesse de 98 %). L'élagage des cinq longueurs d'onde extrêmes suivi d'une standardisation des longueurs d'onde donne la meilleure justesse à ce modèle. Les performances ne sont de nouveau pas aussi élevées lorsque le nombre de variables est plus faible. Comme pour FX10, le MLP dont les valeurs erronées sont retirées n'est pas significativement différent du modèle entraîné sur le jeu de données complet (tableau 14). Le MLP est une fois de plus utile en ce début de saison, puisque c'est encore ce modèle qui performe le mieux pour les images RVB (exactitude de 80 %).

Modèle 1	Modèle 2	Valeur	p-valeur
MLP sg51_auto	MLP sg51_auto_ab	0,716	> 0,1
MLP sg51_snv	SVM sg51_snv	11,560	< 0,01

Tableau 13 – Tests de McNemar - FX10 - 3 JAI; ab : jeu de données dépourvus de valeurs aberrantes, ret5 : retirer cinq longueurs d'onde extrêmes

Modèle 1	Modèle 2	Valeur	p-valeur
MLP sg51_auto	MLP sg51_auto_ab	3,447	> 0,05
MLP ret5_auto	MLP sg51_auto	6,153	< 0,05

Tableau 14 – Tests de McNemar - FX17 - 4 JAI

Suite aux observations concernant les valeurs aberrantes, les distances de Mahalanobis ne sont plus calculées par la suite. Il n'y a donc plus de détection concernant ces valeurs erronées, ce qui permet d'économiser les ressources.

Des images des segmentations pour chacun des appareils sont présentées à l'annexe 16. Globalement, les épis sont bien identifiés mais il y a quelques zones plus bruitées pour lesquelles il est plus difficile de savoir si la prédiction est correcte. La prédiction dans le VIS laisse supposer que quelques feuilles sont identifiées comme épis par le modèle.

4.2.2 18 JAI

A la fin du mois de juin, deux prétraitements avancent de très bonnes performances dans le VPIR : "ret5_snv" et "sg51_auto" (annexe 30). Les algorithmes les plus prometteurs sont le MLP et le SVM. Toutes

ces combinaisons sont égales d'un point de vue statistique, excepté le SVM entraîné sur la dérivée de Savitzky-Golay (tableau 15). Les modèles plus parcimonieux ne parviennent pas aux mêmes justesses, bien que ceux-ci soient adéquats (exactitude de 98 %). Pour le PIR, deux prétraitements se démarquent à nouveau : "ret5_auto" et "sg51_auto" (annexe 31). Le MLP entraîné sur ce premier prétraitement est significativement différent du MLP et du RF du second. Les modèles avec sélections de variables atteignent presque les mêmes exactitudes mais sont significativement moins performants (tableau 16). Le MLP fait encore une fois ses preuves sur les images de l'appareil photo numérique. Il propose en effet une segmentation des épis exacte à plus de 93 % (annexe 32).

Modèle 1	Modèle 2	Valeur	p-valeur
MLP ret5_snv	MLP sg51_auto	3,012	> 0,05
SVM ret5_snv	MLP sg51_auto	1,860	> 0,1
MLP ret5_snv	SVM ret5_snv	0,161	> 0,1
MLP sg51_auto	SVM sg51_auto	4,083	< 0,05

Tableau 15 – Tests de McNemar - FX10 - 18 JAI

Modèle 1	Modèle 2	Valeur	p-valeur
MLP ret5_auto	MLP sg51_auto	4,377	< 0,05
MLP ret5_auto	RF sg51_auto	6,209	< 0,05
MLP sg51_auto	RF sg51_auto	0,251	> 0,1
MLP ret5_auto	MLP ret5_auto_rf	39,459	< 0,05

Tableau 16 – Tests de McNemar - FX17 - 18 JAI; rf : sélection de variables par RF

Les prédictions de ces modèles sont illustrées à l'annexe 17. Les mêmes remarques que pour la première sortie sur le terrain semblent être d'application, mais avec un peu moins de feuilles identifiées comme épis pour les images couleurs.

4.2.3 26 JAI

Presqu'un mois après les inoculations, les modèles entraînés sur FX10 et FX17 sont similaires en terme de performance. Les 99 % d'exactitude sont presque atteints des deux cotés (annexes 33 et 34).

Pour le VPIR, le prétraitement "ret5_auto" est le plus adapté lorsqu'il est combiné à un MLP. Il est significativement différent du MLP "sg51_auto", proposant la deuxième meilleure valeur de justesse (tableau 17). Dans le PIR par contre, c'est le prétraitement "ret5_snv" qui permet d'atteindre la valeur d'exactitude la plus élevée, lorsque ce jeu de données est utilisé pour entraîner une PLS-DA. Le deuxième meilleur modèle est aussi une PLS-DA, avec le prétraitement "sg51_snv". Il se révèle cependant statistiquement différent du premier (tableau 18).

Finalement, une QDA présente les meilleures performances (exactitude de 87 %) sur des acquisitions couleurs (annexe 35). A titre de comparaison, Zhang et al. (2019) segmentent les épis plus efficacement grâce à leur réseau de neurones convolutionnel : leur modèle atteint une justesse de 98 % à ce stade. De leur côté, Qiu et al. (2019) comparent le nombre d'épis identifiés par leur réseau de neurones profond et leur comptage de référence. Le R^2 proposé par leur algorithme est de 92 %.

Modèle 1	Modèle 2	Valeur	p-valeur
MLP ret5_auto	MLP sg51_auto	35,919	< 0,05

Tableau 17 – Test de McNemar - FX10 - 26 JAI

Comme mentionné dans le tableau 6, les conditions extérieures variaient beaucoup durant cette séance d'acquisitions. Il était donc nécessaire de changer à plusieurs reprises le temps d'intégration, la fréquence

Modèle 1	Modèle 2	Valeur	p-valeur
PLS-DA ret5_snv	PLS-DA sg51_snv	20,529	< 0,01

Tableau 18 – Test de McNemar - FX17 - 26 JAI

d'images et la vitesse de rotation des systèmes de vision hyperspectrale. Les hypercubes ayant contribué à la formation des bibliothèques de spectres diffèrent donc à ce niveau. Il semblerait néanmoins que cela ne perturbe pas les modèles, qui apparaissent donc comme robustes face aux changements de luminosité ambiante.

En annexe 18 figure les segmentations pour une microparcelle "saine". La fusariose ayant contaminé l'entièreté de l'essai, il y a un doute quant à l'état sanitaire des blocs non inoculés. L'annexe 19 montre les segmentations pour une microparcelle inoculée. Ces prédictions souffrent d'un problème de distinction entre les feuilles et les épis au niveau des images RVB. Les acquisitions hyperspectrales témoignent de la présence de vent : les épis quittent parfois leur apparence rectiligne au profit d'une forme en "S".

4.2.4 39 JAI

En continuant d'avancer dans la saison, le prétraitement "ret5_auto" reste le plus performant pour FX10, et il le devient aussi pour FX17 (annexes 36 et 37). Les deux meilleurs modèles sont le SVM suivi du MLP pour FX10. C'est l'inverse pour FX17. Ce classement n'est cependant pas interchangeable puisqu'à chaque fois, ils sont jugés statistiquement différents par le test de McNemar (tableaux 19 et 20). Le niveau de justesse atteint dans le VPIR vaut plus de 97 %. Celui du PIR est quant à lui au-dessus de 99 %. Finalement, le RVB plafonne à 73 %, avec pour meilleur modèle un MLP (annexe 38).

Modèle 1	Modèle 2	Valeur	p-valeur
MLP ret5_auto	SVM ret5_auto	13,563	< 0,01

Tableau 19 – Test de McNemar - FX10 - 39 JAI

Modèle 1	Modèle 2	Valeur	p-valeur
SVM ret5_auto	MLP ret5_auto	8,129	< 0,01

Tableau 20 – Test de McNemar - FX17 - 39 JAI

Les images segmentées sont présentées à l'annexe 20 pour la bordure "saine" et 21 pour la partie inoculée. La différence entre tige et épi est parfois confuse, surtout sur les acquisitions VIS et VPIR.

4.3 Détection de la fusariose

Une fois que les épis sont segmentés sur les images, il est possible de prédire s'ils sont fusariés ou non. Les bibliothèques "fusariose" sont mises à contribution pour cette tâche. Comme pour la segmentation, chacune des acquisitions est traitée séparément. Puisque les épis malades ont été marqués aux 21 et 25 JAI, l'annotation des images et l'entraînement de tels modèles n'ont pu être réalisés qu'à partir de ces dates.

4.3.1 26 JAI

La faible quantité de spectres disponibles (cfr section "Annotation") est sans doute à l'origine de la similitude entre les valeurs d'exactitude des modèles (annexes 39 et 40). Elles s'élèvent à près de 99 % dans le VPIR et sont encore supérieures dans le PIR. Ces résultats ne permettent pas de choisir un modèle ou un

prétraitement qui donne de meilleures performances que les autres. Il faut par conséquent appliquer ces modèles sur des images et comparer visuellement les prédictions entre elles.

Cette séance d'acquisitions est réalisée durant le développement des grains (stade principal 7 BBCH). Huang et al. (2020b) identifient cette période comme idéale pour la détection de la fusariose. L'algorithme le plus performant qu'ils conçoivent sur leurs spectres acquis dans le VPIR discrimine les épis sains des épis malades avec une exactitude de 75 %. Whetton et al. (2018), de leur côté, parviennent à faire monter ce chiffre jusqu'à 82 %. Jin et al. (2018) discriminent également les épis à partir de ce stade et dans le VPIR, mais avec un algorithme d'apprentissage profond. L'exactitude de ce dernier est de 74 %. Zhang et al. (2020b) mènent une étude très similaire mais prédisent la sévérité de la maladie avec un R^2 de 97 %.

Les performances des modèles pour les images couleurs sont quant à elles bien différentes (annexe 41). La QDA est le modèle proposant la meilleure justesse (de plus de 92 %) pour distinguer les épis sains des épis fusariés. Zhang et al. (2019) obtiennent la même exactitude avec leur réseau de neurones. Finalement, Menesatti et al. (2013) parviennent à une justesse de 84 % grâce à leur PLS-DA. Ils utilisent des images hyperspectrales dans la gamme du VIS pour ce faire.

Plusieurs prédictions pour la détection de la fusariose sont proposées. Les annexes 22 et 23 mettent en avant les images prédites avec le MLP "ret5_snv" pour FX10 et avec le MLP "ret5_auto" pour FX17, respectivement pour le bloc sain et inoculé. D'autres modèles sont illustrés dans les annexes 24 et 25. Ces images témoignent bien que, malgré des exactitudes de modèles identiques lors de la validation, ceux-ci sont bien différents. Cela pourrait confirmer l'hypothèse à propos de la taille du jeu de données de validation. Il est donc difficile d'opter pour un modèle en particulier. Ces prédictions visuelles semblent indiquer que les librairies utilisées pour l'apprentissage des modèles étaient correctes. En effet, à cette date, le champignon s'est répandu sur l'entièreté du champ (cfr tableau 4). Il y a donc un risque que des épis malades soient renseignés comme étant sains dans les librairies. Si cette erreur avait été commise, les modèles auraient présenté des difficultés à identifier la fusariose et les images auraient été plus bruitées.

Les erreurs de segmentations sur les images couleurs sont bien visibles puisqu'il semblerait que les feuilles soient prédites en tant qu'épis malades. D'après les prédictions, très peu d'épis présentent signes de maladie, pour le bloc non inoculé. Il est quand même possible d'avoir de la fusariose dans ces microparcelles puisque le champignon s'est répandu sur l'entièreté du champ (cfr tableau 4). Pour le bloc inoculé, il est possible de distinguer une dizaine d'épis fusariés. Le lendemain de la prise d'images, une équipe a dénombré 53 épis contaminés. Les modèles semblent donc loin de cette valeur ; cette différence sera discutée dans la partie "Perspectives".

4.3.2 39 JAI

Les modèles de détection de la fusariose dans le VPIR atteignent presque 85 % d'exactitude un peu plus d'un mois après les inoculations. Le prétraitement qui met le plus en valeur les données est "sg51_snv", avec une PLS-DA et un SVM comme meilleurs modèles (annexe 36). Pour la première fois, une sélection de variable par RF permet d'améliorer la qualité de la discrimination. Le MLP franchit la barre de 86 % lorsqu'il est entraîné sur ce jeu de données. Cela s'explique peut-être par la diminution notable du nombre de longueurs d'onde (de 224 à 48), réduisant alors la taille du réseau (cfr section "Entraînement des modèles"). Le nombre d'observations dans la librairie n'est certes pas suffisant (cfr partie "Annotation"), mais cela permet de réduire l'écart entre ce que le perceptron demande et ce qui est disponible.

Le PIR propose des valeurs supérieures au VPIR, en atteignant une exactitude de 89 % pour la PLS-DA entraînée sur les données "sg51_auto" (annexe 43).

Les modèles appliqués sur les images couleurs présentent des performances semblables à celles du VPIR. Le MLP permet d'atteindre une exactitude de plus de 86 % (annexe 44).

Les annexes 26 et 27 présentent les prédictions concernant la détection de la fusariose, respectivement pour la bordure et le bloc inoculé. La bordure semble plutôt saine pour les capteurs hyperspectraux alors que la

prédiction RVB indique quelques épis malades. La prédiction dans le PIR présente beaucoup de bruit, certainement provoqué lors de l'acquisition de l'image. Il semblerait que le bloc inoculé soit quant à lui ravagé par le champignon, bien que cela soit difficile à prouver.

4.4 Comparaison temporelle des capteurs

Chaque séance d'acquisitions a été passée en revue indépendamment dans les sections précédentes. La combinaison prétraitement-modèle donnant le meilleur résultat pour chaque appareil est retenue pour chaque date. Le graphique à la figure 14 présente l'évolution de l'exactitude de la segmentation des épis pour chaque capteur au cours de la saison. Une interpolation quadratique est proposée comme estimation entre les dates d'acquisitions. La sortie du 4 JAI est décalée au 3 JAI pour simplifier la représentation.




Figure 14 – Exactitudes des modèles de segmentation selon le capteur au cours de la saison

La distinction entre les épis et les autres organes du froment est réalisée au mieux dans le VPIR durant le premier mois après les inoculations. Cela correspond aux stades principaux 6 et 7 de l'échelle BBCH. Une fois que les épis deviennent jaunâtres (stade 8 BBCH), il est préférable de se tourner vers le PIR. L'utilisation d'un appareil photo numérique est une solution moins performante que les systèmes de vision hyperspectrale, mais il présente toutefois des résultats corrects, surtout en début de saison.

Les trois capteurs se différencient moins pour la détection de la fusariose (tableau 21). Le PIR est le domaine spectral qui permet de discriminer au mieux les épis sains des épis fusariés, bien que les deux autres technologies soient appropriées également.

	26 JAI	39 JAI
FX10	0,9898	0,8621
FX17	0,9940	0,8920
D5200	0,9270	0,8674

Tableau 21 – Exactitudes des modèles de détection de la fusariose selon les capteurs et la date d'acquisitions

Il apparaît que les solutions hyperspectrales sont plus performantes que l'imagerie couleurs. Cela peut s'expliquer par la différence de quantité et de qualité de l'information enregistrée par les capteurs. D'un côté, les systèmes de vision hyperspectrale découpent le spectre incident en de nombreuses bandes très fines alors que de l'autre, les trois filtres du capteur RGB sont sensibles à une plus large gamme de longueurs d'onde. Les modèles bénéficient d'une plus grande quantité de données, très précises, pour trouver la meilleure séparation possible dans le premier cas.

4.5 Solutions globales pour la segmentation des épis

Afin de simplifier les futures analyses d'images, un modèle de segmentation couvrant l'entièreté de la saison est proposé pour chaque capteur. Afin d'identifier la combinaison modèle-prétraitement optimale, les écarts entre l'exactitude la plus élevée et chacune des combinaisons est sommée pour toutes les dates d'acquisitions. La valeur la plus faible renvoie alors le modèle et le prétraitement présentant la meilleure performance, toutes séances d'acquisitions confondues. Pour FX10, il semblerait que cette combinaison soit le MLP avec "sg51_auto" (tableau 22); pour FX17, il s'agirait aussi du MLP, mais avec un jeu de données prétraité par "ret5_auto" (tableau 23). Il semble assez évident que pour le D5200, c'est le MLP qui permet de segmenter correctement les épis tout au long de la saison. Le tableau 24 quantifie l'écart d'exactitude qui réside entre les meilleurs performances et les MLP "sg51_auto" et "ret5_auto" pour chaque date d'acquisitions.

	ret5_auto	ret5_snv	sg51_auto	sg51_snv
MLP	0,0309	0,0293	0,0177	0,0226
PLS-DA	0,0395	0,0716	0,0434	0,0480
QDA	0,1615	0,2485	0,5708	0,5592
RF	0,1199	0,0620	0,1726	0,1462
SAM	1,4269	0,3926	0,6810	0,5998
SVM	0,0248	0,0284	0,0287	0,0356

Tableau 22 – Sommes des écarts entre le meilleur modèle et chaque combinaison de modèle-prétraitement pour FX10

	ret5_auto	ret5_snv	sg51_auto	sg51_snv
MLP	0,0224	0,1021	0,0358	0,0694
PLS-DA	0,0632	0,1082	0,0821	0,1211
QDA	0,4277	0,3138	0,4336	0,4765
RF	0,1271	0,1616	0,0605	0,1235
SAM	1,6145	1,3341	0,5950	1,1855
SVM	0,0615	0,1335	0,0719	0,1401

Tableau 23 – Sommes des écarts entre le meilleur modèle et chaque combinaison de modèle-prétraitement pour FX17

	3-4 JAI	18 JAI	26 JAI	39 JAI
FX10	-0,5363	0	-0,4417	-0,7965
FX17	0	0	-2,2382	0

Tableau 24 – Différences d'exactitude en pourcents entre le modèle global et le meilleur modèle pour chaque séance d'acquisitions

4.6 Comparaison avec les conditions contrôlées

Il est difficile de comparer ces résultats avec ceux présents dans la littérature à cause du faible nombre de publications sur le sujet. Les quelques études pertinentes s'éloignent rapidement de la recherche menée puisqu'elles mettent en place d'autres systèmes d'acquisition, d'autres capteurs, etc. et ne réalisent souvent qu'une collecte de données à une date précise. Les études les plus semblables ont déjà été discutées dans les sections précédentes. Il est aussi pertinent de mettre en perspective les résultats obtenus pour la détection de la fusariose en conditions non contrôlées avec ceux obtenus en laboratoire. Les développements du blé et du champignon n'évoluent pas aux mêmes rythmes entre ces milieux. Par conséquent, les informations temporelles ne sont pas comparables. Néanmoins, Alisaac et al. (2018) et Mahlein et al. (2019) témoignent de la même tendance : le VPIR et le SWIR combinés atteignent une exactitude maximale (respectivement 99 et 100 % pour ces auteurs) une dizaine de jours après l'inoculation, et ce pour une durée d'environ dix jours. En dehors de cette période, l'exactitude de leur SVM diminue progressivement. Ces résultats sont en phase avec ceux mis en avant précédemment. Dans le VPIR, le SVM optimisé de Huang et al. (2020a) atteint les 92 % d'exactitude. Leur méthode n'emploie cependant que des caractéristiques spectrales et colorimétriques.

5 Conclusions

Compte tenu des difficultés liées aux acquisitions d'image en milieu extérieur, la présente recherche propose des solutions pour segmenter les épis de froment et détecter la fusariose directement au champ. Trois appareils servent aux acquisitions d'image dans le VIS, le VPIR et le PIR respectivement. Plusieurs prétraitements sont appliqués sur les jeux de données et servent à entraîner six modèles différents.

Les deux gammes hyperspectrales parviennent à distinguer les épis des autres objets présents sur les images (feuilles, tiges, sol, etc.). Le VPIR atteint les 99,30 % d'exactitude au plus haut de ses performances (18 JAI). Le PIR le dépasse à peine en arrivant à 99,36 % 39 jours après les inoculations. Les deux systèmes sont en fait complémentaires puisqu'ils segmentent au mieux les épis à des périodes différentes. Le domaine VPIR assure cette tâche entre la fin de la première semaine après les inoculations jusqu'aux 26-27 JAI. Le PIR prend ensuite le relais au moins jusqu'à 38 JAI. Il faudrait davantage explorer les tous premiers jours et au-delà des cinq semaines après les inoculations pour définir le comportement de ces domaines en dehors de ces dates. L'appareil photo numérique performe moins bien que les capteurs hyperspectraux, en atteignant cependant une justesse de 93,88 % au même moment où le VPIR atteint son maximum. Elle chute néanmoins rapidement avant et après à cette date.

Parmi les modèles déployés, le perceptron multicouches est celui qui a le mieux performé pour la segmentation des épis. Si un seul modèle doit être envisagé pour couvrir toute la saison, il donne en effet les meilleurs résultats pour les trois capteurs. Le prétraitement à utiliser n'est quant à lui pas fixe. Les données prises par FX10 semblent mieux être mises en avant par une dérivée de Savitzky-Golay, alors que pour FX17, l'enlèvement des quelques longueurs d'onde de part et d'autre du spectre suffit. Une standardisation des longueurs d'onde est ensuite appliquée pour ces deux jeux de données, afin de les normaliser.

La fusariose est la mieux détectée par le capteur PIR (exactitude de 99,40 %) 26 jours après les inoculations. A cette même date, le VPIR le seconde de très peu (98,98 %) alors que le VIS ne dépasse pas les 87,02 %. Deux semaines plus tard, seule la valeur des acquisitions couleurs n'a que faiblement changé (86,74 %). Les domaines hyperspectraux se succèdent toujours dans le même ordre, avec des exactitudes valant 89,20 et 86,21 % respectivement. Il est beaucoup plus difficile d'identifier un modèle ainsi qu'un prétraitement uniques pour chaque système d'acquisition, puisque les valeurs maximales de justesse sont proposées par plusieurs d'entre-eux. Les images prédites pourraient aiguiller quant à ces choix, mais ceux-ci seraient alors subjectifs.

6 Perspectives

Pour éviter d'attribuer la mauvaise classe à un élément d'une image, seuls les objets bien reconnaissables sont entourés. Sur les acquisitions hyperspectrales principalement, il y a des régions plus sombres, présentant un ratio signal sur bruit plus faible. Ces zones ne sont par conséquent pas incluses dans les librairies. Elles se voient cependant attribuer une classe lors de l'application des modèles sur les images. C'est sans doute la raison pour laquelle les performances lors de la validation semblent élevées lorsque celles-ci sont comparées aux prédictions visuelles. Les régions les plus sombres ne sont pas les seules difficultés lors de la reconnaissance des objets. Comme mentionné précédemment, ce sont des images fausses-couleurs qui forment la référence pour l'annotation (cfr section "Annotation"). Sur celles-ci, les objets peuvent prendre des teintes similaires. Il ne reste alors que leur texture (l'arrangement spatial des intensités au sein d'une image) pour les différencier. Par exemple, une feuille est plutôt lisse (faibles variations d'intensité) là où les épis sont plus rugueux (variations plus importantes entre les grains). La résolution spatiale des systèmes de vision hyperspectrale rend également difficile cette étape de reconnaissance, surtout au-delà d'une certaine distance. La géométrie du système d'acquisition ne facilite pas non plus cette tâche. Elle confère aux capteurs un angle de vue qui entraîne une certaine superposition des objets au sein de la scène. Combiné avec les complications précédentes, cela n'aide pas à définir correctement les bordures des entités. Tous ces éléments rendent complexe l'étape d'annotation.

Initialement, le système d'acquisition est conçu pour offrir un angle de vue maximisant la surface visible des épis. En comparaison, la vue nadir (perpendiculaire au sol) ne voit que l'extrémité supérieure des épis, présentant beaucoup moins de pixels pour l'annotation de l'image. Le système déployé permet donc a priori d'obtenir plus d'observations pour la création de modèles. En pratique, la superposition des éléments impacte la taille des librairies formées, comme cela a déjà été discuté dans la section "Annotation". D'une certaine façon, la vue oblique, supposée permettre une meilleure annotation, la complique en partie également.

Une solution aux problèmes décrits dans les deux paragraphes précédents pourrait être l'utilisation de drones. Les capteurs y seraient suspendus avec un angle de vue oblique. En survolant les microparcelles, ils permettraient aux systèmes de vision de se situer à une distance approximativement constante des épis. Ceci pourrait régler les soucis liés à la résolution spatiale variable au sein des images. Il y aurait aussi moins d'objets superposés. Une plus grande quantité de données serait alors disponible pour l'annotation des images.

Les conditions météorologiques rencontrées depuis le début du mois de juin ont déterminé la fréquence et les dates des sorties sur le champ. Selon l'Institut Royal Météorologique (2021), les sixième et septième mois de 2021 ont compté 14 et 17 jours de pluies respectivement. A cela, il faut ajouter les dates auxquelles le terrain est impraticable à cause de ces précipitations. Finalement, les journées trop nuageuses ou trop venteuses sont évitées car elles sont contraignantes au niveau des acquisitions hyperspectrales. Les quelques opportunités restantes ont été saisies mais un suivi plus régulier de l'évolution du développement de l'épi et de la fusariose permettrait d'affiner le choix du capteur en fonction de l'avancement de la saison. Pour la segmentation, une séance d'acquisition autour des 10 JAI permettrait de confirmer que le VPIR est préférable au PIR pour la première partie de la saison. Il faudrait aussi explorer le comportement des capteurs dès l'inoculation et juste avant la moisson. Cela permettrait aux agriculteurs d'appliquer une protection fongicide de manière raisonnée dans le premier cas ou d'écarter la récolte contaminée dans le second.

Dans le cadre de ce travail, la taille des librairies est relativement importante. Il semblerait néanmoins qu'il soit possible d'atteindre des résultats convenables avec une plus faible quantité d'observations. C'est ce qui est démontré par les dernières acquisitions. Il serait utile de quantifier la perte en qualité des modèles face à des librairies toujours plus petites. En effet, il y a un équilibre à trouver entre les performances d'un modèle et le temps consacré à l'annotation des images. L'entraînement des modèles gagnerait aussi en rapidité puisqu'il est ajusté sur moins d'observations. Il y a un gain en temps et en quantité d'énergie dépensée qu'il serait intéressant de mettre en relation face à la qualité de la prédiction qu'il est possible d'atteindre.

Réduire le nombre de longueurs d'onde présentes dans les bibliothèques permettrait aussi de diminuer le nombre de données nécessaires à l'apprentissage des modèles. Ceci peut être concrétisé par les sélections de variables opérées par la RF et la PLS-DA. Les algorithmes entraînés sur ces données présentent globalement des performances plus faibles, mais elles restent de très bonne qualité. Les longueurs d'onde sélectionnées par ces méthodes pourraient alors servir à l'élaboration d'un système d'acquisition multispectrale. Celui-ci présenterait l'avantage d'acquérir plus rapidement des images puisqu'il enregistre moins d'informations spectrales. Il contribuerait à l'entraînement de modèles plus petits, offrant un temps d'apprentissage plus court et surtout un gain de temps lors de l'étape d'annotation.

D'autres modèles peuvent être explorés pour répondre aux tâches de segmentation des épis et d'identification de la fusariose. Le réseau de neurones identifié comme solution potentielle pour répondre à ces problématiques est d'une simplicité exemplaire. D'autres architectures peuvent être envisagées, pour faire varier aussi bien le nombre de couches intermédiaires que le nombre de nœuds au sein de celles-ci. Des variations des algorithmes pourraient également améliorer les résultats. Par exemple, le SVM déployé ici propose des séparations linéaires entre les classes à cause de son noyau linéaire ; peut-être que des séparations non linéaires conduiraient à de meilleurs résultats (notamment grâce au noyau à fonction de base radiale, par exemple).

7 Bibliographie

- Alisaac E., Behmann J., Kuska M. T., Dehne H. W. et Mahlein A. K. 2018, «Hyperspectral quantification of wheat resistance to Fusarium head blight : comparison of two Fusarium species», *European Journal of Plant Pathology*, vol. 152, n° 4, doi : 10.1007/s10658-018-1505-9, pp. 869–884, ISSN 15738469.
- Barbedo J. G., Tibola C. S. et Fernandes J. M. 2015, «Detecting Fusarium head blight in wheat kernels using hyperspectral imaging», *Biosystems Engineering*, vol. 131, doi : 10.1016/j.biosystemseng.2015.01.003, pp. 65–76, ISSN 15375110.
- Bateman G. L., Gutteridge R. J., Gherbawy Y., Thomsett M. A. et Nicholson P. 2007, «Infection of stem bases and grains of winter wheat by Fusarium culmorum and F. graminearum and effects of tillage method and maize-stalk residues», *Plant Pathology*, vol. 56, n° 4, doi : 10.1111/j.1365-3059.2007.01577.x, pp. 604–615, ISSN 00320862.
- Bauriegel E., Giebel A., Geyer M., Schmidt U. et Herppich W. B. 2011a, «Early detection of Fusarium infection in wheat using hyper-spectral imaging», *Computers and Electronics in Agriculture*, vol. 75, n° 2, doi : 10.1016/j.compag.2010.12.006, pp. 304–312, ISSN 01681699. URL <http://dx.doi.org/10.1016/j.compag.2010.12.006>.
- Bauriegel E., Giebel A. et Herppich W. B. 2011b, «Hyperspectral and chlorophyll fluorescence imaging to analyse the impact of fusarium culmorum on the photosynthetic integrity of infected wheat ears», *Sensors*, vol. 11, n° 4, doi : 10.3390/s110403765, pp. 3765–3779, ISSN 14248220.
- Bodson B., De Proft M. et Watillon B., éd.. 2020, *Livre Blanc Céréales*, septembre 2020 éd., Université de Liège – Gembloux Agro-Bio Tech. URL <https://www.livre-blanc-cereales.be/wp-content/uploads/2020/12/LivreBlanc-sept-2020.pdf>.
- Bodson B. et Watillon B., éd.. 2017, *Livre Blanc Céréales*, février 2017 éd., Université de Liège – Gembloux Agro-Bio Tech. URL <https://www.livre-blanc-cereales.be/wp-content/uploads/2017/02/LBfev2017.pdf>.
- Bolanos-Carriel C., Wegulo S. N., Baenziger P. S., Funnell-Harris D., Hallen-Adams H. E. et Eskridge K. M. 2020, «Effects of fungicide chemical class, fungicide application timing, and environment on Fusarium head blight in winter wheat», *European Journal of Plant Pathology*, vol. 158, n° 3, doi : 10.1007/s10658-020-02109-3, pp. 667–679, ISSN 15738469.
- Dammer K. H., Möller B., Rodemann B. et Heppner D. 2011, «Detection of head blight (Fusarium spp.) in winter wheat by color and multispectral image analyses», *Crop Protection*, vol. 30, n° 4, doi : 10.1016/j.cropro.2010.12.015, pp. 420–428, ISSN 02612194. URL <http://dx.doi.org/10.1016/j.cropro.2010.12.015>.
- De Wolf E., Shroyer J. P. et Olson B. 2011, «Wheat Disease Identification», Consulté le 02/02/2021.
- Delwiche S. R., Rodriguez I. T., Rausch S. R. et Graybosch R. A. 2019, «Estimating percentages of fusarium-damaged kernels in hard wheat by near-infrared hyperspectral imaging», *Journal of Cereal Science*, vol. 87, n° September 2018, doi : 10.1016/j.jcs.2019.02.008, pp. 18–24, ISSN 10959963. URL <https://doi.org/10.1016/j.jcs.2019.02.008>.
- Dumont B., De Proft M. et Watillon B., éd.. 2021, *Livre Blanc Céréales*, février 2021 éd., Université de Liège – Gembloux Agro-Bio Tech, 331 pp.. URL <https://www.livre-blanc-cereales.be/wp-content/uploads/2021/03/LB-fev-2021-Compleet-Internet.pdf>.

- European Commission. 2006, «Commission Regulation (EC) No 1881/2006 of 19 December 2006 setting maximum levels for certain contaminants in foodstuffs (Text with EEA relevance)», *Official Journal of the European Union*, vol. 49, pp. 5–24, ISSN 1725-2555.
- Figuroa M., Hammond-Kosack K. E. et Solomon P. S. 2018, «A review of wheat diseases—a field perspective», *Molecular Plant Pathology*, vol. 19, n° 6, doi : 10.1111/mpp.12618, pp. 1523–1536, ISSN 13643703.
- Food and Agriculture Organization of the United Nations. 2021, «FAOSTAT», URL <http://www.fao.org/faostat/en/#home>, consulté le 11/02/2021.
- He X., Zhao T., Shen F., Liu Q., Fang Y. et Hu Q. 2021, «Online detection of naturally DON contaminated wheat grains from China using Vis-NIR spectroscopy and computer vision», *Biosystems Engineering*, vol. 201, doi : 10.1016/j.biosystemseng.2020.11.001, pp. 1–10, ISSN 15375110. URL <https://doi.org/10.1016/j.biosystemseng.2020.11.001>.
- Hooker D. C., Schaafsma A. W. et Tamburic-Ilincic L. 2002, «Using weather variables pre- and post-heading to predict deoxynivalenol content in winter wheat», *Plant Disease*, vol. 86, n° 6, doi : 10.1094/PDIS.2002.86.6.611, pp. 611–619, ISSN 01912917.
- Huang L., Li T., Ding C., Zhao J., Zhang D. et Yang G. 2020a, «Diagnosis of the severity of fusarium head blight of wheat ears on the basis of image and spectral feature fusion», *Sensors (Switzerland)*, vol. 20, n° 10, doi : 10.3390/s20102887, ISSN 14248220.
- Huang L., Wu Z., Huang W., Ma H. et Zhao J. 2019, «Identification of fusarium head blight in winter wheat ears based on fisher's linear discriminant analysis and a support vector machine», *Applied Sciences (Switzerland)*, vol. 9, n° 18, doi : 10.3390/app9183894, ISSN 20763417.
- Huang L., Zhang H., Ruan C., Huang W., Hu T. et Zhao J. 2020b, «Detection of scab in wheat ears using in situ hyperspectral data and support vector machine optimized by genetic algorithm», *International Journal of Agricultural and Biological Engineering*, vol. 13, n° 2, doi : 10.25165/j.ijabe.20201302.5331, pp. 182–188, ISSN 19346352.
- Institut Royal Météorologique. 2021, «Bilans climatologiques de 2021», URL <https://www.meteo.be/fr/climat/climat-de-la-belgique/bilans-climatologiques/2021/juillet>, consulté le 04/08/2021.
- Jin X., Jie L., Wang S., Qi H. J. et Li S. W. 2018, «Classifying wheat hyperspectral pixels of healthy heads and Fusarium head blight disease using a deep neural network in the wild field», *Remote Sensing*, vol. 10, n° 3, doi : 10.3390/rs10030395, ISSN 20724292.
- Kamilaris A. et Prenafeta-Boldú F. X. 2018, «Deep learning in agriculture : A survey», *Computers and Electronics in Agriculture*, vol. 147, n° July 2017, doi : 10.1016/j.compag.2018.02.016, pp. 70–90, ISSN 01681699.
- Lancashire P. D., Bleiholder H., Boom T. V. D., Langelüddeke P., Stauss R., Weber E. et Witzemberger A. 1991, «A uniform decimal code for growth stages of crops and weeds», *Annals of Applied Biology*, vol. 119, n° 3, doi : 10.1111/j.1744-7348.1991.tb04895.x, pp. 561–601, ISSN 17447348.
- Ma H., Huang W., Jing Y., Pignatti S., Laneve G., Dong Y., Ye H., Liu L., Guo A. et Jiang J. 2019, «Identification of Fusarium Head Blight in Winter Wheat Ears Using Continuous Wavelet Analysis», *Sensors (Switzerland)*, pp. 1–15.
- Madgwick J. W., West J. S., White R. P., Semenov M. A., Townsend J. A., Turner J. A. et Fitt B. D. 2011, «Impacts of climate change on wheat anthesis and fusarium ear blight in the UK», *European Journal of Plant Pathology*, vol. 130, n° 1, doi : 10.1007/s10658-010-9739-1, pp. 117–131, ISSN 09291873.
- Mahlein A.-K., Alisaac E., Masri A. A., Behmann J., Dehne H.-w. et Oerke E.-c. 2019, «Comparison and Combination of Thermal, Fluorescence, and Hyperspectral Imaging for Monitoring Fusarium Head Blight of Wheat on Spikelet Scale», *Sensors (Switzerland)*.

- McNemar Q. 1947, «Note on the sampling error of the difference between correlated proportions or percentages», *Psychometrika*, vol. 12, n° 2, doi : 10.1007/BF02295996, pp. 153–157, ISSN 00333123.
- Melloy P., Hollaway G., Luck J., Norton R., Aitken E. et Chakraborty S. 2010, «Production and fitness of *Fusarium pseudograminearum* inoculum at elevated carbon dioxide in FACE», *Global Change Biology*, vol. 16, n° 12, doi : 10.1111/j.1365-2486.2010.02178.x, pp. 3363–3373, ISSN 13541013.
- Menesatti P., Antonucci F., Pallottino F., Giorgi S., Matere A., Nocente F., Pasquini M., D'Egidio M. G. et Costa C. 2013, «Laboratory vs. in-field spectral proximal sensing for early detection of *Fusarium* head blight infection in durum wheat», *Biosystems Engineering*, vol. 114, n° 3, doi : 10.1016/j.biosystemseng.2013.01.004, pp. 289–293, ISSN 15375110. URL <http://dx.doi.org/10.1016/j.biosystemseng.2013.01.004>.
- Pirgozliev S. R., Edwards S. G., Hare M. C. et Jenkinson P. 2003, «Strategies for the control of *Fusarium* head blight in cereals», *European Journal of Plant Pathology*, vol. 109, n° 7, doi : 10.1023/A:1026034509247, pp. 731–742, ISSN 09291873.
- Prescott J., Burnett P., Saari E., Ransoom J., Bowman J., de Miliano W., Singh R. et Bekele G. 1986, *Wheat diseases and pests. A guide for field identification.*, International Maize And Wheat Improvement Center. URL <https://agris.fao.org/agris-search/index.do>.
- Qiu R., Yang C., Moghimi A., Zhang M., Steffenson B. J. et Hirsch C. D. 2019, «Detection of *Fusarium* Head Blight in wheat using a deep neural network and color imaging», *Remote Sensing*, vol. 11, n° 22, doi : 10.3390/rs11222658, ISSN 20724292.
- Service Public de Wallonie. 2015, «Carte Numérique des Sols de Wallonie», URL <https://geoportail.wallonie.be/walonmap#BB0X=173041.7123914007,175157.06037209666,138604.6982854937,139485.76254762226>, consulté le 20/05/2021.
- Shewry P. R. 2009, «Wheat», *Journal of Experimental Botany*, vol. 60, n° 6, doi : 10.1093/jxb/erp058, pp. 1537–1553, ISSN 00220957.
- Soyeurt H. 2019, *Artificial Neural Network*.
- Stepien L. et Chelkowski J. 2010, «*Fusarium* head blight of wheat : Pathogenic species and their mycotoxins», *World Mycotoxin Journal*, vol. 3, n° 2, doi : 10.3920/WMJ2009.1193, pp. 107–119, ISSN 18750796.
- United Nations, Department of Economic and Social Affairs, Population Division. 2019, *World population prospects 2019*, 141, United Nations, ISBN 9789211483161, 46 pp.. URL <http://www.ncbi.nlm.nih.gov/pubmed/12283219>.
- West J. S., Holdgate S., Townsend J. A., Edwards S. G., Jennings P. et Fitt B. D. 2012, «Impacts of changing climate and agronomic factors on *Fusarium* ear blight of wheat in the UK», *Fungal Ecology*, vol. 5, n° 1, doi : 10.1016/j.funeco.2011.03.003, pp. 53–61, ISSN 17545048. URL <http://dx.doi.org/10.1016/j.funeco.2011.03.003>.
- Whetton R. L., Waine T. W. et Mouazen A. M. 2018, «Hyperspectral measurements of yellow rust and *Fusarium* head blight in cereal crops : Part 2 : On-line field measurement», *Biosystems Engineering*, vol. 167, doi : 10.1016/j.biosystemseng.2018.01.004, pp. 144–158, ISSN 15375110. URL <https://doi.org/10.1016/j.biosystemseng.2018.01.004>.
- Wise K., Johnson B., Mansfield C. et Krupke C. 2011, «Managing Wheat by Growth Stage», URL <https://www.extension.purdue.edu/extmedia/ID/ID-422.pdf>, consulté le 18/03/2021.
- Zhang D., Wang D., Gu C., Jin N., Zhao H., Chen G., Liang H. et Liang D. 2019, «Using neural network to identify the severity of wheat *Fusarium* head blight in the field environment», *Remote Sensing*, vol. 11, n° 20, doi : 10.3390/rs11202375, ISSN 20724292.

Zhang D., Wang Z., Jin N., Jin N., Gu C., Chen Y. et Huang Y. 2020a, «Evaluation of Efficacy of Fungicides for Control of Wheat Fusarium Head Blight Based on Digital Imaging», *IEEE Access*, vol. 8, doi : 10.1109/ACCESS.2020.3001652, pp. 109 876–109 890, ISSN 21693536.

Zhang D. Y., Chen G., Yin X., Hu R. J., Gu C. Y., Pan Z. G., Zhou X. G. et Chen Y. 2020b, «Integrating spectral and image data to detect Fusarium head blight of wheat», *Computers and Electronics in Agriculture*, vol. 175, n° May, doi : 10.1016/j.compag.2020.105588, p. 105 588, ISSN 01681699. URL <https://doi.org/10.1016/j.compag.2020.105588>.

8 Annexes

	sg51_auto	sg51_snv	sg52_auto	sg52_snv
MLP	0,9572	0,9626	0,9369	0,9374
PLS-DA	0,9527	0,9546	0,9471	0,9473
QDA	0,8500	0,8320	0,7534	0,8658
RF	0,8905	0,9244	0,8591	0,8605
SAM	0,7306	0,7262	0,7266	0,7050
SVM	0,9544	0,9597	0,9579	0,9502
	sg71_auto	sg71_snv	sg72_auto	sg72_snv
MLP	0,9540	0,9675	0,9451	0,9469
PLS-DA	0,9529	0,9548	0,9498	0,9478
QDA	0,5853	0,6968	0,7575	0,5852
RF	0,9120	0,9378	0,8799	0,8929
SAM	0,7297	0,7258	0,7344	0,7285
SVM	0,9541	0,9601	0,9575	0,9506
	sg91_auto	sg91_snv	sg92_auto	sg92_snv
MLP	0,9544	0,9678	0,9494	0,9519
PLS-DA	0,9530	0,9561	0,9481	0,9477
QDA	0,6539	0,6131	0,6805	0,6095
RF	0,9222	0,9448	0,8960	0,9105
SAM	0,7310	0,7256	0,7330	0,7266
SVM	0,9533	0,9612	0,9578	0,9510

Tableau 25 – Exactitudes des modèles selon les paramètres du filtre de Savitzky-Golay - FX10 - 3 JAI

	sg51_auto	sg51_snv	sg52_auto	sg52_snv
MLP	0,9810	0,9599	0,9750	0,9450
PLS-DA	0,9738	0,9313	0,9727	0,9259
QDA	0,7882	0,7652	0,8083	0,6381
RF	0,9801	0,9333	0,9496	0,8599
SAM	0,9153	0,5884	0,9004	0,5949
SVM	0,9788	0,9398	0,9780	0,9362
	sg71_auto	sg71_snv	sg72_auto	sg72_snv
MLP	0,9817	0,9567	0,9768	0,9561
PLS-DA	0,9723	0,9307	0,9727	0,9251
QDA	0,7174	0,7309	0,6367	0,6733
RF	0,9826	0,9416	0,9611	0,8987
SAM	0,9125	0,5893	0,8905	0,5960
SVM	0,9779	0,9391	0,9783	0,9353
	sg91_auto	sg91_snv	sg92_auto	sg92_snv
MLP	0,9824	0,9576	0,9782	0,9522
PLS-DA	0,9727	0,9314	0,9722	0,9244
QDA	0,7475	0,7573	0,8630	0,6778
RF	0,9834	0,9434	0,9730	0,9199
SAM	0,9111	0,5928	0,8909	0,6007
SVM	0,9788	0,9384	0,9781	0,9352

Tableau 26 – Exactitudes des modèles selon les paramètres du filtre de Savitzky-Golay - FX17 - 4 JAI

	ret5_auto	ret5_snv	sg51_auto	sg51_snv
MLP	0,9433	0,9540	0,9572	0,9626
PLS-DA	0,9508	0,9589	0,9527	0,9546
QDA	0,9161	0,8936	0,8500	0,8320
RF	0,8973	0,9464	0,8905	0,9244
SAM	0,6553	0,7716	0,7306	0,7262
SVM	0,9486	0,9576	0,9544	0,9597
	sg51_auto_ab	sg51_snv_plsda	sg51_snv_rf	
MLP	0,9566	0,9572	0,9447	
PLS-DA	0,9528	0,9486	0,9184	
QDA	0,8796	0,9464	0,9066	
RF	0,8907	0,9500	0,9196	
SAM	0,7306	0,7627	0,7302	
SVM	0,9544	0,9554	0,9359	

Tableau 27 – Exactitudes des modèles de segmentation des épis - FX10 - 3 JAI; plsda : transformation de variables par PLS-DA

	ret5_auto	ret5_snv	sg51_auto	sg51_snv	
MLP	0,9829	0,9426	0,9810	0,9599	
PLS-DA	0,9747	0,9328	0,9738	0,9313	
QDA	0,8055	0,9019	0,7882	0,7652	
RF	0,9716	0,9406	0,9801	0,9333	
SAM	0,5840	0,6220	0,9153	0,5884	
SVM	0,9795	0,9401	0,9788	0,9398	
	sg51_auto_ab	ret5_auto_plsda	ret5_auto_rf	sg51_auto_plsda	sg51_auto_rf
MLP	0,9820	0,9628	0,9785	0,9622	0,9781
PLS-DA	0,9735	0,9538	0,9612	0,9611	0,9740
QDA	0,7693	0,9415	0,8875	0,9663	0,9304
RF	0,9801	0,9571	0,9695	0,9661	0,9789
SAM	0,9160	0,6310	0,5825	0,9571	0,9550
SVM	0,9787	0,9503	0,9634	0,9620	0,9741

Tableau 28 – Exactitudes des modèles de segmentation des épis - FX17 - 4 JAI

	colspa_auto
MLP	0,8089
PLS-DA	0,7052
QDA	0,7172
RF	0,7738
SVM	0,7284

Tableau 29 – Exactitudes des modèles de segmentation des épis - D5200 - 3 JAI; colspa : calcul d'autres espaces colorimétriques

	ret5_auto	ret5_snv	sg51_auto	sg51_snv
MLP	0,9856	0,9921	0,9930	0,9874
PLS-DA	0,9917	0,9903	0,9918	0,9886
QDA	0,9744	0,9728	0,7726	0,9624
RF	0,9764	0,9894	0,9681	0,9709
SAM	0,6556	0,9289	0,7953	0,8827
SVM	0,9915	0,9924	0,9921	0,9878
	ret5_snv_plsda	ret5_snv_rf	sg51_auto_plsda	sg51_auto_rf
MLP	0,9815	0,9809	0,9388	0,9806
PLS-DA	0,9677	0,9751	0,9150	0,9551
QDA	0,9701	0,9661	0,9413	0,9526
RF	0,9847	0,9853	0,9575	0,9662
SAM	0,9375	0,9129	0,8540	0,8741
SVM	0,9817	0,9847	0,9400	0,9693

Tableau 30 – Exactitudes des modèles de segmentation des épis - FX10 - 18 JAI

	ret5_auto	ret5_snv	sg51_auto	sg51_snv
MLP	0,9569	0,9381	0,9546	0,9462
PLS-DA	0,9425	0,9379	0,9429	0,9321
QDA	0,7935	0,8759	0,8282	0,8223
RF	0,9261	0,9262	0,9540	0,9376
SAM	0,6324	0,6881	0,8040	0,6506
SVM	0,9417	0,9314	0,9416	0,9302
	ret5_auto_plsda	ret5_auto_rf	sg51_auto_plsda	sg51_auto_rf
MLP	0,8002	0,9503	0,9329	0,9488
PLS-DA	0,7523	0,9323	0,9267	0,9382
QDA	0,7795	0,8891	0,9362	0,9108
RF	0,8135	0,9264	0,9349	0,9511
SAM	0,6408	0,6273	0,9064	0,8509
SVM	0,7520	0,9242	0,9216	0,9335

Tableau 31 – Exactitudes des modèles de segmentation des épis - FX17 - 18 JAI

	colspa_auto
MLP	0,9388
PLS-DA	0,9268
QDA	0,8484
RF	0,9292
SVM	0,9235

Tableau 32 – Exactitudes des modèles de segmentation des épis - D5200 - 18 JAI

	ret5_auto	ret5_snv	sg51_auto	sg51_snv	ret5_auto_plsda	ret5_auto_rf
MLP	0,9894	0,9763	0,9850	0,9813	0,9674	0,9776
PLS-DA	0,9813	0,9596	0,9765	0,9757	0,9626	0,9458
QDA	0,9615	0,9495	0,8668	0,8967	0,9677	0,8936
RF	0,9787	0,9774	0,9712	0,9675	0,9759	0,9677
SAM	0,6583	0,9473	0,8733	0,9084	0,7182	0,6209
SVM	0,9800	0,9750	0,9748	0,9760	0,9706	0,9598

Tableau 33 – Exactitudes des modèles de segmentation des épis - FX10 - 26 JAI

	ret5_auto	ret5_snv	sg51_auto	sg51_snv	ret5_snv_plsda	ret5_snv_rf
MLP	0,9644	0,9659	0,9679	0,9713	0,9352	0,9278
PLS-DA	0,9618	0,9868	0,9750	0,9843	0,9443	0,9502
QDA	0,9818	0,9305	0,9775	0,9584	0,9644	0,9126
RF	0,9305	0,9513	0,9613	0,9724	0,9193	0,9278
SAM	0,4411	0,7432	0,8868	0,8975	0,9543	0,9432
SVM	0,9459	0,9555	0,9583	0,9569	0,9060	0,9253

Tableau 34 – Exactitudes des modèles de segmentation des épis - FX17 - 26 JAI

	colspa_auto
MLP	0,8647
PLS-DA	0,8473
QDA	0,8702
RF	0,8604
SVM	0,8663

Tableau 35 – Exactitudes des modèles de segmentation des épis - D5200 - 26 JAI

	ret5_auto	ret5_snv	sg51_auto	sg51_snv	ret5_auto_plsda	ret5_auto_rf
MLP	0,9718	0,9693	0,9681	0,9671	0,8960	0,9312
PLS-DA	0,9578	0,9406	0,9566	0,9541	0,8719	0,8758
QDA	0,9076	0,8567	0,8609	0,6707	0,8754	0,8822
RF	0,9488	0,9458	0,9187	0,9120	0,9013	0,9158
SAM	0,5249	0,8806	0,8407	0,8038	0,5356	0,5570
SVM	0,9761	0,9677	0,9711	0,9619	0,8989	0,9199

Tableau 36 – Exactitudes des modèles de segmentation des épis - FX10 - 39 JAI

	ret5_auto	ret5_snv	sg51_auto	sg51_snv	ret5_auto_plsda	ret5_auto_rf
MLP	0,9936	0,9715	0,9810	0,9735	0,9825	0,9694
PLS-DA	0,9780	0,9546	0,9464	0,9515	0,9317	0,9609
QDA	0,9118	0,8983	0,8927	0,8979	0,9558	0,8835
RF	0,9650	0,9405	0,9643	0,9534	0,9754	0,9436
SAM	0,6481	0,5328	0,7192	0,5982	0,6550	0,6478
SVM	0,9916	0,9597	0,9698	0,9534	0,9704	0,9709

Tableau 37 – Exactitudes des modèles de segmentation des épis - FX17 - 39 JAI

	colspa_auto
MLP	0,8441
PLS-DA	0,7867
QDA	0,7295
RF	0,8216
SVM	0,8076

Tableau 38 – Exactitudes des modèles de segmentation des épis - D5200 - 39 JAI

	ret5_auto	ret5_snv	sg51_auto	sg51_snv	sg51_auto_plsda	sg51_auto_rf
MLP	0,9235	0,9898	0,9847	0,8980	0,5000	0,9796
PLS-DA	0,9872	0,9821	0,9872	0,9439	0,9898	0,9847
QDA	0,8699	0,8903	0,8265	0,9566	0,9847	0,9566
RF	0,8163	0,9821	0,9898	0,8903	0,9898	0,9847
SAM	0,7474	0,9745	0,9898	0,7423	0,9898	0,9847
SVM	0,9872	0,9745	0,9872	0,9362	0,9898	0,9847

Tableau 39 – Exactitudes des modèles de détection de la fusariose - FX10 - 26 JAI

	ret5_auto	ret5_snv	sg51_auto	sg51_snv	ret5_auto_plsda	ret5_auto_rf
MLP	0,9940	0,9881	0,9702	0,9762	0,5000	0,9940
PLS-DA	0,8571	0,9583	0,9940	0,9821	0,9940	0,9286
QDA	0,6429	0,7381	0,8750	0,9821	0,9940	0,9345
RF	0,9940	0,9821	0,9345	0,9940	0,9583	0,9940
SAM	0,9940	0,9702	0,9821	0,8988	0,9940	0,9940
SVM	0,8690	0,9821	0,9881	0,9821	0,9940	0,9583

Tableau 40 – Exactitudes des modèles de détection de la fusariose - FX17 - 26 JAI

	colspa_auto
MLP	0,9197
PLS-DA	0,9002
QDA	0,9270
RF	0,8860
SVM	0,9172

Tableau 41 – Exactitudes des modèles de détection de la fusariose - D5200 - 26 JAI

	ret5_auto	ret5_snv	sg51_auto	sg51_snv	sg51_snv_plsda	sg51_snv_rf
MLP	0,8319	0,7371	0,6767	0,8017	0,5000	0,8621
PLS-DA	0,6681	0,7198	0,7026	0,8491	0,6940	0,7759
QDA	0,5474	0,8276	0,5431	0,7586	0,6810	0,8147
RF	0,7069	0,6207	0,7586	0,7414	0,6466	0,7500
SAM	0,8190	0,7500	0,8319	0,7672	0,7241	0,8233
SVM	0,6336	0,6466	0,6293	0,8448	0,6379	0,7888

Tableau 42 – Exactitudes des modèles de détection de la fusariose - FX10 - 39 JAI

	ret5_auto	ret5_snv	sg51_auto	sg51_snv	sg51_auto_plsda	sg51_auto_rf
MLP	0,8323	0,8407	0,8637	0,8564	0,5000	0,8396
PLS-DA	0,8784	0,8344	0,8920	0,8816	0,6897	0,8553
QDA	0,7484	0,8333	0,7904	0,7537	0,5776	0,8208
RF	0,8155	0,8470	0,8302	0,8312	0,5647	0,8218
SAM	0,7589	0,7862	0,8543	0,7306	0,7284	0,8512
SVM	0,8249	0,8260	0,8428	0,8574	0,5819	0,8312

Tableau 43 – Exactitudes des modèles de détection de la fusariose - FX17 - 39 JAI

	colspa_auto
MLP	0,8674
PLS-DA	0,8562
QDA	0,8206
RF	0,8344
SVM	0,8488


Tableau 44 – Exactitudes des modèles de détection de la fusariose - D5200 - 39 JAI

d.f.	.995	.99	.975	.95	.9	.1	.05	.025	.01
1	0.00	0.00	0.00	0.00	0.02	2.71	3.84	5.02	6.63
2	0.01	0.02	0.05	0.10	0.21	4.61	5.99	7.38	9.21
3	0.07	0.11	0.22	0.35	0.58	6.25	7.81	9.35	11.34
4	0.21	0.30	0.48	0.71	1.06	7.78	9.49	11.14	13.28
5	0.41	0.55	0.83	1.15	1.61	9.24	11.07	12.83	15.09
6	0.68	0.87	1.24	1.64	2.20	10.64	12.59	14.45	16.81
7	0.99	1.24	1.69	2.17	2.83	12.02	14.07	16.01	18.48
8	1.34	1.65	2.18	2.73	3.49	13.36	15.51	17.53	20.09
9	1.73	2.09	2.70	3.33	4.17	14.68	16.92	19.02	21.67
10	2.16	2.56	3.25	3.94	4.87	15.99	18.31	20.48	23.21
11	2.60	3.05	3.82	4.57	5.58	17.28	19.68	21.92	24.72
12	3.07	3.57	4.40	5.23	6.30	18.55	21.03	23.34	26.22
13	3.57	4.11	5.01	5.89	7.04	19.81	22.36	24.74	27.69
14	4.07	4.66	5.63	6.57	7.79	21.06	23.68	26.12	29.14
15	4.60	5.23	6.26	7.26	8.55	22.31	25.00	27.49	30.58
16	5.14	5.81	6.91	7.96	9.31	23.54	26.30	28.85	32.00
17	5.70	6.41	7.56	8.67	10.09	24.77	27.59	30.19	33.41
18	6.26	7.01	8.23	9.39	10.86	25.99	28.87	31.53	34.81
19	6.84	7.63	8.91	10.12	11.65	27.20	30.14	32.85	36.19
20	7.43	8.26	9.59	10.85	12.44	28.41	31.41	34.17	37.57
22	8.64	9.54	10.98	12.34	14.04	30.81	33.92	36.78	40.29
24	9.89	10.86	12.40	13.85	15.66	33.20	36.42	39.36	42.98
26	11.16	12.20	13.84	15.38	17.29	35.56	38.89	41.92	45.64
28	12.46	13.56	15.31	16.93	18.94	37.92	41.34	44.46	48.28
30	13.79	14.95	16.79	18.49	20.60	40.26	43.77	46.98	50.89
32	15.13	16.36	18.29	20.07	22.27	42.58	46.19	49.48	53.49
34	16.50	17.79	19.81	21.66	23.95	44.90	48.60	51.97	56.06
38	19.29	20.69	22.88	24.88	27.34	49.51	53.38	56.90	61.16
42	22.14	23.65	26.00	28.14	30.77	54.09	58.12	61.78	66.21
46	25.04	26.66	29.16	31.44	34.22	58.64	62.83	66.62	71.20
50	27.99	29.71	32.36	34.76	37.69	63.17	67.50	71.42	76.15
55	31.73	33.57	36.40	38.96	42.06	68.80	73.31	77.38	82.29
60	35.53	37.48	40.48	43.19	46.46	74.40	79.08	83.30	88.38
65	39.38	41.44	44.60	47.45	50.88	79.97	84.82	89.18	94.42
70	43.28	45.44	48.76	51.74	55.33	85.53	90.53	95.02	100.43
75	47.21	49.48	52.94	56.05	59.79	91.06	96.22	100.84	106.39
80	51.17	53.54	57.15	60.39	64.28	96.58	101.88	106.63	112.33
85	55.17	57.63	61.39	64.75	68.78	102.08	107.52	112.39	118.24
90	59.20	61.75	65.65	69.13	73.29	107.57	113.15	118.14	124.12
95	63.25	65.90	69.92	73.52	77.82	113.04	118.75	123.86	129.97
100	67.33	70.06	74.22	77.93	82.36	118.50	124.34	129.56	135.81


Figure 15 – Valeurs de la table de distribution Chi-carrée (source : Université de Queensland, consulté le 06/07/2021)




(a) Photo originale RVB



(b) Prédiction RVB



(c) Prédiction FX10




(d) Prédiction FX17


Figure 16 – Image originale et segmentations pour les différents capteurs - RGT Graivty inoculé - 3 et 4 JAI; code couleurs : jaune : épi, vert : matériel végétal, bleu : autre




(a) Photo originale RVB



(b) Prédiction RVB



(c) Prédiction FX10




(d) Prédiction FX17


Figure 17 – Image originale et segmentations pour les différents capteurs - RGT Gravity inoculé - 18 JAI




(a) Photo originale RVB



(b) Prédiction RVB



(c) Prédiction FX10




(d) Prédiction FX17


Figure 18 – Image originale et segmentations pour les différents capteurs - RGT Gravity non inoculé - 26 JAI




(a) Photo originale RVB



(b) Prédiction RVB



(c) Prédiction FX10




(d) Prédiction FX17


Figure 19 – Image originale et segmentations pour les différents capteurs - RGT Gravity inoculé - 26 JAI




(a) Photo originale RVB



(b) Prédiction RVB



(c) Prédiction FX10




(d) Prédiction FX17


Figure 20 – Image originale et segmentations pour les différents capteurs - bordure (non inoculée) - 39 JAI




(a) Photo originale RVB



(b) Prédiction RVB



(c) Prédiction FX10




(d) Prédiction FX17


Figure 21 – Image originale et segmentations pour les différents capteurs - RGT Gravity inoculé - 39 JAI




(a) Photo originale RVB



(b) Prédiction RVB



(c) Prédiction FX10




(d) Prédiction FX17


Figure 22 – Image originale et détection de la fusariose pour les différents capteurs - RGT Gravity non inoculé - 26 JAI; code couleurs : rouge : épi fusarié, noir : partie abandonnée lors de la segmentation des épis




(a) Photo originale RVB



(b) Prédiction RVB



(c) Prédiction FX10



(d) Prédiction FX17

Figure 23 – Image originale et détection de la fusariose pour les différents capteurs - RGT Gravity inoculé - 26 JAI






Figure 24 – Détection de la fusariose pour FX10 et FX17 avec d'autres modèles - RGT Gravity non inoculé - 26 JAI



(a) Prédiction FX10 RF "sg51_auto"

(b) Prédiction FX10 RF "sg51_auto_plsda"



(c) Prédiction FX17 RF "ret5_auto"

(d) Prédiction FX17 RF "ret5_auto_rf"


Figure 25 – Détection de la fusariose pour FX10 et FX17 avec d'autres modèles - RGT Gravity inoculé - 26 JAI




(a) Photo originale RVB



(b) Prédiction RVB



(c) Prédiction FX10




(d) Prédiction FX17


Figure 26 – Image originale et détection de la fusariose pour les différents capteurs - bordure (non inoculée) - 39 JAI




(a) Photo originale RVB



(b) Prédiction RVB



(c) Prédiction FX10



(d) Prédiction FX17

Figure 27 – Image originale et détection de la fusariose pour les différents capteurs - RGT Gravity inoculé - 39 JAI