

Université du Québec
Institut National de la Recherche Scientifique
Centre Eau Terre Environnement

**DÉPISTAGE AUTOMATIQUE DU DORYPHORE DE LA POMME DE
TERRE À L'AIDE DE L'IMAGERIE ULTRA-HAUTE RÉOLUTION
ACQUISE PAR DRONE ET DE L'APPRENTISSAGE PROFOND**

Par
Dominic Thériault

Mémoire présenté pour l'obtention du grade de
Maître ès sciences (M.Sc.)
en sciences de l'eau

Jury d'évaluation

Président du jury et
Examineur interne

Dr. Saeid Homayouni
Institut National de la Recherche
Scientifique

Examineur externe

Dr. Yacine Bouroubi
Département de géomatique appliquée
Université de Sherbrooke

Directeur de recherche

Dr. Karem Chokmani
Institut National de la Recherche
Scientifique

DÉDICACE

Je dédie ce mémoire à ma famille et à mes amis :

De nombreux sacrifices ont été faits afin de parvenir à déposer ce mémoire. En 2012, à l'âge de 23 ans, j'ai décidé de retourner aux études pour découvrir le monde de la géomatique au Cégep de Chicoutimi pour ensuite compléter un Baccalauréat en géomatique appliquée à l'environnement à l'Université de Sherbrooke. Mon expérience de stagiaire à l'INRS m'a donné le goût de la recherche et l'envie de poursuivre vers les études supérieures. Il y a eu de nombreuses rencontres marquantes durant ce parcours qui m'a fait grandir en tant qu'humain.

Ma mère, **Anne Vigneault**, a été la première personne à m'encourager dans mon choix de carrière. Sans elle, je ne serai jamais parvenu à accomplir ce parcours. Elle a toujours cru en moi et m'a dévoué par amour son soutien, ses conseils, sa sagesse, sa patience ainsi que sa compréhension.

Mon père, **Gilles Thériault**, a toujours été là pour m'écouter et m'épauler dans les différentes étapes de mon retour aux études. Il a su voir en mes yeux l'importance et la passion que j'accordais à ce projet de vie.

Étant enfant unique, j'ai toujours considéré mes amis les plus proches comme des frères et sœurs pour lesquels j'ai un amour inconditionnel. Que ce soit la distance qui nous sépare ou la mort, sachez que vous êtes toujours là avec moi. Je dédie donc ce mémoire à mes frères, pour ne nommer que ceux-ci : **Jean-Olivier Brassard, Philippe Brazeau, Jean-Sébastien Collard, Alejandro Gastan, Nicolas Gauvin-Rocray, Charles Morand, Antoine Paquet, Patrick Perron, Carl Plante et Emmanuel Rhéaume.**

REMERCIEMENTS

Premièrement, je tiens à remercier mon directeur de recherche, **Dr Karem Chokmani**, de m'avoir donné l'occasion de réaliser un projet de maîtrise innovant, pour ses nombreux et judicieux conseils et encouragements tout au long de mon parcours.

La réalisation de ce projet a été possible grâce au financement de **Mitacs Accélération** en partenariat avec le producteur de pommes de terres **Patates Dolbec** et le **MAPAQ**.

Je désire remercier **Patates Dolbec** d'avoir fourni une parcelle agricole expérimentale et pour leur contribution au financement du projet. Je désire remercier également les agronomes, **M Philippe Parent** et **Juliette Lévesque**, d'avoir répondu à mes questions et m'éclairer en ce qui a trait à la régie des cultures de pommes de terre, à l'agronomie et à la phytoprotection.

Je tiens également à remercier **M Daniel Bergeron** du **MAPAQ** pour avoir créé le lien entre l'**INRS** et **Patates Dolbec** et le **MAPAQ** pour avoir contribué au financement du projet.

Je remercie l'équipe du **Laboratoire de Télédétection environnementale et nordique** (TENOR) et le **Laboratoire de Télédétection par Drone** (TED). Je remercie particulièrement : **M Hachem Agili**, **Dr Monique Bernier**, **Amal Hmaissia**, **Dr Rachid Lhissou** et **M Jimmy Poulin** pour leur soutien lors des sorties terrain et leurs conseils.

Je remercie mes **collègues étudiants de l'INRS** avec qui j'ai pu partager mes joies et mes peines et qui ont toujours eu les bons mots pour m'encourager.

Enfin, je désire remercier ma **communauté de voisins et d'amis de la rue Richelieu** avec qui j'ai eu une vie de quartier épanouissante et avec qui j'ai partagé de merveilleux moments tout au long de ma maîtrise.

RÉSUMÉ

Le Doryphore de la pomme de terre (*Leptinotarsa decemlineata*) pose une menace d'importance pour la culture de la pomme de terre. Le contrôle de l'insecte ravageur se fait principalement en combinant les rotations de cultures et l'utilisation d'insecticide chimique. Malgré que les populations du ravageur sont très agrégées naturellement à cause de leur mode de reproduction, les interventions phytosanitaires sont souvent peu ciblées. Les méthodes de dépistage conventionnelles sont souvent très laborieuses et coûteuses en ressources humaines et sont donc souvent négligées. L'utilisation de drone se voit comme une alternative rapide au dépistage conventionnel afin de localiser avec précision les foyers d'infestation et de calculer les seuils d'intervention phytosanitaire.

Ce projet en partenariat avec le producteur de pommes de terre Patates Dolbec a pour but de développer une méthode de dépistage du doryphore de la pomme de terre en utilisant l'imagerie d'ultra-haute résolution acquise par drone afin de permettre le décompte des grosses larves et adultes au sommet de la canopée. L'étude consiste à 1) déterminer les paramètres optimaux d'acquisition des images par drone, 2) concevoir un algorithme de détection basé sur les réseaux de neurones convolutifs permettant de dénombrer les individus (grosses larves et adultes) et 3) optimiser l'algorithme afin de réduire le temps de calcul afin que celle-ci puisse être utilisable opérationnellement. Une parcelle agricole densément infestée a été survolée à deux reprises lors de l'été 2018 et un dépistage conventionnel a été fait dans ce champ afin d'être comparé au dépistage par drone et afin de valider les observations.

L'algorithme développé se décompose en deux phases de détection :

- 1) Une détection des zones potentielles par caractéristiques définies par un expert,
- 2) Une classification des zones potentielles à l'aide de l'apprentissage profond afin de déterminer une classe d'appartenance (doryphore ou non).

Comme il peut y avoir plusieurs centaines de zones potentielles pour quelques doryphores dans une image, il s'agit d'un problème de classification non balancée. Pour pallier ce déséquilibre des classes, différentes stratégies d'entraînement de réseaux de neurones convolutifs ont été comparées. Le suréchantillonnage par augmentation de

données et l'apprentissage sensible au coût ont démontré être les stratégies les plus efficaces. Une validation a été effectuée à l'échelle des individus ainsi qu'à l'échelle des foyers d'infestations. À l'échelle des individus de doryphores, le meilleur modèle présente un f1-score de 77% avec une précision de 82% et un rappel de 72%. Au niveau des foyers d'infestation, le meilleur modèle présente un f1-score de 87% avec une précision de 82% et un rappel de 93%. Le meilleur modèle a présenté un coefficient de détermination de 70% entre le nombre de détections et le nombre de grosses larves et adultes au sommet de la canopée pour les parcelles de dépistage conventionnel.

Le temps de traitement demeure un enjeu important du projet et les résultats démontrent que la phase de détection préliminaire est l'étape la plus coûteuse en temps de calcul. Par l'utilisation de processeurs graphiques, il est possible de traiter des images couvrant une superficie de 1 ha en environ 8 heures.

La méthode développée permet de cibler les foyers d'infestation et ainsi de déterminer les seuils d'intervention phytosanitaire automatiquement avec un minimum de main-d'œuvre nécessaire. Finalement, l'utilisation d'une telle méthode appuie les principes d'agriculture de précision et devrait contribuer à réduire les applications d'insecticides dans l'environnement en appliquant le bon traitement, à la bonne dose, au bon moment, et au bon endroit.

TABLE DES MATIÈRES

1	INTRODUCTION.....	1
1.1	CONTEXTE	1
1.2	PROBLÉMATIQUE	3
1.3	OBJECTIFS	8
2	NOTIONS GÉNÉRALES	9
2.1	LE DORYPHORE DE LA POMME DE TERRE.....	9
2.1.1	<i>Biologie.....</i>	9
2.2	LA GESTION INTÉGRÉE DES ENNEMIS DES CULTURES	11
2.2.1	<i>Le dépistage du doryphore de la pomme de terre</i>	12
2.2.2	<i>Moyens de lutte contre le doryphore de la pomme de terre</i>	13
2.2.3	<i>Seuils d'interventions phytosanitaires</i>	16
2.3	L'AGRICULTURE DE PRÉCISION ET LA TÉLÉDÉTECTION.....	18
2.3.1	<i>La télédétection en agriculture de précision.....</i>	18
2.4	VISION ASSISTÉE PAR ORDINATEUR	24
2.4.1	<i>La segmentation des images numériques</i>	25
2.4.2	<i>Espaces colorimétriques</i>	28
2.4.3	<i>Reconnaitances d'objets par caractéristiques et apprentissage automatique</i>	30
2.4.4	<i>Reconnaissance d'objets par apprentissage profond</i>	31
2.5	ACQUISITION DES PHOTOGRAPHIES NUMÉRIQUES À PARTIR D'UN DRONE.....	41
2.5.1	<i>Les paramètres de photographies à partir d'un drone à considérer</i>	41
2.5.2	<i>Réglementation des vols de drone au Canada.....</i>	45
3	MATÉRIELS ET MÉTHODES	47
3.1	DISPOSITIF EXPÉRIMENTAL.....	47
3.1.1	<i>Campagnes de terrain.....</i>	47
3.1.2	<i>Acquisition des images ultra-haute résolution par drone</i>	49
3.2	ALGORITHME DE DÉTECTION	52
3.2.1	<i>Détection préliminaire.....</i>	54
3.2.2	<i>Détection par réseau de neurones convolutifs.....</i>	56
3.3	STRATÉGIES D'ENTRAÎNEMENT DU RÉSEAU DE NEURONES CONVOLUTIF.....	57
3.3.1	<i>Stratégies d'entraînement pour faire face au déséquilibre des classes.....</i>	57
3.3.2	<i>Les hyperparamètres</i>	59

3.4	CRÉATION DES CARTES DE DÉPISTAGE	60
3.5	VALIDATION DES ALGORITHMES	61
3.5.1	<i>Jeux de données d'entraînement, de validation, de test et de foyers d'infestations</i>	61
3.5.2	<i>Métriques de validation</i>	65
4	RÉSULTATS ET DISCUSSION.....	67
4.1	DÉTECTION PRÉLIMINAIRE	67
4.2	COMPARAISON DES STRATÉGIES D'ENTRAÎNEMENT DE RÉSEAUX DE NEURONES CONVOLUTIF.....	73
4.3	CARTES DE DÉPISTAGE	87
4.4	TEMPS DE TRAITEMENT	90
4.5	COMPARAISON ENTRE LE DÉPISTAGE PAR DRONE ET LE DÉPISTAGE CONVENTIONNEL.....	91
4.6	PROTOCOLE D'ACQUISITION DES IMAGES ULTRA-HAUTE RÉOLUTION	94
5	CONCLUSIONS.....	97
6	RÉFÉRENCES.....	101
7	ANNEXES	109

LISTE DES TABLEAUX

TABLEAU 1: SATELLITES À TRÈS HAUTE RÉOLUTION SPATIALE (ADAPTÉ DE SOZZI <i>ET AL.</i> , 2018 ET DE EFFIGIS, 2017)	20
TABLEAU 2: COÛT D'ACQUISITION DES DIFFÉRENTS SATELLITES À TRÈS HAUTE RÉOLUTION SPATIALE (ADAPTÉ DE SOZZI <i>ET AL.</i> , 2018).....	21
TABLEAU 3: COMPARAISON DES DIFFÉRENTES PLATEFORMES DE TÉLÉDÉTECTION (ADAPTÉ DE CANDIAGO <i>ET AL.</i> , 2015)	22
TABLEAU 4 : TYPES DE PLATEFORMES DE SYSTÈMES AÉRIENS SANS PILOTE (ADAPTÉ DE SANKARAN, 2015).....	23
TABLEAU 5: MÉTHODES DE SEGMENTATION DES IMAGES NUMÉRIQUES (ADAPTÉ DE CHENG <i>ET AL.</i> , 2001).....	26
TABLEAU 6: PARAMÈTRES D'ACQUISITION DES IMAGES LORS DES DIFFÉRENTS VOLS POUR LES DEUX SORTIES TERRAIN	51
TABLEAU 7: DIFFÉRENTS JEUX DE DONNÉES POUR LES STRATÉGIES D'ENTRAÎNEMENT UTILISÉES COMPRENANT LE NOMBRE D'ÉCHANTILLONS POUR CHACUNE DES CLASSES	63
TABLEAU 8 : JEUX DE DONNÉES DE VALIDATION ET DE TESTS COMPRENANT LE NOMBRE D'ÉCHANTILLONS DE CHACUNE DES CLASSES	64
TABLEAU 9 : RÉSULTAT DE LA DÉTECTION PRÉLIMINAIRE POUR LES JEUX DE DONNÉES D'ENTRAÎNEMENT, DE VALIDATION ET DE TESTS POUR LES DIFFÉRENTES SORTIES TERRAIN D'ACQUISITION DES IMAGES.	71
TABLEAU 10: ÉPOQUES D'ENTRAÎNEMENT POUR LESQUELLES LES MEILLEURS MODÈLES ONT ÉTÉ SAUVEGARDÉS	74
TABLEAU 11: RÉSULTAT DES DIFFÉRENTS MODÈLES POUR LE JEU DE DONNÉES DE VALIDATION NON BALANCÉ ...	80
TABLEAU 12: RÉSULTAT DES DIFFÉRENTS MODÈLES POUR LE JEU DE DONNÉES TESTS.....	82
TABLEAU 13: TABLEAU DÉTAILLANT LES VRAIS POSITIFS (VP), VRAIS NÉGATIFS (VN), FAUX POSITIFS (FP) ET FAUX NÉGATIFS (FN) POUR CHACUNE DES IMAGES UTILISÉES DANS LE JEU DE VALIDATION DES FOYERS D'INFESTATION.....	88
TABLEAU 14: PERFORMANCE DES TROIS MEILLEURS MODÈLES POUR LE JEU DE VALIDATION DES FOYERS D'INFESTATION.....	88
TABLEAU 15: COMPARAISON DU TEMPS DE TRAITEMENT POUR UNE MACHINE VIRTUELLE AWS ET UN ORDINATEUR PORTABLE MUNIE D'UN PROCESSEUR GRAPHIQUE POUR LES DIFFÉRENTES ARCHITECTURES.	91
TABLEAU 16: RÉSULTAT DE COMPARAISON ENTRE LE DÉPISTAGE CONVENTIONNEL ET LE DÉPISTAGE PAR DRONE POUR LE MODÈLE RESNET-18 NON BALANCÉ 15-1.	92
TABLEAU 17: RÉSULTAT DE COMPARAISON ENTRE LE DÉPISTAGE CONVENTIONNEL ET LE DÉPISTAGE PAR DRONE POUR LE MODÈLE RESNET-34 NON BALANCÉ 15-1.	92
TABLEAU 18: RÉSULTAT DE COMPARAISON ENTRE LE DÉPISTAGE MANUEL ET LE DÉPISTAGE PAR DRONE POUR LE MODÈLE RESNET-50 SURÉCHANTILLONNÉ V1.....	93

LISTE DES FIGURES

FIGURE 1: A) DORYPHORE ADULTE; B) 4E STADE LARVAIRE DU DORYPHORE; C) ŒUFS NON ÉCLOS DE DORYPHORE ; D) LES QUATRE STADES LARVAIRES DU DORYPHORE (SOURCE: A) ET B) : PHOTO PAR PATRICK CHATELLE (INRS), C) ET D) : PHOTO PAR LE MAPAQ (HTTPS://WWW.AGRIRESEAU.NET/PDT/DOCUMENTS/VT045.))..	10
FIGURE 2: CYCLE DE VIE DU DORYPHORE DE LA POMME DE TERRE (SOURCE: KHELIFI, 2007).....	11
FIGURE 3: REPRÉSENTATION CUBIQUE DE L'ESPACE COLORIMÉTRIQUE RGB.....	28
FIGURE 4: REPRÉSENTATION VISUELLE DE L'ESPACE COLORIMÉTRIQUE HSV (SOURCE : IFT1423 – TELUQ : CHAPITRE 1).....	29
FIGURE 5: PRINCIPE DU PERCEPTRON	33
FIGURE 6: NON-LINÉARITÉ INTRODUITE DANS LE RÉSEAU PAR LA FONCTION D'ACTIVATION RELU (ADAPTÉ DE GLOROT <i>ET AL.</i> , 2011).....	33
FIGURE 7: EXEMPLE SIMPLIFIÉ DE CALCUL DE LA FONCTION DE COÛT	35
FIGURE 8: EXEMPLE D'ARCHITECTURE DE RÉSEAU DE NEURONES CONVOLUTIF PRÉSENTANT LES RÉSULTATS INTERMÉDIAIRES ENTRE CHACUNE DES COUCHES DU RÉSEAU (ADAPTÉ DE DING & TAYLOR, 2016).	38
FIGURE 9: BLOC RÉSIDUEL UTILISÉ DANS LES RESNET (HE <i>ET AL.</i> , 2015).....	39
FIGURE 10: CONFIGURATION DES COUCHES DE CONVOLUTION POUR LES DIFFÉRENTES PROFONDEURS D'ARCHITECTURES RÉSIDUELLES RESNET (HE <i>ET AL.</i> , 2015).	39
FIGURE 11: FILTRES DE BAYER EMPLOYÉS SUR LA PLUPART DES CAPTEURS DE CAMÉRAS COMMERCIALES (ADAPTÉ DE : HTTPS://EN.WIKIPEDIA.ORG/WIKI/BAYER_FILTER).....	41
FIGURE 12: EXEMPLE DES RAYONS DE LUMIÈRE INCIDENTE VERS LE CAPTEUR DE LA CAMÉRA (INSPIRÉ DE O'CONNOR <i>ET AL.</i> , 2017).....	42
FIGURE 13: LE TRIANGLE DE L'EXPOSITION AFFECTÉ PAR LES TROIS PARAMÈTRES PRINCIPAUX DE LA PHOTOGRAPHIE NUMÉRIQUE: VITESSE D'OBTURATION, OUVERTURE DU DIAPHRAGME ET L'ISO (SOURCE : HTTPS://TINYURL.COM/Y654CARP)	43
FIGURE 14: SITE D'ÉTUDE ET PARCELLES DE DÉPISTAGE MANUEL ET PHOTOGRAPHIQUE POUR LES DEUX SORTIES TERRAIN	48
FIGURE 15: EXEMPLE DE DÉPISTAGE PAR PHOTOGRAPHIE PROXIMALE POUR LA PARCELLE DE DÉPISTAGE #23 (30 JUILLET 2018) (À GAUCHE: PHOTOGRAPHIE PAR CELLULAIRE, MILIEU ET DROITE: PHOTOGRAPHIE PAR DRONE).	48
FIGURE 16: DRONE <i>ONYXSTAR HYDRA-12</i> (GAUCHE) ET CAMÉRA <i>SONY A6000</i> (DROITE).	49
FIGURE 17: SCHÉMA MÉTHODOLOGIQUE DE LA MÉTHODE DE DÉTECTION ET DE PRODUCTION DE CARTES DE DÉPISTAGE DU DORYPHORE.....	53
FIGURE 18: SCHÉMA MÉTHODOLOGIQUE DÉTAILLANT LE PROCESSUS DE CONCEPTION DE L'ALGORITHME DE DÉTECTION PRÉLIMINAIRE.....	54
FIGURE 19: GÉOLOCALISATION DES PARCELLES DE DÉPISTAGE ET DES IMAGES ACQUISES PAR DRONE UTILISÉES POUR LES JEUX DE DONNÉES D'ENTRAÎNEMENT, DE VALIDATION ET DE TESTS.	62

FIGURE 20: HISTOGRAMME DE LA COMPOSANTE TEINTE (H) DES PIXELS DE SEGMENTS DE DORYPHORES ET VALEURS DE SEUILS DÉTERMINÉS	67
FIGURE 21: HISTOGRAMME DE LA COMPOSANTE LUMINOSITÉ (V) DES PIXELS DE SEGMENTS DE DORYPHORES ET VALEURS DE SEUILS DÉTERMINÉS	68
FIGURE 22: HISTOGRAMME DE LA COMPOSANTE TEINTE (H) DES SEGMENTS DE DORYPHORES ET DE NON-DORYPHORES ET VALEURS DES SEUILS DÉTERMINÉS.....	69
FIGURE 23: HISTOGRAMME DE LA CIRCULARITÉ (C) DES SEGMENTS DE DORYPHORES ET DE NON-DORYPHORES ET VALEURS DES SEUILS DÉTERMINÉS	69
FIGURE 24: HISTOGRAMME DE L'ÉLONGATION (E) DES SEGMENTS DE DORYPHORES ET NON-DORYPHORES ET VALEURS DES SEUILS DÉTERMINÉS	70
FIGURE 25: HISTOGRAMME DE L'AIRE (A) DES SEGMENTS DE DORYPHORES ET NON-DORYPHORES ET VALEURS DES SEUILS DÉTERMINÉS.....	70
FIGURE 26: PARCELLE DE DÉPISTAGE #4 DU 19 JUILLET 2018 (DROITE), CLASSIFICATION DE LA VÉGÉTATION (MILIEU) ET LES ZONES POTENTIELLES ISSUES DE LA DÉTECTION PRÉLIMINAIRE (DROITE).....	72
FIGURE 27: PRÉCISION GLOBALE (GAUCHE) ET FONCTION DE COÛT (DROITE) PAR RAPPORT AU NOMBRE D'ÉPOQUES POUR L'ENTRAÎNEMENT ET LA VALIDATION DU MODÈLE RESNET-18 SURÉCHANTILLONNÉ V1....	75
FIGURE 28: PRÉCISION GLOBALE (GAUCHE) ET FONCTION DE COÛT (DROITE) PAR RAPPORT AU NOMBRE D'ÉPOQUES POUR L'ENTRAÎNEMENT ET LA VALIDATION DU MODÈLE RESNET-18 SURÉCHANTILLONNÉ V2....	75
FIGURE 29: PRÉCISION GLOBALE (GAUCHE) ET FONCTION DE COÛT (DROITE) PAR RAPPORT AU NOMBRE D'ÉPOQUES POUR L'ENTRAÎNEMENT ET LA VALIDATION DU MODÈLE RESNET-18 SOUS-ÉCHANTILLONNÉ V1	75
FIGURE 30: PRÉCISION GLOBALE (GAUCHE) ET FONCTION DE COÛT (DROITE) PAR RAPPORT AU NOMBRE D'ÉPOQUES POUR L'ENTRAÎNEMENT ET LA VALIDATION DU MODÈLE RESNET-18 SOUS-ÉCHANTILLONNÉ V2	76
FIGURE 31: PRÉCISION GLOBALE (GAUCHE) ET FONCTION DE COÛT (DROITE) PAR RAPPORT AU NOMBRE D'ÉPOQUES POUR L'ENTRAÎNEMENT ET LA VALIDATION DU MODÈLE RESNET-18 NON BALANCÉ	76
FIGURE 32: PRÉCISION GLOBALE (GAUCHE) ET FONCTION DE COÛT (DROITE) PAR RAPPORT AU NOMBRE D'ÉPOQUES POUR L'ENTRAÎNEMENT ET LA VALIDATION DU MODÈLE RESNET-34 SURÉCHANTILLONNÉ V1....	76
FIGURE 33: PRÉCISION GLOBALE (GAUCHE) ET FONCTION DE COÛT (DROITE) PAR RAPPORT AU NOMBRE D'ÉPOQUES POUR L'ENTRAÎNEMENT ET LA VALIDATION DU MODÈLE RESNET-34 SURÉCHANTILLONNÉ V2....	77
FIGURE 34: PRÉCISION GLOBALE (GAUCHE) ET FONCTION DE COÛT (DROITE) PAR RAPPORT AU NOMBRE D'ÉPOQUES POUR L'ENTRAÎNEMENT ET LA VALIDATION DU MODÈLE RESNET-34 SOUS-ÉCHANTILLONNÉ V1	77
FIGURE 35: PRÉCISION GLOBALE (GAUCHE) ET FONCTION DE COÛT (DROITE) PAR RAPPORT AU NOMBRE D'ÉPOQUES POUR L'ENTRAÎNEMENT ET LA VALIDATION DU MODÈLE RESNET-34 SOUS-ÉCHANTILLONNÉ V2	77
FIGURE 36: PRÉCISION GLOBALE (GAUCHE) ET FONCTION DE COÛT (DROITE) PAR RAPPORT AU NOMBRE D'ÉPOQUES POUR L'ENTRAÎNEMENT ET LA VALIDATION DU MODÈLE RESNET-34 NON BALANCÉ	78
FIGURE 37: PRÉCISION GLOBALE (GAUCHE) ET FONCTION DE COÛT (DROITE) PAR RAPPORT AU NOMBRE D'ÉPOQUES POUR L'ENTRAÎNEMENT ET LA VALIDATION DU MODÈLE RESNET-50 SURÉCHANTILLONNÉ V1....	78

FIGURE 38: PRÉCISION GLOBALE (GAUCHE) ET FONCTION DE COÛT (DROITE) PAR RAPPORT AU NOMBRE D'ÉPOQUES POUR L'ENTRAÎNEMENT ET LA VALIDATION DU MODÈLE RESNET-50 SURÉCHANTILLONNÉ V2....	78
FIGURE 39: PRÉCISION GLOBALE (GAUCHE) ET FONCTION DE COÛT (DROITE) PAR RAPPORT AU NOMBRE D'ÉPOQUES POUR L'ENTRAÎNEMENT ET LA VALIDATION DU MODÈLE RESNET-50 SOUS-ÉCHANTILLONNÉ V1	79
FIGURE 40: PRÉCISION GLOBALE (GAUCHE) ET FONCTION DE COÛT (DROITE) PAR RAPPORT AU NOMBRE D'ÉPOQUES POUR L'ENTRAÎNEMENT ET LA VALIDATION DU MODÈLE RESNET-50 SOUS-ÉCHANTILLONNÉ V2	79
FIGURE 41: PRÉCISION GLOBALE (GAUCHE) ET FONCTION DE COÛT (DROITE) PAR RAPPORT AU NOMBRE D'ÉPOQUES POUR L'ENTRAÎNEMENT ET LA VALIDATION DU MODÈLE RESNET-50 NON BALANCÉ	79
FIGURE 42: EXEMPLES DE VRAIS POSITIFS, VRAI NÉGATIFS, FAUX POSITIFS ET FAUX NÉGATIFS POUR LE MODÈLE RESNET-18 NON BALANCÉ 15-1	84
FIGURE 43: EXEMPLES DE VRAIS POSITIFS, VRAI NÉGATIFS, FAUX POSITIFS ET FAUX NÉGATIFS POUR LE MODÈLE RESNET-34 NON BALANCÉ 15-1	84
FIGURE 44: EXEMPLES DE VRAIS POSITIFS, VRAI NÉGATIFS, FAUX POSITIFS ET FAUX NÉGATIFS POUR LE MODÈLE RESNET-50 SURÉCHANTILLONNÉ V1.....	84
FIGURE 45: BOÎTES À MOUSTACHES PRÉSENTANT LES RÉSULTATS DE PRÉCISION, RAPPEL ET F1-SCORE DES DIFFÉRENTS MODÈLES ENTRAÎNÉS POUR LES IMAGES DE LA BASE DE DONNÉES TEST SÉPARÉES SELON LES ACQUISITIONS DU 19 JUILLET 2018 (SORTIE 1 EN BLEU) ET DU 30 JUILLET 2018 (SORTIE 2 EN MAUVE) AINSI QUE POUR L'ENSEMBLE DES IMAGES DU JEU DE DONNÉES TEST (TOTAL EN ROUGE)	86
FIGURE 46: EXEMPLE DE CARTE DE DÉPISTAGE POUR L'IMAGE 4981 DU 19 JUILLET 2018 PRODUITE AVEC LE MODÈLE RESNET-50 SURÉCHANTILLONNÉ V1.....	87
FIGURE 47: FOYER D'INFESTATION PHOTOGRAPHIÉ AVEC UNE OUVERTURE DU DIAPHRAGME F2.8 (GAUCHE) ET F3.5 (DROITE) POUR UNE MÊME VITESSE D'OBTURATION (1/4000 SEC).....	95
FIGURE 48: EXEMPLE DE PLAN DE VOL PRIORISANT LES BORDURES ET PARCOURANT EN ZIGZAG L'INTÉRIEUR DE LA PARCELLE AGRICOLE QUI POURRAIT ÊTRE UTILISÉ DANS UN CONTEXTE OPÉRATIONNEL.....	96

LISTE DES ABRÉVIATIONS

ASP : Aéronef sans pilote

AVIRIS : Airborne Visible/Infrared Imaging Spectrometer

DPT : Doryphore de la Pomme de terre

GIEC : Gestion intégrée des Ennemis des Cultures

GNDVI : Green Normalized Difference Vegetation Index

GPS : Positionnement global par Satellites

HSV : Hue Saturation Value

LIDAR : Light Detection and Ranging

MSAVI2 : Modified Soil-adjusted Vegetation Index

NDVI : Normalized Difference Vegetation Index

PBCRC : Plant Biosecurity Cooperative Research Centre

RADAR : Radio Detection and Ranging

RGB : Red Green Blue

RVI : Ratio Vegetation Index

SAVI : Soil-adjusted Vegetation Index

SIG : Système d'Information géographique

SMOTE : Synthetic Minority Over-sampling Technique

SPQA : Stratégie phytosanitaire québécoise en Agriculture

TVDI : Temperature Vegetation Dryness Index

1 INTRODUCTION

1.1 Contexte

La pomme de terre (*Solanum tuberosum L.*) est la plus importante culture légumière au Canada, représentant 29,3% des recettes totales de la production des légumes et 15,4% des recettes totales de la production horticole. En 2016, la production canadienne totale est estimée à 4 770 521 tonnes pour une valeur totale de 1.2 milliard de dollars (AAC, 2017). En 2017, au Québec, la superficie cultivée en pomme de terre est de 17 100 ha, pour une production totale de 567 200 tonnes. Alors que les recettes monétaires sont estimées à 166,9 millions de dollars (ISQ, 2019). Cependant, cette culture d'importance subit des pressions importantes, comme le stress hydrique, les besoins en fertilisants et les ravageurs.

Le Doryphore de la pomme de terre (DPT) est le plus grand ravageur de cette culture et en constitue une grande menace. Avec la hausse de la température anticipée par les changements climatiques, les pressions causées par l'insecte ravageur pourraient augmenter en complétant plus de deux générations annuellement. Le contrôle du ravageur repose sur l'utilisation d'insecticides chimiques, mais leur utilisation est inquiétante et pose des risques pour la santé humaine et l'environnement. Les suivis environnementaux démontrent sans doute que les pesticides utilisés contaminent les eaux souterraines et de surface. Pour la grande majorité des échantillons récoltés lors de ces suivis, les concentrations en néonicotinoïdes dépassent les critères de qualité de l'eau pour la protection de la vie aquatique (OAQ, 2019). Les producteurs de pommes terre commerciaux tolèrent très mal la présence du ravageur et préfèrent une utilisation importante d'insecticide à la perte de rendement qui peut être occasionnée.

Au Michigan, en 1991 lorsque la résistance aux insecticides est apparue, le coût moyen pour contrôler les infestations de DPT était de 306\$/ha alors que pour les régions où il n'y avait pas de résistance aux insecticides le coût était de 35-74\$/ha. Le coût total des dommages et mesures de contrôles était estimé à 13.3 millions en 1994 soit 13.7% de la valeur de la production de pommes de terre totale (Grafius, 1997).

À l'échelle globale, la quantité de pommes de terre produites dans des régions colonisées par le DPT est d'environ 200 millions de tonnes annuellement. Pour un prix de vente moyen de 100\$/tonne, la valeur totale est de \$20 milliards. Le coût du contrôle du DPT est estimé à 5% soit 1 milliard et la perte de rendement est estimée à 10% de la production soit environ \$2 milliards. Le dommage sur les autres types de cultures telles que les tomates et aubergines est estimé à environ \$500 millions. Pour un total d'environ \$3.5 milliards annuel de mesures de contrôles et de pertes de rendements causés par le DPT (Jernelöv, 2017).

Afin de lutter contre l'insecte ravageur de façon durable, il est important de développer des méthodes de gestion intégrée qui utilisent différentes techniques jumelant le dépistage et les méthodes de lutte préventives et directes. Les applications d'insecticides se basent généralement sur des seuils de dommages économiques afin d'assurer l'efficacité et la rentabilité des interventions. Afin de détecter l'atteinte des seuils, un dépistage rigoureux est nécessaire.

Certaines études ont démontré que les applications ciblées d'insecticides peuvent réduire de 30 à 40% la quantité d'insecticide nécessaire pour contrôler le ravageur en comparaison aux traitements systémiques sur les champs au complet et lorsque les densités moyennes d'infestation ont dépassé les seuils d'intervention (Weisz *et al.*, 1996a). Malgré que la répartition spatiale des foyers d'infestations de doryphores soit très agrégée (Harcourt, 1971), il est irréaliste d'effectuer des traitements phytosanitaires ciblés puisque le temps requis et la main-d'œuvre nécessaire pour parcourir complètement les champs sont trop importants.

L'approche conventionnelle employée est de parcourir les bordures du champ (pour les champs avec rotation) et l'intérieur du champ partiellement. Lorsqu'il ne semble pas y avoir d'infestation au milieu du champ, une application d'insecticides sur les bordures (lorsqu'infesté) est employée. Alors que lorsqu'il y a des foyers d'infestations à l'intérieur du champ, une application systémique sur l'ensemble du champ est souvent employée lorsque les seuils d'intervention économiques sont atteints (Communication personnelle : Philippe Parent, agronome chez Patates Dolbec).

1.2 Problématique

Le dépistage des maladies et des ravageurs peut être particulièrement difficile pour des cultures qui s'étendent sur des superficies de plusieurs hectares. L'utilisation des systèmes de télédétection permet un appui aux opérations de dépistage offrant un bon rapport coût/bénéfice afin de détecter les zones affectées par des maladies ou des ravageurs.

Pour la lutte aux ravageurs et maladies des cultures, différents systèmes de télédétection sont utilisés selon l'échelle d'observation du phénomène. La plupart des études utilisent la réponse spectrale de la végétation pour identifier indirectement les zones affectées. Des indices spectraux sont souvent utilisés afin de détecter les zones atteintes puisque ces indices profitent de la réponse spectrale de la chlorophylle présente dans les pigments des végétaux qui absorbe les longueurs d'onde du visible et qui réfléchit les longueurs d'onde du proche infrarouge.

Les capteurs multispectraux et hyperspectraux embarqués aux satellites, avions et drones sont utilisés pour détecter et différencier différents stress biotiques ou abiotiques. De nombreuses études ont utilisé des plateformes comme le satellite ou l'avion et des capteurs multispectraux et hyperspectraux pour détecter les stress infligés par différentes maladies et ravageurs par exemple : différencier le stress infligé par les pucerons des autres types de stress dans la culture du blé (Backoulou *et al.*, 2015), les dommages causés par le tétranyque de la fraise (*Tetranychus*) dans les cultures de coton (Fitzgerald *et al.*, 2004), le verdissement des agrumes (Kumar *et al.*, 2012; Li *et al.*, 2015), la rouille orangée dans la culture de la canne à sucre (Apan *et al.*, 2004), la pourriture de la moutarde *Sclerotinia sclerotiorum* (Bhattacharya & Chattopadhyay, 2013), le virus de la mosaïque du blé (Mirik *et al.*, 2010).

Le potentiel des aéronefs sans pilotes a été évalué par le Centre de Recherche Coopérative en Biosécurité des Plantes (PBCRC) en Australie et au Kansas où des protocoles de surveillance ont été développés pour détecter les espèces d'insectes ravageurs invasifs pour plusieurs cultures, comme le blé, les vignes, le soya et la canne à sucre (McCornack *et al.*, 2018). Une de ces études a permis de corrélérer le NDVI avec la densité d'infestation de la mouche de Hesse ainsi qu'avec la sécrétion du miellat par

les pucerons dans la canne à sucre. Vanegas *et al.* (2018) ont utilisé l'imagerie hyperspectrale acquise par drone pour détecter le phylloxéra de la vigne (*Daktulosphaira vitifoliae*).

Pour le doryphore de la pomme de terre, il y a eu quelques études utilisant les drones et la télédétection afin de développer des outils de surveillance phytosanitaire. Gavelle et Théau (2015) ont étudié la relation entre des paramètres biophysiques et différents indices de végétation. Les indices de végétation tels que le NDVI, SAVI, MSAVI2, GNDVI, RVI et TVDI ont été calculés à partir de l'imagerie multispectrale (visible et proche infrarouge) et de l'imagerie thermique. Les images acquises par drone possèdent une résolution spatiale de 6 cm/pixel pour le capteur multispectral et de 15 cm/pixel pour le capteur thermique à une altitude de 125 m. Les paramètres biophysiques étudiés sont la biomasse humide, la biomasse sèche, la température, la chlorophylle, la luminance et la couverture foliaire des plants. La biomasse humide est le paramètre le plus corrélé avec les indices de végétation étudié avec un coefficient de détermination de 0,81 avec l'indice MSAVI2 pour une régression logarithmique. Des données de dépistage comprenant des zones affectées par des ravageurs, des maladies et des problèmes de croissance ainsi que des zones non stressées ont été utilisées afin d'étudier la relation entre les indices de végétation et les différents stress. Les résultats démontrent une corrélation entre les indices de végétation et les problèmes phytosanitaires dépistés. Toutefois, ces indices ne permettent pas de différencier les types de stress observés ni l'intensité de ces stress. Les cartes spatialisées de stress produites permettent de cibler les opérations de dépistage et constituent un appui aux opérations de traitements phytosanitaires.

Hunt et Rondon (2017) ont utilisé les drones ainsi qu'un capteur multispectral à 6 bandes (rouge, vert, bleu, red-edge, proche infrarouge, capteur d'éclairement) afin de comparer les réflectances des plants de pommes de terre avant et après les infestations de doryphore pour différents degrés d'infestation. Leur plan expérimental est composé de 16 parcelles expérimentales de taille d'environ 2,4 x 10 m où différentes densités de doryphores adultes ont été intégrés aux parcelles. Des dommages ont été observés un jour seulement après l'intégration des doryphores dans les différentes parcelles expérimentales. Les auteurs ont classé les parcelles en ordre de dommages apparent allant de 1 pour peu endommagé à 16 pour la plus endommagée. Deux méthodes de

détection des dommages ont été comparées soit un seuillage de l'indice NDVI et une classification supervisée orientée-objet résultant en trois classes (plant en santé, sol ou plant endommagé par le DPT). La méthode orientée-objet présente les meilleurs résultats avec un coefficient de détermination de 0,85 pour les classements visuels des dommages des parcelles par rapport à la superficie endommagée estimée. Les auteurs ont également étudié la hauteur de la canopée mesurée en stéréoscopie numérique par la méthode « structure à partir d'un mouvement » pour déterminer les zones endommagées. La hauteur de canopée a démontré des dépressions aux mêmes endroits où un dommage était indiqué par le NDVI. Ce projet a démontré l'utilité de l'imagerie multispectrale ainsi que la génération de modèle de hauteur de canopée pour la détection des dommages très rapidement après l'infestation de doryphores.

Les études mentionnées précédemment détectent indirectement la présence du doryphore de la pomme de terre selon les dommages qu'il a causés. Les plants de pommes de terre peuvent subir une défoliation sans qu'il n'y ait de pertes de rendements importantes. Cependant, afin de s'assurer que cette perte de rendement soit minimale et afin de calculer les seuils d'interventions phytosanitaires, il est important de détecter le doryphore lors des stades larvaires. Il est idéal de détecter le ravageur lors des trois premiers stades larvaires qui sont les moins dommageables.

Des études ont été effectuées afin de détecter le doryphore à l'échelle de l'individu à l'aide d'un appareil photographique embarqué sur un drone. Bouroubi *et al.* (2018) ont utilisé un drone DJI Phantom-3 afin d'acquérir des images d'une résolution spatiale de 0,2 mm/pixel. Pour acquérir une telle résolution, le drone doit voler à environ 2 m au-dessus de la canopée. Après avoir testé différentes résolutions, les auteurs mentionnent que la résolution optimale est de l'ordre de 1 mm/pixel. Un réseau de neurones convolutif a été utilisé pour détecter de façon directe les symptômes de la maladie du mildiou dans la culture de la vigne, les larves de doryphores dans la culture de la pomme de terre et les mauvaises herbes dans les cultures de carottes, laitues et oignons. Pour la détection du doryphore, les auteurs ont utilisé une segmentation selon une valeur de seuillage du rapport entre la bande rouge et la bande verte suivi de l'entraînement de séparateurs à vaste marge à partir des activations d'un réseau de neurones convolutifs. Une fenêtre fixe de 50 pixels x 50 pixels a été utilisée pour entraîner l'algorithme avec un ratio de 1

doryphore : 1 non-doryphore. Les résultats présentés dans cet article de conférence démontrent la faisabilité d'utiliser les réseaux de neurones convolutifs pour détecter différents problèmes phytosanitaires dans un contexte de gestion intégrée des ennemis des cultures.

Lors de l'été 2017, au sein de l'équipe du Laboratoire de Télédétection environnementale par Drone (TED) de l'INRS, une étude de faisabilité a été effectuée pour évaluer le potentiel de l'utilisation de la photographie numérique couleur embarquée sur drone pour le dépistage du DPT (Lhissou *et al.*, 2018). Les conditions d'acquisition et les paramètres testés n'ont pas permis d'acquérir des images nettes avec un drone en mouvement, mais ont permis de déterminer la résolution spatiale optimale, soit environ 1 mm/pixel pour des images acquises de façon statique. L'algorithme extrait en premier lieu les zones potentielles pouvant être un doryphore ou du sol à partir d'un espace colorimétrique hybride entre les espaces colorimétriques CIELAB, YCbCr et HSV. De plus, la végétation est masquée de l'image en utilisant l'indice ExcessGreen. L'analyse en composante principale de l'espace colorimétrique hybride est utilisée pour calculer la magnitude du gradient de l'image. Ensuite, une segmentation par seuillage du gradient est utilisée pour repérer les zones potentielles. Une classification est finalement effectuée selon des attributs de formes des segments en utilisant la méthode des K plus proches voisins. La méthode développée a été validée sur des sections d'images et présente une précision globale de 74%. Toutefois, cette méthode ne permet pas de traiter l'entièreté des images dans un contexte opérationnel puisque l'analyse en composante principale et l'extraction des espaces colorimétriques sont trop coûteuses en temps de calcul.

Au niveau de l'identification d'objets au sein des images, il existe deux grands paradigmes, soient : la classification des pixels d'une image et la classification orientée-objet. La classification par pixel a été longtemps utilisée pour les images à faible résolution spatiale, mais pose des lacunes pour les images à haute résolution spatiale. La grande variation des intensités de pixels pour un même objet observé à haute résolution spatiale cause un effet de poivre et sel lorsque la classification est effectuée cette échelle (Blaschke, 2010). Les méthodes de classification orientée-objet sont par la suite apparues proposant une solution à ce problème. Les méthodes orientées-objet reposent sur une segmentation qui regroupe des pixels contigus et semblables ensemble

à différentes échelles. Par la suite, des statistiques et attributs extraits à partir des bandes spectrales ou de la forme des segments sont calculés afin de classer chacun de ces segments. Les algorithmes de classification utilisés pour la classification par pixel ou par objets peuvent être similaires. On peut penser à des méthodes de classification supervisée telles que les séparateurs à vaste marge, les arbres de décision, le maximum de vraisemblance et les K plus proches voisins. Des méthodes non supervisées peuvent également être utilisées comme par exemple les *K-moyennes* ou ISODATA. Cependant, il est important de bien choisir les attributs utilisés lorsqu'on effectue une classification supervisée ou non supervisée afin que ceux-ci soient les plus discriminants possible.

Pour certains problèmes de classification, il peut être très difficile et laborieux d'extraire les attributs discriminants des objets. L'apprentissage profond et plus principalement les réseaux de neurones convolutifs profonds (RNCP) viennent pallier ce problème en extrayant automatiquement les attributs à plusieurs échelles d'observation distinctes. En effet, l'apprentissage profond a démontré des performances de pointes dans la classification et la localisation des objets contenus dans les images numériques (He *et al.*, 2015; Krizhevsky *et al.*, 2012). Afin d'entraîner ces réseaux, on doit utiliser une base de données comprenant de nombreuses images contenant les objets d'intérêts des différentes classes. Ces images peuvent être sous forme de niveaux de gris ou RGB ou avec plusieurs bandes spectrales. Par ailleurs, il a été démontré qu'il est possible d'utiliser des réseaux de neurones préentraînés pour les utiliser dans un contexte différent duquel il a été initialement entraîné. Le « transfert d'apprentissage » réutilise des attributs appris sur des jeux de données différents et nécessite moins d'échantillons pour l'entraînement tout en offrant des performances exemplaires. Par exemple, certaines études ont utilisé des architectures de RNCP pour identifier et localiser certains types d'insectes sur les trappes collantes (Ding & Taylor, 2016) ou pour différencier certaines maladies de plantes cultivées (DeChant *et al.*, 2017; Fuentes *et al.*, 2017; Gandhi *et al.*, 2018; Mohanty *et al.*, 2016b; Rangarajan *et al.*, 2018).

1.3 Objectifs

L'objectif général est de développer une méthode de dépistage automatisée, rapide et efficace des doryphores en utilisant les drones et la photographie couleur d'ultra-haute résolution spatiale. Ce projet a été réalisé en partenariat avec le producteur de pommes de terre Patates Dolbec et le MAPAQ afin d'améliorer les pratiques de dépistage du DPT et de faciliter ainsi l'adoption de pratiques de gestion intégrée des ennemis des cultures.

Afin qu'un tel objectif soit atteint, le projet doit répondre aux objectifs spécifiques suivants :

1. Établir un protocole d'acquisition des images ultra-haute résolution spatiale par drone en déterminant les paramètres d'acquisition (paramètres de vol et de photographie) des images optimaux;
2. Développer une méthode de traitement d'image utilisant l'apprentissage profond permettant d'identifier (larves et adultes), de dénombrer les doryphores et ainsi cibler les foyers d'infestations;
3. Optimiser le processus de détection afin de diminuer la complexité de calcul et le temps de traitement afin de permettre une cartographie des foyers d'infestation rapide et efficace.

2 NOTIONS GÉNÉRALES

2.1 Le doryphore de la pomme de terre

2.1.1 Biologie

Le doryphore de la pomme de terre, *Leptinotarsa decemlineata* (Say, 1824), est un insecte appartenant à l'ordre des coléoptères et de la famille des chrysomélidés. Il est le plus important ravageur de la pomme de terre pouvant détruire complètement les cultures lorsqu'il n'est pas contrôlé. L'insecte originaire du Mexique se nourrit des espèces végétales appartenant à la famille des solanacées dont les pommes de terre, tomates et aubergines font partie (Weber, 2003). Les doryphores adultes mesurent environ 10 mm de longueur et 7 mm de largeur. Ceux-ci sont de forme ovale et de couleur jaune pâle avec cinq rayures noires sur la longueur de chaque élytre et de petits points noirs sur la tête et le corselet (figure 1-a). Les œufs mesurent environ 1.5 mm et sont de couleur jaune pour devenir orange à maturité. Les larves naissantes sont de couleur rougeâtre avec la tête et les jambes noires pour devenir orange et jaune dans les stades larvaires plus avancés (Alyokhin *et al.*, 2013).

Après avoir passé l'hiver caché sous le sol, l'insecte sort de diapause, au début de l'été, afin de coloniser leur plante hôte favori, les pommes de terre. On doit compter une accumulation de 50 à 250 degrés jours ($> 10^{\circ} \text{C}$) (Ferro *et al.*, 1999), avant que le ravageur atteigne la surface du sol. En sortant de diapause, ses muscles sont atrophiés ce qui les empêche de voler afin de coloniser les plants. Il faudra attendre environ 3 à 10 jours après la diapause avant que le DPT puisse se mettre à voler à la recherche de plants de pommes de terre (Boiteau *et al.*, 2003). Le succès reproducteur du ravageur peut être énorme, comme une femelle peut pondre de 300 à 800 œufs durant sa vie (Harcourt, 1971). Une à deux semaines après l'émergence, les femelles pondent des masses de 20 à 60 œufs jaunâtres au-dessous des feuilles de pomme de terre (figure 1-c). Après quelques jours, les œufs éclosent et font naître les petites larves d'une couleur rougeâtre. Les larves du premier stade larvaire sont d'une taille de l'ordre de quelques millimètres alors que les larves du dernier stade larvaires mesurent environ 10 mm x 7

mm et sont d'une couleur orange jaunâtre (Figure 1-b). Ces larves vont passer par quatre stades larvaires sur une période de 10 à 20 jours selon la température et l'abondance de nourriture (figure 1-d et figure 2). Par la suite, une fois que les larves ont atteint la maturité celles-ci vont descendre des feuilles pour effectuer la pupaison sur le sol avant de se transformer en adultes après 10 à 20 jours (Alyokhin *et al.*, 2013). C'est ainsi que le cycle recommence pouvant créer une à quatre générations en une seule année selon les conditions climatiques et la disponibilité en nourriture. Lorsque la température se refroidit et que l'hiver approche, le doryphore adulte entre en diapause et s'enfouit dans le sol à une profondeur d'environ 20 à 25 cm. Dans les régions plus froides comme au Canada, il peut creuser jusqu'à 120 cm pour se protéger du gel (Hurst, 1975). La durée de vie d'un adulte est de 1 à 2 ans et celui-ci peut consommer jusqu'à 10 cm² de feuillage par jour. Alors qu'une seule larve consomme jusqu'à 40 cm² durant tous les stades larvaires (Ferro *et al.*, 1985).

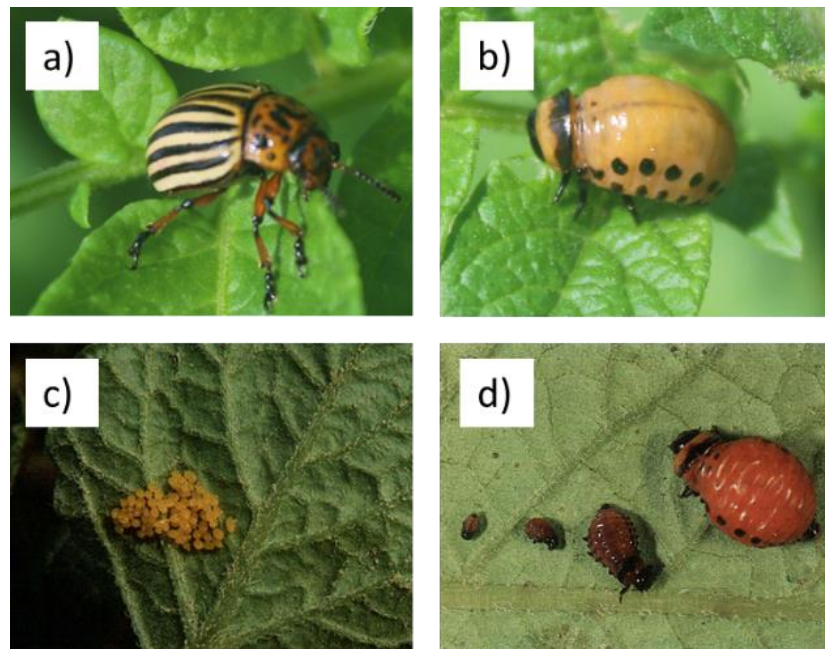


Figure 1: a) Doryphore adulte; b) 4e stade larvaire du doryphore; c) œufs non éclos de doryphore ; d) les quatre stades larvaires du doryphore (Source: a) et b) : photo par Patrick Chatelle (INRS), c) et d) : photo par le MAPAQ (<https://www.agrireseau.net/pdt/documents/VT045.>))




Figure 2: Cycle de vie du doryphore de la pomme de terre (Source: Khelifi, 2007).

2.2 La gestion intégrée des ennemis des cultures

L'Organisation des Nations Unies pour l'Alimentation et l'Agriculture définit la Gestion intégrée des Ennemis des Cultures (GIEC) comme étant : « la prise en compte de toutes les techniques de lutte antiparasitaire disponibles et l'intégration subséquente de mesures appropriées qui découragent le développement de populations de ravageurs et maintiennent les pesticides et autres interventions à des niveaux économiquement justifiés et réduisent ou minimisent les risques pour la santé humaine et pour l'environnement. La lutte intégrée contre les parasites met l'accent sur la croissance d'une culture saine en perturbant le moins possible les agroécosystèmes et encourage les mécanismes naturels de lutte contre les parasites » (FAO, 2019).

La GIEC se base les cinq étapes suivantes (MAPAQ, 2014) :

- 1) La connaissance : Connaître les espèces nuisibles à la culture d'intérêt, leur cycle de vie, leurs ennemis naturels ainsi que le mode de gestion.

- 2) La prévention : Par la sélection de sites moins à risques, d'un choix de cultiver plus résilient, la période de semis, gestion des fertilisants et de l'irrigation, mesures sanitaires et aménagement de l'habitat.
- 3) Suivi des champs : Le dépistage des champs par échantillonnage permettant de déterminer l'atteinte de seuils d'intervention. La surveillance par l'utilisation de modèles prévisionnels, de pièges à phéromones, pièges collants ou autre méthode de surveillance.
- 4) Intervention : Contrôle des populations d'ennemis des cultures par une lutte qui peut être mécanique, biologique ou chimique. Il est également possible de combiner différentes méthodes directes de lutte antiparasitaire.
- 5) Évaluation – rétroaction : La dernière étape consiste à évaluer l'efficacité des traitements apportés par la récolte de données de phytoprotection permettant d'apporter des modifications et ajustements, augmentant ainsi la connaissance des ennemis des cultures.

La Stratégie phytosanitaire québécoise en Agriculture (SPQA) 2011-2021 a comme objectif général d'accroître l'adoption de la GIEC et de réduire les risques des pesticides pour la santé et l'environnement en assurant la viabilité économique des productions agricoles (SPQA, 2011).

2.2.1 Le dépistage du doryphore de la pomme de terre

Le dépistage constitue donc une opération importante de l'étape 3 et de l'étape 5 de la GIEC. Différentes méthodes sont employées pour détecter si les cultures ont atteint les seuils économiques d'intervention pour l'utilisation de diverses méthodes de contrôles ou pour localiser les foyers d'infestations des doryphores.

La technique du « boom de l'éclosion », adaptée au Québec par Desaulniers (1996), est utilisée pour déterminer le moment d'application des insecticides. Cette méthode consiste à localiser, dès la levée des plants, 30 feuilles portant des masses d'œufs dans une zone représentative de l'ensemble du champ afin de déterminer le moment où la densité de larves est la plus élevée. Les masses d'œufs sont suivies afin de calculer chaque jour le nombre d'œufs qui sont éclos et ainsi calculer le pourcentage cumulatif d'éclosion. Après

quelques jours, le taux d'éclosion augmente progressivement et lorsqu'il dépasse 30%, c'est le « boom de l'éclosion ». Environ 6 à 9 jours, selon la température, après la date du « boom de l'éclosion », si on trouve plus de 5 larves par plants, il est conseillé d'appliquer un insecticide afin de contrôler les populations du doryphore (Desaulniers, 1996). Bien que la méthode du « boom de l'éclosion » permette de connaître le moment idéal pour le traitement des insecticides, cette méthode informe peu sur la distribution spatiale du ravageur.

Weisz *et al.* (1996a) a étudié l'impact de la gestion spécifique des applications d'insecticides au champ sur les rendements dans la culture de la pomme de terre. Dans leur étude, ils ont calculé la distribution spatiale des adultes émergents, des grosses larves de première génération et des adultes de la première génération en effectuant un échantillonnage manuel selon les observations du dessus de la canopée. Les champs de superficie variable sont divisés en blocs de 30 x 12 m (12 rangs) et chaque bloc est échantillonné en relevant aléatoirement 10 tiges de pommes de terre en deux sections distinctes du bloc (20 échantillons par bloc). Le nombre d'individus est recensé à chaque semaine à partir des observations du dessus de la canopée. Les densités absolues ont été estimées à partir d'un modèle de régression linéaire développé dans une étude précédente (Weisz *et al.*, 1995) qui démontre la corrélation entre les observations du dessus de la canopée et les densités absolues. Ceux-ci ont démontré que pour les trois champs commerciaux étudiés pour lesquels il y a eu rotation de cultures, les populations de doryphores sont très agrégées. Au moins la moitié de la superficie des champs présentait des densités d'infestations dans les deux déciles inférieurs tandis que les infestations les plus denses étaient observées sur une superficie inférieure à 5% de la superficie des champs. Avec des applications d'insecticides ciblées, les auteurs estiment qu'il est possible de réduire de 30 à 40% la quantité d'insecticide utilisé en comparaison aux applications systémiques sur l'étendue complète du champ.

2.2.2 Moyens de lutte contre le doryphore de la pomme de terre

Malgré de nombreuses discussions sur ses avantages, la GIEC est encore loin d'être universellement adoptée par les producteurs commerciaux de pommes de terre. Présentement, en Amérique du Nord, le contrôle du doryphore de la pomme de terre est

basé sur l'utilisation de l'imidaclopride qui est appliqué au sillon ou au planton. Peu de producteurs appliquent le premier niveau de GIEC soit d'effectuer un dépistage et d'appliquer des insecticides chimiques lorsque les seuils d'intervention économiques sont atteints (Alyokhin, 2009). Selon la littérature, les luttes contre le doryphore peuvent être classées comme suit :

Lutte chimique

Durant les deux dernières décennies, les producteurs de pommes de terre ont principalement utilisé des insecticides de la famille des néonicotinoïdes. Bien que l'adoption d'insecticides à base de néonicotinoïdes appliqués au sol a été largement bénéfique pour l'industrie de la pomme de terre en réduisant l'utilisation d'insecticides foliaires à large spectre (ex. carbamates, pyréthroïdes et organophosphates), l'émergence d'une résistance aux insecticides et d'autres impacts non ciblés possibles (ex. toxicité pour les pollinisateurs et contamination des eaux souterraines) menace la durabilité à long terme de ces composés (Huseth *et al.*, 2014). Des plans d'intervention priorisant l'utilisation d'insecticides à différents modes d'action sont proposés par Huseth *et al.* (2014) selon l'avancement des populations de ravageur.

Lutte biologique

Le DPT possède quelques ennemis naturels en Amérique du Nord comme plusieurs espèces de coccinelles indigènes et exotiques telles que *Coleomegilla maculata*, *Lebia grandis* qui est un carabidé spécialisé qui agit comme parasitoïde nymphal, quelques espèces de punaises, deux espèces de parasitoïdes tachines *Myiopharus aberrans* et *Myiopharus doryphorae* et une variété de prédateurs arthropodes généralistes des genres *Orius*, *Geocoris* et *Nabis*, *Carabidae*, *Cantharidae* et *Opiliones*. Des études d'évaluation moléculaire de la prédation ont permis de déterminer que les adultes de *Podisus maculiventris* et que *Lebia grandis* sont les prédateurs les plus efficaces du DPT (Weber, 2013). Une étude utilisant des lâchés de punaises soldat *Podisus maculiventris* au champ par un système de lâché mécanique a démontré la faisabilité et l'efficacité d'une telle méthode (de Ladurantaye, 2011) par contre cette méthode est difficilement rentable économiquement pour les producteurs commerciaux.

Des biopesticides peuvent également être utilisés pour contrôler le DPT. Le biopesticide le plus utilisé est un insecticide à base d'endotoxines de *Bacillus thuringiensis*. Toutefois, le DPT a commencé développé une résistance à ce biopesticide (Federici, 1999).

Lutte préventive

Il existe d'autres méthodes de contrôle du doryphore que l'utilisation d'insecticides chimiques qui peuvent être préventives ou curatives. Une des méthodes préventives les plus efficaces est la rotation des cultures. En effet les doryphores peuvent se déplacer sur une distance maximale de 1,45 km afin de coloniser une nouvelle plantation (Weisz *et al.*, 1996b). La rotation des cultures permet de ralentir la colonisation assez pour réduire le besoin d'application d'insecticides en début de saison d'un traitement ou plus (Wright, 1984). Une distance entre les cultures de 400 m est prouvée être efficace pour réduire en grande partie les populations de doryphore colonisant les champs (Sexson & Wyman, 2005). Pour qu'une telle méthode soit efficace, les producteurs de la région doivent collaborer ensemble afin de coordonner leurs plans de rotation de cultures.

Afin de prévenir effectivement l'arrivée des doryphores dans les cultures de pomme fraîchement plantées, il est possible d'utiliser des pièges sous forme de tranchées dans le sol recouvertes d'une pellicule de plastique d'environ 25 cm de profondeur (Boiteau *et al.*, 1994).

L'utilisation de cultures trappes consiste à installer des cultures placées stratégiquement entre les sites de diapause et la culture principale afin d'y attirer les doryphores fraîchement sortis du sol suite à la diapause. Cette technique permet d'intercepter les doryphores avant qu'ils colonisent la culture principale (Khelifi *et al.*, 2007).

Lutte physique

Khelifi *et al.* (2007) ont effectué une revue exhaustive des méthodes alternatives aux insecticides chimiques permettant de contrôler le doryphore de la pomme de terre. Cette étude présente notamment des méthodes physiques qui ont été prouvées efficaces pour contrôler le ravageur une fois que celui-ci a colonisé la culture. Notamment, des méthodes utilisant l'énergie thermique et pneumatique ont été étudiées afin de prouver leur efficacité. Le contrôle thermique vise à éliminer principalement les doryphores

adultes par la chaleur (75°C à 200°C) sans endommager les plants. Le contrôle pneumatique vise à retirer les doryphores des plants de pommes de terre par une force pneumatique comme le ferait un aspirateur. Lague *et al.* (1999) ont conçu un appareil combinant les méthodes pneumatiques et thermiques.

Dépendre d'une seule méthode de contrôle, qu'elle soit chimique, biologique ou physique, constitue un piège dangereux. Il s'agit de « mettre tous les œufs dans le même panier », l'erreur d'une telle approche ayant été démontrée à maintes reprises et à grands frais tout au long de l'histoire de la lutte antiparasitaire. Les producteurs de pommes de terre doivent s'équiper d'un éventail de méthodes de contrôle afin de réduire les risques de développement de résistance, réduire les risques associés à l'utilisation d'insecticides chimiques et augmenter l'efficacité des mesures de contrôles (Alyokhin, 2009). Les doryphores utilisent une stratégie adaptative pour distribuer leur progéniture autant dans le temps que dans l'espace et s'adaptent extrêmement bien aux différentes pressions infligées, ce qui en fait une menace difficile à gérer. Afin de bien contrôler l'insecte d'une manière viable économiquement et environnementalement, la seule option est de déterminer une solution basée sur la science intégrant plusieurs méthodes de contrôle dans une approche dynamique de gestion intégrée des ennemis de la culture (Alyokhin *et al.*, 2013).

2.2.3 Seuils d'interventions phytosanitaires

Lorsque le ravageur n'est pas contrôlé, il peut complètement défolier les plants de pommes de terre et empêcher la formation de tubercules pouvant causer une perte totale de la production de pomme de terre (Hare, 1990). Le rendement des pommes de terre est plus vulnérable aux dommages lors du stade de formation des tubercules. Les stades de croissance végétative et de maturité sont les stades où le plant peut subir une défoliation plus importante (Dripps & Smilowitz, 1989). Les seuils d'action pour les applications d'insecticides se font souvent selon la défoliation et le stade phénologique.

Des seuils d'action ont été déterminés en Virginie (É.-U.) pour contrôler le DPT avant qu'un dommage soit causé aux tubercules. On parle de 20% entre l'émergence et la première floraison, 30% entre la première et la dernière floraison et de 60% de défoliation

entre la dernière floraison et la récolte (Zehnder *et al.*, 1995). Selon Ferro *et al.* (1985), il devrait y avoir une intervention phytosanitaire lorsque les densités excèdent 0,5 adulte, 4 petites larves (1^{er} et 2^e stades larvaires) ou 1,5 grosses larves (3^e et 4^e stades larvaires) par tige de pomme de terre. Tandis que Martel *et al.* (1986) ont établis un seuil économique de 20 larves par plant suite à un échantillonnage aléatoire pour une perte de rendement d'environ 10%. Sachant que la densité de plantation moyenne est de 3,6 plants/m² ou de 17 tiges/m² (Bouchard, 1992), les seuils d'intervention, selon Ferro *et al.* (1985), sont de 9 adultes/m², 68 petites larves/m² ou de 26 grosses larves/m². Tandis que selon Martel *et al.* (1986), le seuil d'intervention est de 72 larves de doryphores/m². Il faut considérer que ces seuils d'interventions tiennent compte de l'ensemble des doryphores et non seulement ceux qui sont visibles au sommet du couvert végétal. Selon les régressions linéaires établies entre les observations relatives au sommet de la canopée et les densités absolues établies par Weisz *et al.* (1995) avec les équations de régression suivantes :

$$\text{Densité absolue Adultes} = 1.14 * A + 0.02 \quad (1)$$

$$\text{Densité absolue Grosses larves} = 1.16 * GL + 0.02 \quad (2)$$

Où A est la densité relative d'adulte et GL la densité relative de grosses larves selon les observations au sommet de la canopée.

On obtient des seuils d'intervention relatifs au sommet de la canopée par m² de :

- Selon Ferro *et al.* (1985) :
 - 7 adultes au sommet de la canopée/m²
 - 21 grosses larves au sommet de la canopée/m²
- Selon Martel *et al.* (1986) :
 - 62 larves au sommet de la canopée/m²

2.3 L'agriculture de précision et la télédétection

L'agriculture de précision est un mode d'exploitation qui vise à gérer les ressources telles que l'eau, les engrais, le sol, et les semences afin d'augmenter la production, le rendement, la qualité et de réduire le gaspillage afin que le système existant devienne écologique. Le positionnement global par satellites (GPS), les systèmes d'informations géographiques (SIG), la télédétection ainsi que de nombreux capteurs sont utilisés en agriculture de précision afin de déterminer la variabilité spatiale au champ et d'adapter les pratiques culturales (Srinivasan, 2006). La caractérisation de la variabilité spatiale intrinsèque des parcelles agricoles peut se traduire par la production de cartes des propriétés du sol ou de rendement potentiel et permet l'utilisation de mesures d'applications à taux variable de fertilisants, pesticides ou de densité d'ensemencement (Weisz *et al.*, 1996a). Ce mode d'exploitation est intimement lié à l'agriculture durable définie comme étant celle qui, à long terme, améliore la qualité de l'environnement et des ressources dont dépend l'agriculture, répond aux besoins fondamentaux en aliments et en fibres des humains, est économiquement viable et améliore la qualité de vie des agriculteurs et de l'ensemble de la société (Bongiovanni, 2004).

Actuellement, plus de la moitié des technologies d'agriculture de précision utilisées au Québec sont liées au drainage des parcelles agricoles afin d'éviter les accumulations d'eau qui causent des pertes de rendement (CRAAQ, 2015). Aux États-Unis, ce sont le guidage et l'autoguidage par GPS de la machinerie agricole qui sont les pratiques les plus utilisées. La télédétection demeure peu utilisée en agriculture de précision face à son potentiel réel. Les avancées de technologie importantes et récentes telles que la miniaturisation des capteurs, les nuages de stockage, les processeurs graphiques, l'apprentissage profond et les nouvelles réglementations de Transport Canada concernant l'utilisation des drones permettront sans doute à démocratiser l'utilisation de la télédétection en agriculture de précision.

2.3.1 La télédétection en agriculture de précision

Les applications de la télédétection en agriculture consistent généralement à analyser et interpréter le signal électromagnétique réfléchi par la végétation en culture. Ce signal

procure une source d'information précieuse et permet la prise de décision éclairée. Un système de télédétection est composé d'une plateforme ainsi que d'un capteur monté sur celle-ci. Ces systèmes permettent de mesurer à distance la quantité d'énergie réfléchie ou émise par les plants et le sol d'une culture. Les plateformes utilisées en télédétection sont généralement les satellites, les aéronefs avec et sans pilote ainsi que les ballons aériens. Les capteurs utilisés en agriculture peuvent couvrir le spectre électromagnétique de l'ultra-violet aux micro-ondes. Certains capteurs optiques permettent de mesurer la luminosité de la cible ainsi que de mesurer l'éclairement incident afin de calculer la réflectance. La réflectance est en fait le rapport entre la luminosité et l'éclairement pour une longueur d'onde donnée. Ces systèmes ont démontré leur potentiel en agriculture de précision par leur efficacité pour le suivi de la croissance (Bendig *et al.*, 2015; Berni *et al.*, 2009; Córcoles *et al.*, 2013; Jannoura *et al.*, 2015; Vega *et al.*, 2015), le phénotypage (Araus & Cairns, 2014; Sugiura *et al.*, 2016), la prédiction des rendements (Yu *et al.*, 2016; Zhou *et al.*, 2017), la détection du stress hydrique (Gago *et al.*, 2015; Santesteban *et al.*, 2017; Zarco-Tejada *et al.*, 2012), la détection des mauvaises herbes (Torres-Sánchez *et al.*, 2014) et la détection des maladies et des insectes ravageurs (Bouroubi *et al.*, 2018; Gavelle, 2015; Hunt & Rondon, 2017; McCornack *et al.*, 2018; Vanegas *et al.*, 2018) pour différentes cultures.

Les plateformes de télédétection

Le choix d'un système de télédétection est gouverné par un compromis entre la résolution spectrale, la résolution spatiale, la fréquence de revisite et l'accessibilité. Les satellites d'observation de la Terre ont grandement évolué dans les dernières années. Il y a une quarantaine d'années, les premiers satellites d'observation de la Terre furent lancés, mais les performances offertes à l'époque étaient limitées. Par exemple, LANDSAT-5 offrait une résolution spatiale de 30 m et une résolution temporelle de 16 jours tandis que SPOT-1 offrait une résolution spatiale de 20 m et temporelle de 26 jours (Mulla, 2013). Les satellites disponibles aujourd'hui offrent une performance nettement supérieure permettant d'offrir à la fois une très haute résolution spatiale et une fréquence de revisite élevée (Satellites à très haute résolution spatiale (adapté de Sozzi *et al.*, 2018 et de Effigis, 2017) Tableau 1). Les images acquises par télédétection doivent subir une série

de traitements tels que les corrections géométriques, les corrections atmosphériques et le calcul d'indice spectral afin que celles-ci puissent être analysées. Certains satellites offrent à faible coût ou gratuitement leur produit (Sentinel-2) alors que pour d'autres le coût minimum d'une image de 10000 ha peut être jusqu'à 2850 \$ (WorldView-2/3/4) en incluant les traitements post-acquisition (Tableau 2). Les besoins d'imagerie en agriculture de précision nécessitent généralement une très haute résolution spatiale à une échelle globale et avec un temps de revisite élevé afin de permettre d'acquérir des images à des moments clés de la saison de croissance. Les derniers capteurs satellites d'observation de la Terre à très haute résolution spatiale offrent une source de données précieuse qui permet d'être utilisée directement par les agriculteurs avec un très bon rapport qualité/prix.

Tableau 1: Satellites à très haute résolution spatiale (adapté de Sozzi *et al.*, 2018 et de Effigis, 2017)

Satellites	Résolution spatiale (m pixel⁻¹)	Résolution spectrale (VIS/PIR) (nm)	Résolution radiométrique (bits pixel⁻¹)	Temps de revisite (jours)
Deimos-2	4	466-697/770-892	10	2
Dove (Planet)	3.125	420-700/770-900	16	1
GeoEye-1	2	450-690/780-920	11	3
Kompsat-2	4	450-690/760-900	14	6
Kompsat-3	2-2.8	450-690/760-900	14	3
Kompsat-3A	1.6	450-690/760-900	14	3
Landsat-7/8	30	450-690/770-900	8, 12	8
Pleiades-1A/1B	2	430-720/750-950	12	1
RapidEye	5	440-785/690-850	12	5.5
Sentinel-2	10 et 20	458-680/785-900	16	5
Spot-6/7	6	455-695/760-890	12	1
WorldView-2/3/4	1.6-2	450-690/770-1040	11	1

Tableau 2: Coût d'acquisition des différents satellites à très haute résolution spatiale (adapté de Sozzi *et al.*, 2018)

Satellites	Aire minimum par commande (<i>ha</i>)	Prix par unité de surface (\$ <i>ha</i> ⁻¹)	Prix minimum * (\$)	Espace de stockage (<i>KB ha</i> ⁻¹)
Deimos-2	10000	0.060	700	50
Dove (Planet)	10000	0.012	218	8
GeoEye-1	10000	0.275	2850	100
Kompsat-2	2500	0.055	237.5	20
Kompsat-3	2500	0.110	375	50
Kompsat-3A	2500	0.160	500	100
Landsat-7/8	3700000 (1 scène)	0	09-avr	0.5
Pleiades-1A/1B	10000	0.213	2225	100
RapidEye	10000	0.012	218	4
Sentinel-2	1200000 (1 scène)	0	100	0.63
Spot-6/7	10000	0.045	550	8
WorldView-2/3/4	10000	0.275	2850	130

* prix minimum est déterminé par l'aire minimale par commande multipliée par le prix par unité de surface plus le coût de traitement des données

Malgré ces avancées importantes au niveau des satellites d'observation de la Terre, ces systèmes proposent tout de même certaines lacunes, car la qualité des images est affectée par les conditions météorologiques, les corrections atmosphériques et géométriques. De plus, la résolution spatiale et temporelle est faible en comparaison à ce que les drones peuvent offrir (Babankumar *et al.*, 2017). Les avions sont également utilisés comme plateforme en agriculture de précision et plusieurs études montrent leur efficacité (Fitzgerald *et al.*, 2004; Kumar *et al.*, 2012; Lan *et al.*, 2009). Le tableau suivant (Tableau 3) présente les avantages et inconvénients des différents types de plateformes de télédétection.

Tableau 3: Comparaison des différentes plateformes de télédétection (adapté de Candiago *et al.*, 2015)

Plateforme	Résolution spatiale	Largeur de fauchée	Convivialité	Charge	Coût d'acquisition
Aéronef sans-pilote	0.5 - 10 cm	50 - 500 m	Très bon	Limitée	Très faible
Hélicoptère	5 - 50 cm	0.2 - 2 km	Nécessite un pilote	Limitée	Moyen
Aéronef	0.1 - 2 m	0.5 - 5 km	Nécessite un pilote	Illimitée	Élevé
Satellite	1 - 25 m	10 - 50 km	-	-	Très élevé

Les systèmes aériens de télédétection sans pilote (ASP), communément appelés drones, sont parmi les solutions les plus prometteuses en agriculture de précision pour le suivi des cultures. Ces systèmes sont avantageux puisque leur déploiement est flexible, ils peuvent soutenir une variété de capteurs, la résolution spatiale est très peu limitée, il est possible de reconstruire des mosaïques d'images orthorectifiées à partir des données acquises, on peut visualiser les données immédiatement après un vol et leur coût d'utilisation est relativement faible (Zhang & Kovacs, 2012).

Les ASP sont définis comme étant des véhicules aériens ayant la capacité de voler sans qu'il y aille de pilote à bord pour contrôler la direction et la vitesse et pouvant supporter une charge, comme un capteur, permettant d'acquérir de l'information à distance (Sankaran *et al.*, 2015). Ces systèmes sont classés en quatre types soient les parachutes, les dirigeables, les rotocoptères ou les ailes fixes. Chaque type de plateforme d'ASP possède ses avantages et inconvénients qui sont présentés dans le Tableau 4.

Le rotocoptère est la plateforme permettant de voler à la plus basse altitude, permettant donc d'offrir une très haute résolution spatiale. Ce système permet de supporter une vaste gamme de capteurs allant de la caméra multispectrale, hyperspectrale ou la caméra numérique couleur. Les piles utilisées par ce système contribuent elles-mêmes à une grande partie de la charge du système. Le temps de vol du système est limité par la capacité des batteries utilisée, le nombre de moteurs du système et la charge supportée.

Tableau 4 : Types de plateformes de systèmes aériens sans pilote (adapté de Sankaran, 2015).

Type	Charge (kg)	Temps d'autonomie de vol (min)	Avantages	Désavantages	Exemples
Parachute	1.5	10-30	<ul style="list-style-type: none"> • Simple d'opération 	<ul style="list-style-type: none"> • Non utilisable lors de conditions venteuses • Charge limitée 	Hawkeye
Dirigeables	>3.0	≈ 600	<ul style="list-style-type: none"> • Simple d'opération 	<ul style="list-style-type: none"> • Non utilisable lors de conditions venteuses • Charge limitée 	AB1100, Cameron Fabric Engineering
Rotocoptère	0.8 – 8.0	8 – 120	<ul style="list-style-type: none"> • Plan de vol programmable • Possibilité de vol sur place • Peut supporter une grande variété de capteurs (caméras thermiques, multispectrales, hyperspectrales) • Permet le vol à une faible altitude 	<ul style="list-style-type: none"> • La charge peut limiter le temps de vol 	DJI Inspire, Mikrocopter ARK OktoXL 6S12, Yamaha RMAX, OnyxStar HYDRA-12, etc.
Aile fixe	1.0 - 10	30 - 240	<ul style="list-style-type: none"> • Plan de vol programmable • Peut supporter une grande variété de capteurs 	<ul style="list-style-type: none"> • Limitée dans sa capacité de vol stationnaire • Basse vitesse de vol est requise pour le mosaïquage des images 	Landcaster Precision Hawk, senseFly eBee

Les capteurs de télédétection utilisés en agriculture de précision

Les capteurs d'imagerie aéroportés peuvent être classés dans les catégories multispectrales et hyperspectrales en fonction du nombre de bandes spectrales et de la largeur des bandes. Les capteurs d'imagerie multispectrale mesurent généralement l'énergie réfléchie ou émise dans 3 à 12 bandes spectrales différentes. En revanche, les capteurs d'imagerie hyperspectrale mesurent le rayonnement dans des dizaines, voire des centaines de bandes spectrales étroites sur l'ensemble du spectre électromagnétique. Les images produites à partir de capteurs hyperspectraux contiennent beaucoup plus de détails spectraux que les images de capteurs multispectraux et ont un grand potentiel pour détecter des différences subtiles entre des objets au sol et des caractéristiques similaires (Yang, 2018). Les capteurs infrarouges thermiques sont utilisés pour caractériser le stress hydrique de la plante, puisque sa température augmente lorsqu'elle cesse de transpirer afin de conserver son eau (Gago *et al.*, 2015). Les capteurs micro-ondes actifs (RADAR) sont utilisés pour certaines applications en agriculture telle que l'estimation de l'humidité du sol, la classification des cultures, l'estimation de l'indice de surface foliaire et de la biomasse (Liu *et al.*, 2019). Les capteurs LIDAR sont également utilisés en agriculture précision puisque les pulsions lasers envoyées par le capteur permettent de mesurer des distances. La distance est donnée par la mesure du délai entre l'émission d'une impulsion et la détection d'une impulsion réfléchie. Ce capteur permet de calculer des modèles numériques d'altitude et de surface précis. Ces modèles numériques peuvent être utilisés afin de planifier le nivellement des parcelles agricoles et estimer la hauteur de la végétation par exemple (Estrada *et al.*, 2017). La caméra numérique digitale est également utilisée comme elle permet d'acquérir une très haute résolution spatiale et à un coût d'acquisition très abordable en comparaison aux autres capteurs de télédétection.

2.4 Vision assistée par ordinateur

Les systèmes de vision par ordinateur ont souvent pour but d'identifier et/ou de localiser des objets dans une image. Pour ce faire, il est nécessaire de caractériser l'information pertinente présente dans une image afin de décrire son contenu. Chaque objet d'une

image peut être décrit par un vecteur de caractéristiques. Ces caractéristiques peuvent être, par exemple, l'intensité des pixels d'une bande de l'image, la texture d'un pixel pour un voisinage donné ou la forme d'un segment de pixels connectés. Il existe deux grandes familles de méthodes pour extraire des caractéristiques : de façon manuelle avec les connaissances d'un expert ou de façon automatique par l'apprentissage profond. Les caractéristiques peuvent ensuite être utilisées pour classifier différents objets (ex. identifier une espèce d'insecte) en utilisant un algorithme d'apprentissage machine qui peuvent être supervisées (ex. K plus proches voisins, séparateurs à vaste marge, arbres de décisions, réseau de neurones) ou non supervisé (ex. k-moyennes, regroupement hiérarchique). En entomologie, la vision numérique propose des applications très intéressantes dans un contexte de gestion intégrée des ennemis des cultures afin de déterminer la présence ou l'absence d'une espèce d'insecte donnée et afin d'automatiser les opérations de dépistage et d'identifier les espèces difficiles à différencier.

2.4.1 La segmentation des images numériques

La segmentation d'images est souvent la première étape dans l'analyse des images et la reconnaissance d'objets. C'est une étape cruciale tout en étant une composante essentielle de l'analyse des images numériques en plus d'être une des tâches les plus difficiles en traitement d'images qui détermine la qualité du résultat final. La segmentation d'image est un processus qui divise l'image en différentes régions dans le but que chaque région soit homogène tout en étant hétérogène par rapport à ses voisins (Cheng *et al.*, 2001). Les segmentations d'image peuvent se faire à partir d'une image en niveaux de gris ou une image couleur qui peut être sous différents espaces colorimétriques. Il existe plusieurs méthodes de segmentation d'images qui sont décrites dans le Tableau 5. D'autres méthodes de segmentation peuvent s'apparenter à la classification des images en étant soit supervisées ou non supervisées. Pour les algorithmes de segmentation supervisée, on retrouve : maximum de vraisemblance, les arbres de décisions, les K plus proches voisins, les séparateurs à vaste marge et plusieurs autres. Parmi les méthodes non supervisées, on retrouve : le seuillage adaptatif, la méthode floue des k-moyennes, la transformée en composantes principales/découpage médianes, séparation et regroupement et la segmentation multirésolution (Cheng *et al.*, 2001).

Tableau 5: Méthodes de segmentation des images numériques (adapté de Cheng et al., 2001)

Technique de segmentation	Description de la méthode	Avantages	Désavantages
Seuillage de l'histogramme	Requiers que l'histogramme d'une image ait un certain nombre de pics, chacun correspondant à une région.	<ul style="list-style-type: none"> • Ne nécessite pas d'information préalable ; • Fonctionne bien pour la plupart des images et faibles en complexité de calcul. 	<ul style="list-style-type: none"> • Ne fonctionne pas bien pour une image sans pics évidents ou avec de larges vallées ; • Ne tient pas compte des détails spatiaux et ne peut pas garantir que les régions segmentées soient contiguës.
Regroupement d'espaces de caractéristiques	<p>Suppose que chaque région de l'image forme un faisceau distinct dans l'espace de l'élément. Peut généralement se décomposer en deux étapes :</p> <ol style="list-style-type: none"> 1. Classer les points de l'espace de caractéristiques en grappes ; 2. Relier les grappes au domaine spatial pour former des régions distinctes. 	<ul style="list-style-type: none"> • Simple à classer et facile à mettre en œuvre. 	<ul style="list-style-type: none"> • Comment déterminer le nombre de grappes ; • Les caractéristiques dépendent souvent de l'image et la façon de sélectionner ces caractéristiques afin d'obtenir des résultats de segmentation satisfaisants demeure incertaine ; • N'utilise pas d'information spatiale.
Approches régionales	Consiste à regrouper les pixels en régions homogènes. On y retrouve la croissance par région, le fractionnement de régions, la fusion de régions ou leur combinaison.	<ul style="list-style-type: none"> • Fonctionne au mieux lorsque le critère d'homogénéité de la région est facile à définir. 	<ul style="list-style-type: none"> • Sont par nature séquentielles et assez coûteuses en temps de calcul et en mémoire ; • La croissance des régions dépend intrinsèquement de la sélection de la région de départ et de l'ordre dans lequel les pixels et les régions sont examinés ; • Segments semblent trop carrés.

Technique de segmentation	Description de la méthode	Avantages	Désavantages
Détection de contours	En se basant sur la détection de discontinuité, essaie normalement de localiser des points avec des changements plus ou moins brusques dans le niveau de gris. Habituellement classés en deux catégories : séquentielle et parallèle.	<ul style="list-style-type: none"> • La technique de détection des contours est la façon dont l'humain perçoit les objets et fonctionne bien pour les images ayant un bon contraste entre les régions. 	<ul style="list-style-type: none"> • Ne fonctionne pas bien avec des images dont les bords sont mal définis ou dont les bords sont trop nombreux ; • Il n'est pas anodin de produire une courbe ou une limite fermée ; • Moins insensible au bruit que d'autres techniques comme le seuillage et le regroupement.
Approches floues	Appliquer des opérateurs flous, des propriétés, des mathématiques et des règles d'inférence (règles du type : SI : ALORS)	<ul style="list-style-type: none"> • La fonction d'appartenance floue peut être utilisée pour représenter le degré de certaines propriétés ou phrases linguistiques, et les règles floues peuvent être utilisées pour effectuer une inférence approximative. 	<ul style="list-style-type: none"> • La détermination de l'appartenance floue n'est pas un travail trivial ; • Le calcul impliqué dans les approches floues peut être intensif.
Approches de réseaux neuronaux	Utilisation de réseaux de neurones pour effectuer des classifications ou des regroupements.	<ul style="list-style-type: none"> • Pas besoin d'écrire des programmes compliqués ; • Peut utiliser pleinement la nature parallèle des réseaux de neurones. 	<ul style="list-style-type: none"> • Le temps d'entraînement est long et coûteux en calculs ; • L'initialisation peut affecter les résultats ; • Le surentraînement doit être évité.

2.4.2 Espaces colorimétriques

Les couleurs sont comprises par l'œil humain selon une combinaison de trois stimulus soient le rouge, le vert et le bleu qui sont souvent appelées « couleurs primaires ». L'espace colorimétrique RGB signifie une image à trois dimensions où chacune des dimensions comprend, en chacun des pixels d'encodage radiométrique prédéterminé (ex. 8 octets), la luminosité réfléchiée par les longueurs d'onde du rouge, du vert ou du bleu. L'espace RGB (Figure 3) encodé en 8 octets est le plus commun étant utilisé pour les systèmes de télévision et les photographies acquises par les appareils photo numériques.

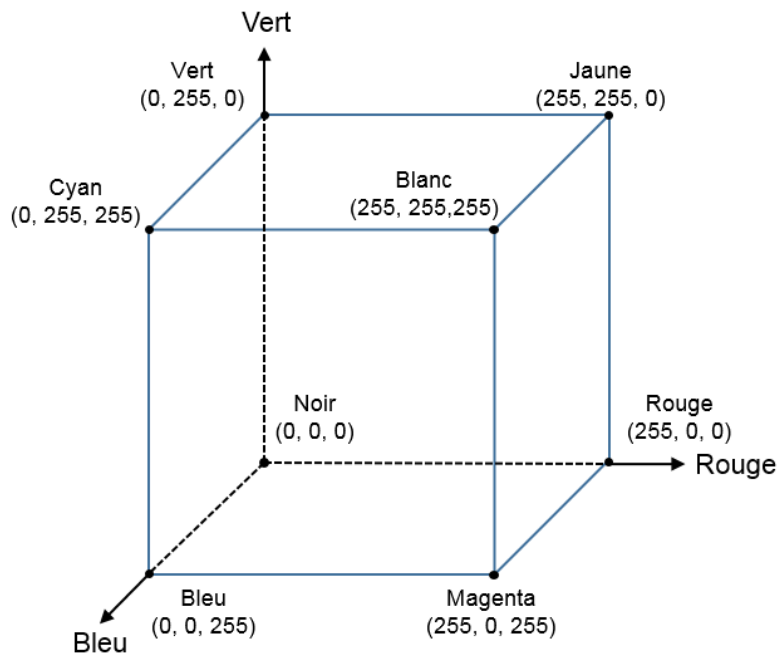


Figure 3: Représentation cubique de l'espace colorimétrique RGB.

Pour la segmentation d'images, il n'est pas souhaitable d'utiliser l'espace RGB à cause que les trois canaux sont hautement corrélés entre eux (Cheng *et al.*, 2001). Plusieurs autres espaces colorimétriques peuvent être dérivés de l'espace RGB à partir de transformations linéaires ou non linéaires.

L'espace colorimétrique *Nrgb* signifie RGB normalisé qui est une méthode efficace pour uniformiser les variations d'intensité de la distribution spectrale. L'espace colorimétrique *Nrgb* est formulé comme suit :

$$r = \frac{R}{R+G+B} , g = \frac{G}{R+G+B} , b = \frac{B}{R+G+B} \quad (3)$$

L'espace colorimétrique *HSV* est basé sur une approche psychologique de la perception des couleurs par l'humain. Une couleur dans l'espace HSV est caractérisée par trois composantes soient: la teinte *H*, la saturation *S* et la luminosité *V*. La couleur est représentée par un cercle de couleurs. La teinte est indiquée par une valeur d'angle dans ce cercle comprise entre 0° et 360° où :

- 0° ou 360° = rouge ;
- 60° = jaune ;
- 120° = vert ;
- 180° = cyan ;
- 240° = bleu ;
- 300° = magenta.

La saturation est la distance du centre du cylindre qui permet de décrire l'intensité de la couleur. Comprise entre 0 et 1, une valeur de 1 indique une couleur saturée ou intense alors que 0 indique une couleur fade. La valeur permet de décrire la luminosité de la couleur et est comprise entre 0 et 1. Plus la valeur est faible, plus la couleur est sombre et plus elle est élevée et plus la couleur est pure.




Figure 4: Représentation visuelle de l'espace colorimétrique HSV (Source : IFT1423 – TELUQ : Chapitre 1)

Il existe plusieurs autres espaces colorimétriques tels que YUV, YCbCr, YDbDr, CIEXYZ, CIELUV, CIELAB, CIELCH qui sont utilisés pour différentes applications notamment pour la représentation de couleur pour les systèmes télévisés (Asmare *et al.*, 2009). Ces espaces sont dépendants de l'appareil, non-linéaires avec la perception visuelle humaine et non intuitifs. Il a été démontré que, pour la segmentation des images couleur, l'espace HSV offre une meilleure performance que l'espace CIELAB (Bora *et al.*, 2015). Afin de simplifier la revue de littérature, ces espaces ne seront pas détaillés.

2.4.3 Reconnaissances d'objets par caractéristiques et apprentissage automatique

La reconnaissance d'objets au sein d'une image, également appelée la classification orientée-objet, est une tâche qui suscite un grand intérêt tant en vision numérique qu'en télédétection. Alors que la classification basée sur les pixels a longtemps été l'approche de base pour classifier l'imagerie d'observation de la terre, la classification orientée-objet est devenue de plus en plus courante à partir des années 2000 avec l'arrivée des satellites offrant une haute résolution spatiale (Blaschke, 2010). La méthode traditionnelle pose des lacunes pour les images de haute résolution comme un objet peut présenter une variation importante des valeurs d'intensité des pixels, créant alors un effet poivre et sel dans le résultat de classification thématique.

L'étape de segmentation comprise dans la classification orientée-objet vient éliminer cet effet poivre et sel par l'agrégation des pixels voisins selon certains critères d'homogénéité et d'hétérogénéité. Comme les segments regroupent un ensemble de pixels, il est possible de calculer des caractéristiques propres à chaque segment à partir des bandes de l'image. Par exemple, on peut calculer des caractéristiques spectrales (ex. moyenne, écart-type d'une bande), texturales (ex. matrice de cooccurrence, texture de Haralick), géométriques (ex. forme de l'objet, aire, périmètre) et contextuelles (notions de voisinage entre les objets) (Burnett & Blaschke, 2003; Wiseman *et al.*, 2009). La classification orientée-objet comprend au minimum une étape de segmentation ainsi qu'une étape de classification des objets appartenant à différentes classes d'intérêt. Une approche courante pour les images d'observation de la Terre est de segmenter l'image selon différentes échelles et ensuite déterminer des relations entre les différents objets des

segmentations proposées (Burnett & Blaschke, 2003). L'étape de classification utilise différentes méthodes d'apprentissage automatique à savoir les K plus proches voisins, les séparateurs à vaste marge, les arbres de décision ou la méthode du maximum de vraisemblance.

Différentes applications en entomologie et en agriculture ont été développées à l'aide de la vision numérique. Par exemple, un système d'identification automatique au niveau de l'ordre des insectes a été conçu en utilisant des photographiques proximales des individus et un algorithme reposant sur des caractéristiques discriminantes définies par un expert et une méthode d'apprentissage automatique utilisant les séparateurs à vaste marge et les réseaux de neurones artificiels (Wang *et al.*, 2012). Un système se basant sur la vision numérique a permis de détecter et de quantifier les aleurodes (mouches blanches) sur les feuilles de soya (Barbedo, 2014) différenciant les stades larvaires, les adultes, les lésions et la feuille de soya à partir de leurs caractéristiques colorimétriques et morphologiques. Jin *et al.* (2017) ont utilisé une approche de classification orientée-objet pour déterminer la densité de plant de blé à l'émergence avec une résolution spatiale de 0,2 mm/pixel acquise par drone. Les auteurs ont utilisé une segmentation par seuillage de l'indice de végétation MNVI (calculé à partir d'une image RGB) qui correspond à : $MNVI = 2G - 2B - 2.4R$ puis à l'extraction de caractéristiques pour chacun des objets. Une classification supervisée des objets a ensuite été réalisée à l'aide d'un séparateur à vaste marge. Les résultats démontrent un coefficient de détermination supérieur à 80% entre la méthode proposée et le comptage manuel.

2.4.4 Reconnaissance d'objets par apprentissage profond

Récemment, les réseaux de neurones convolutifs profonds (RNCP) et leur variantes ont émergé comme étant les méthodes les plus performantes pour la reconnaissance et la détection d'objets, en obtenant des performances de pointe sur de nombreux ensembles de données bien reconnus (Krizhevsky *et al.*, 2012; Lecun *et al.*, 1998). Les réseaux de neurones artificiels sont des systèmes informatiques vaguement inspirés des réseaux neuronaux biologiques constitués de neurones et de synapses interreliés les uns aux autres. Le théorème de l'approximation universelle a démontré que ces réseaux de neurones artificiels à couches multiples avec fonctions d'activation non linéaires

permettent pour un nombre fini de neurones, un nombre fini d'échantillons et pour un pouvoir fini de calcul d'estimer n'importe quelle fonction mesurable avec n'importe quel degré de précision désiré (Hornik *et al.*, 1989).

Le principe des réseaux de neurones

Un réseau de neurones à une couche cachée est composé de trois types de neurones : neurones à l'entrée, neurones cachés et neurones en sortie. Lorsque le réseau sert de classificateur, le nombre de neurones d'entrée et de sorties correspond respectivement au nombre de variables en entrée et au nombre de classes en sortie. Plusieurs couches de neurones peuvent se suivre en ayant chacun un nombre distinct de neurones. Pour chaque neurone, on effectue la propagation vers l'avant en calculant une valeur z avec l'équation 4 :

$$z = g \left(\sum_{i=1}^n x_i w_i + b \right) \quad (4)$$

Où : w_i est le coefficient ou poids liant un neurone d'une couche inférieure au neurone j , x_i est la valeur d'un neurone de couche inférieure, b est le biais pour un neurone et $g(x)$ est la fonction d'activation.

On dénomme ce bloc d'opérations mathématiques comme étant le perceptron. La fonction d'activation permet d'introduire des propriétés non linéaires dans le réseau et convertit le signal en une valeur dans un espace défini (ex. supérieur à 0 ou entre -1 et 1). Un réseau de neurones sans fonction d'activation est en fait un simple modèle de régression linéaire qui a un pouvoir limité et qui ne performe pas aussi bien, la plupart du temps (Goodfellow *et al.*, 2016). Une fonction d'activation sigmoïde ou soft-max permet d'estimer une probabilité $p \in [0,1]$. Cette fonction est souvent utilisée à la couche supérieure du réseau après une couche de neurones de sortie afin de prédire la classe d'appartenance de l'objet d'échantillon.




Figure 5: Principe du perceptron

À l'exception de la couche supérieure du réseau, la fonction d'activation ReLU (Rectified Linear-Unit) est privilégiée puisqu'elle assure que la valeur z du neurone appartienne à l'intervalle $[0, +\infty[$. Cette fonction conserve la valeur du neurone lorsqu'elle est positive et la rend égale à 0 lorsqu'elle est négative (Figure 6). Lorsque le résultat du neurone est compris entre $[0, 1]$ (ex. fonction d'activation sigmoïde), on peut observer le problème de disparition du gradient. Lorsque les couches subséquentes de neurones sont multipliées entre elles et que la valeur de z est près de 0, ceci entraîne une faible différence entre les valeurs z ce qui cause de faibles différences de gradient. Ces faibles différences de gradient ne permettent pas d'ajuster suffisamment les paramètres w pour que le réseau puisse apprendre convenablement les différents attributs d'un objet (Glorot *et al.*, 2011).

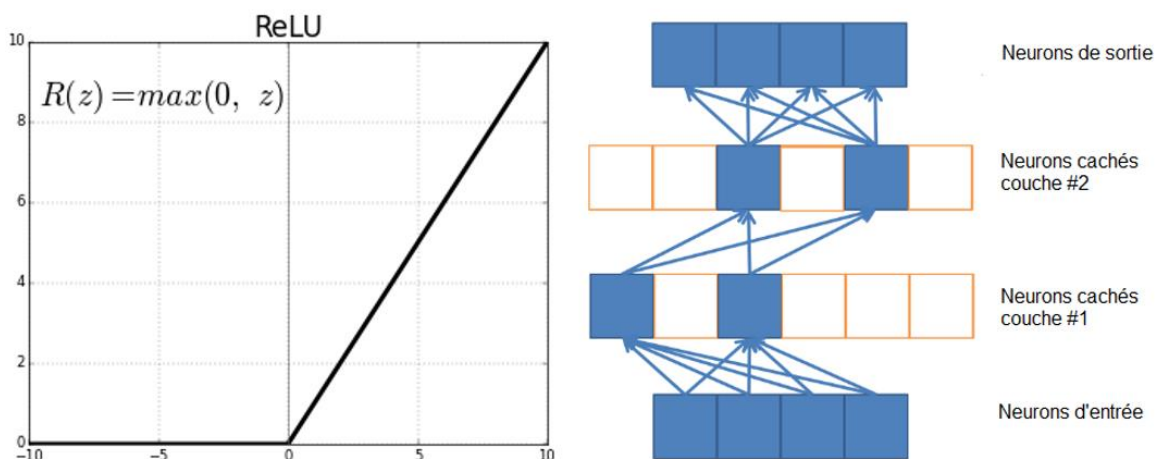


Figure 6: Non-linéarité introduite dans le réseau par la fonction d'activation ReLU (adapté de Glorot *et al.*, 2011)

L'apprentissage du réseau de neurones se fait comme suit :

- Initialiser le modèle avec les poids aléatoires
- Tant que l'entraînement n'est pas terminé :
 - Pour chaque exemple de la liste des données d'entraînement :
 - Donner l'entrée au modèle pour obtenir la sortie
 - Calculer la valeur de la fonction de coût en comparant la sortie avec le résultat attendu
 - Propager l'erreur de couche en couche vers l'arrière
 - Mettre à jour tous les poids du réseau

La fonction de coût permet d'estimer les inconsistances entre les valeurs prédites (\hat{y}) et les vraies valeurs (y). C'est une valeur positive, où la robustesse du modèle augmente avec la diminution de la valeur de la fonction de coût.

Il existe plusieurs types de fonctions de coût qui peuvent être utilisées. L'expression générale d'une fonction de coût est une fonction des coefficients w_{nj} , des objets $x^{(i)}$ de la base de données d'échantillons et des vraies valeurs $y^{(i)}$ (équation 5).

$$L(w) = \frac{1}{n} \sum_{i=1}^n L(f(x^{(i)}, w), y^{(i)}) \quad (5)$$

Pour une classification discrète binaire, on utilise la fonction entropie-croisée binaire (équation 6) qui s'écrit comme suit :

$$L = -\frac{1}{n} \sum_{i=1}^n [y^{(i)} \log(\hat{y}^{(i)}) + (1 - y^{(i)}) \log(1 - \hat{y}^{(i)})] \quad (6)$$

Où: y est la valeur cible, \hat{y} est la valeur prédite et n est le nombre d'échantillons d'entraînement.

Le but de l'apprentissage est donc de trouver l'ensemble de poids w_{nj} qui minimise la fonction de coût (equation 7).

$$\mathbf{w}^* = \operatorname{argmin} \frac{1}{n} \sum_{i=1}^n L(f(x^{(i)}, \mathbf{w}), y^{(i)}) \quad (7)$$

Pour un réseau de neurones, comme le modèle peut être constitué de millions de fonctions, il n'est pas simple de calculer la dérivée partielle. C'est pourquoi on utilise la rétropropagation du gradient qui consiste à faire circuler l'information de la dérivée de la fonction de coût à partir de la couche de sortie jusqu'à la couche d'entrée. Les nouveaux poids w_{hj} et biais b_j sont actualisés et le processus se fait de façon itérative jusqu'à tant que les poids et les biais convergent et donne la valeur de coût la plus faible possible.

Prenons pour exemple une couche ayant un neurone en entrée x , un neurone caché z et un neurone en sortie \bar{y} (Figure 7).




Figure 7: Exemple simplifié de calcul de la fonction de coût

On doit commencer par calculer la dérivée partielle de w_2 , en appliquant la règle de la dérivée en chaîne (équation 8), comme suit :

$$\frac{\partial L(\mathbf{w})}{\partial w_2} = \frac{\partial L(\mathbf{w})}{\partial \bar{y}} * \frac{\partial \bar{y}}{\partial w_2} \quad (8)$$

Ensuite, calculer la dérivée partielle de w_1 , en appliquant la règle de la dérivée en chaîne (équation 9), comme suit :

$$\frac{\partial L(\mathbf{w})}{\partial w_1} = \frac{\partial L(\mathbf{w})}{\partial \bar{y}} * \frac{\partial \bar{y}}{\partial z_1} * \frac{\partial z_1}{\partial w_1} \quad (9)$$

On répète ce processus pour chaque neurone du réseau puis on met à jour les poids du réseau par la descente du gradient (équation 10).

$$w \leftarrow w - \alpha * \frac{\partial L(\mathbf{w})}{\partial w} \quad (10)$$

Où α est le taux d'apprentissage $\epsilon [0,1]$ qui est un coefficient permettant d'estimer le pas vers la descente de gradient.

Idéalement, on veut choisir un taux d'apprentissage qui soit assez large pour éviter les minimums locaux, mais converge vers le minimum global de $L(w)$. Certaines méthodes d'optimisation permettent que le taux d'apprentissage soit adaptatif et variable selon le

gradient par différentes méthodes telles que Momentum, Adagrad, Adadelta, Adam et RMSProp (Goodfellow *et al.*, 2016). Le taux d'apprentissage est un des hyperparamètres qui doit être le mieux ajusté et qui varie selon la complexité du problème et le jeu de données utilisées et il n'existe pas une seule manière optimale de définir celui-ci pour l'ensemble des problèmes existants. L'entraînement des réseaux de neurones se fait pour un nombre donné d'époques, c'est-à-dire un nombre d'itérations sur l'ensemble du jeu de données d'entraînement et de validation. Il faut faire attention, car un temps d'entraînement trop important peut causer du surapprentissage. Une pratique courante est d'arrêter l'entraînement du réseau lorsque celui-ci cesse de s'améliorer pour une certaine période d'époques et de sauvegarder la version du modèle offrant la meilleure performance (Yao *et al.*, 2007). Le surapprentissage est lorsqu'un modèle offre une bonne performance sur le jeu de données d'entraînement, mais présente une faible performance sur le jeu de données de validation ou de tests. L'utilisation du « Dropout » permet de réduire les chances qu'un réseau surapprenne les données et a démontré des améliorations majeures par rapport à d'autres méthodes de régularisation. Le « Dropout » désactive aléatoirement des neurones lors de l'entraînement selon une valeur de probabilité ce qui a pour effet d'entraîner un ensemble de sous-réseaux et de réduire la coadaptation des neurones du réseau (Srivastava *et al.*, 2014). On dit qu'un réseau généralise bien lorsqu'il performe bien sur d'autres jeux de données que celui-ci avec lequel il a été entraîné.

Les réseaux de neurones convolutifs

Un réseau de neurones convolutif est un type de réseau de neurones artificiels dans lequel les connexions entre les neurones sont inspirées du cortex visuel primaire des animaux. Ils sont sûrement le meilleur exemple de réussite de l'intelligence artificielle inspirée par la biologie. Leur fonctionnement consiste à un empilage de plusieurs couches de perceptrons qui ont une topologie en grille connue (Goodfellow *et al.*, 2016). Ces réseaux utilisent l'opération mathématique de la convolution en au moins une couche au lieu du produit scalaire des matrices. Les réseaux de neurones à perceptrons multicouches ont des difficultés à traiter des images de grande taille puisque dans ce

modèle chaque pixel de l'image constitue un neurone d'entrée qui sont connectés chacun à une série de neurones cachés d'une couche suivante. Ceci entraîne une croissance exponentielle du nombre de connexions entre les neurones et donc de paramètres à estimer. Les filtres de convolutions avec une taille et une dimension prédéfinie permettent de réduire considérablement le nombre de paramètres d'un réseau.

La convolution nécessite un argument en entrée (ex. une image 64x64x3), ensuite le second argument est le noyau de convolution composé d'une taille de filtre et d'un nombre de filtres prédéterminé (ex. taille du filtre = 3x3, nombre de filtres = 32) pour ensuite donner en sortie 32 cartes de caractéristiques de 64x64 qui est le résultat de la fenêtre de convolution pour chacun des filtres passés sur l'image d'entrée. Ensuite, une fonction d'activation telle que ReLU est souvent utilisée sur chacun des pixels de la carte de caractéristiques pour filtrer les activations. Un décalage dans le déplacement des fenêtres de convolutions peut être appliqué réduisant ainsi la taille de l'image en sortie.

Par la suite, une opération appelée le « pooling » est généralement utilisée afin de réduire la taille de l'image et afin de réduire la quantité de calcul et le stockage en mémoire tout en conservant les propriétés principalement activées par les filtres de convolution. Cette opération aide à ce que la représentation soit invariante aux translations (Goodfellow *et al.*, 2016). Le max-pooling est souvent utilisé afin de conserver uniquement la valeur d'activation maximale dans une fenêtre. Par exemple, le résultat d'une opération max-pooling avec une fenêtre de 2x2 et avec un déplacement de 2 pixels dans les axes X et Y donne une carte de caractéristiques 2 fois plus petite dans l'axe X et Y conservant seulement les pixels où l'activation par le filtre est maximale dans la fenêtre de 2x2. Le pooling moyen peut également être utilisé afin de calculer une moyenne des activations dans la fenêtre d'agrégation. Cette opération est généralement utilisée au sommet du réseau suivie par une couche complètement connectée pour ensuite passer à une fonction d'activation assignant une probabilité de classe d'appartenance.

Les architectures de réseaux de neurones sont un assemblage de différents types de couches souvent composées de couches de convolutions, suivies par une couche de max-pooling, par d'autres couches de convolutions, ainsi de suite jusqu'à tant de

permettre de déterminer une classe en sortie à l'image d'entrée (Figure 8). Il existe une panoplie de variantes d'architectures présentement. La première véritable architecture de RNCP est AlexNet qui a gagné le concours « ImageNet Large Scale Visual Recognition Challenge » (ILSVRC) en septembre 2012 avec un taux d'erreur de 15,3% soit 10,8 % plus faible que l'algorithme en deuxième position. Depuis ce temps, les architectures de RNCP ont dominé les concours de vision numérique et leur innovation n'a cessé de continuer (Krizhevsky *et al.*, 2012).




Figure 8: Exemple d'architecture de réseau de neurones convolutif présentant les résultats intermédiaires entre chacune des couches du réseau (adapté de Ding & Taylor, 2016).

Les architectures ResNet ont gagné la première place du concours ILSVRC en 2015 avec un taux d'erreur inférieur à 3,57%. Il a été observé que la performance des architectures sature puis diminue lorsque la profondeur augmente. Afin de corriger ce problème, les architectures ResNet utilisent des blocs résiduels (Figure 9) auxquels la valeur x en entrée est ajoutée à la valeur z en sortie du perceptron (He *et al.*, 2015). Ce bloc résiduel permet de conserver les apprentissages des couches moins profondes vers les couches plus profondes lorsque celles-ci ne sont pas activées.




Figure 9: Bloc résiduel utilisé dans les ResNet (He *et al.*, 2015).

Plusieurs variantes de ResNet existent selon le nombre de couches de convolution utilisées. Ces architectures ont 5 stages pour lesquels des opérations d'agrégation sont effectuées. La Figure 10 présente les différentes architectures ResNet utilisées.

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
		3×3 max pool, stride 2				
conv2_x	56×56	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4_x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10 ⁹	3.6×10 ⁹	3.8×10 ⁹	7.6×10 ⁹	11.3×10 ⁹

Figure 10: Configuration des couches de convolution pour les différentes profondeurs d'architectures résiduelles ResNet (He *et al.*, 2015).

Applications des réseaux de neurones convolutifs en agriculture de précision et en entomologie

Les RNCP ont des applications dans plusieurs domaines utilisant la vision par ordinateur et l'agriculture de précision n'en fait pas exception. Il existe différents jeux de données contenant de l'information relative aux plantes tels que Flowers 102, PlantVillage, LeafSnap, Urban Trees et CropVision (Zheng *et al.*, 2019). Plusieurs auteurs ont développé et testé des architectures de réseaux de neurones sous différents paramètres

afin d'identifier des maladies à partir de ces jeux de données. Zheng *et al.* (2019) ont comparé différentes architectures et méthodes de localisation des objets sur le jeu de données CropVision afin d'être utilisés par des robots cueilleurs de fruits et légumes. Les résultats démontrent que l'architecture ResNet-50 permet d'obtenir une précision globale de 99.81 % évaluée sur 31 classes pour l'identification des fruits et légumes ainsi qu'une précision globale moyenne de 91.44% pour la localisation des objets en utilisant le réseau YOLOv3. Mohanty *et al.* (2016b) ont comparé les architectures AlexNet et GoogleNet avec différents paramètres d'entraînement sur le jeu de données PlantVillage qui contient 38 classes dont 14 espèces de culture et 26 maladies. Les résultats démontrent une précision globale de 99,35%. Rangarajan *et al.* (2018) se sont spécialisés sur les maladies affectant les tomates du jeu de données PlantVillage et ont obtenu des précisions globales de 97,29% et 97,49% pour les architectures AlexNet et VGG16, respectivement. Ha *et al.* (2017) ont utilisé l'imagerie de culture de radis acquise par drone pour détecter la flétrissure fusarienne. Les auteurs ont classifié les zones étant des plants de radis au champ puis ont utilisé un RNCP par la suite avec une approche en fenêtre glissante pour classifier les plants affectés par la maladie ou en santé avec une précision globale de 93,3 %. Plusieurs études utilisent les RNCP pour identifier et quantifier des stress biotiques et abiotiques à partir d'images acquises manuellement ou par drones pour différentes cultures (Singh *et al.*, 2018).

En entomologie, on utilise également l'apprentissage profond afin d'identifier et de localiser des insectes dans les images. On peut penser à Xia *et al.* (2018) qui ont développé une approche utilisant une méthode de détection de régions candidates et un RNCP afin de classifier des images d'un jeu de données contenant 24 espèces d'insectes et a obtenu une précision moyenne globale de 89,22 %. Ces modèles pourraient être utilisés dans une application de téléphone intelligent pour faciliter le dépistage. Ding et Taylor (2016) ont entraînés un RNCP pour détecter et localiser le carpocapse de la pomme (*Cydia pomonella*) à partir d'images des individus collés à une trappe à phéromone (Ding & Taylor, 2016).

2.5 Acquisition des photographies numériques à partir d'un drone

2.5.1 Les paramètres de photographies à partir d'un drone à considérer

Lors de la capture d'une photographie numérique, la lumière réfléchie ou émise d'une scène est convertie en un signal électrique qui est mesuré et stocké par les photosites du capteur de l'appareil. Pour distinguer les couleurs, la plupart des caméras commerciales utilisent un réseau de filtres colorés (filtre de Bayer) (Figure 11) qui laisse passer vers le capteur certaines longueurs d'onde du spectre visible, ce qui permet au capteur d'être sensible au rouge, bleu et vert et de décomposer le signal acquis en différentes bandes (Brown, 2004).

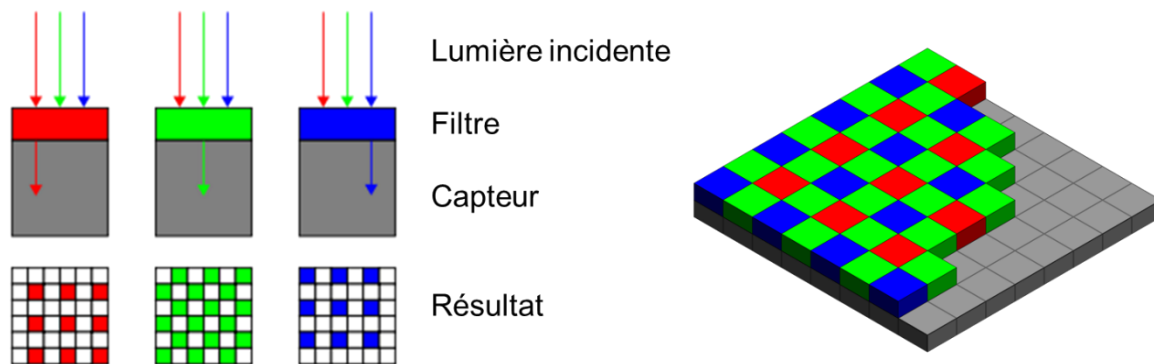


Figure 11: Filtres de Bayer employés sur la plupart des capteurs de caméras commerciales (adapté de : https://en.wikipedia.org/wiki/Bayer_filter)

Le champ de vision d'un appareil photographique (équation 11) est une fonction de la longueur de la focale utilisée, la largeur et la hauteur du capteur de la caméra.

$$CdV = 2 \arctan \left(\frac{l}{2f} \right) \approx \frac{l}{f} \quad (11)$$

Où : CdV est le champ de vision, l la largeur du capteur et f est la longueur focale.

La longueur focale est la distance entre le centre de la lentille et le point de convergence des rayons de lumières parallèles incidents vers la lentille lorsqu'elle est en accent vers l'infini (Hecht, 2002).

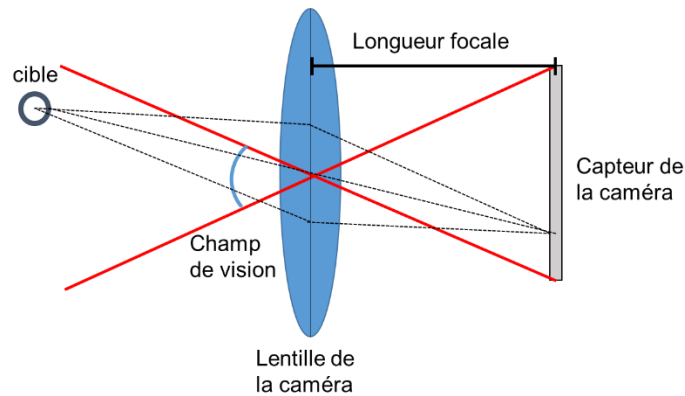


Figure 12: Exemple des rayons de lumière incidente vers le capteur de la caméra (inspiré de O'Connor et al., 2017).

La résolution qu'offre une caméra résulte du nombre de photosites du capteur ce qui détermine le nombre de pixels compris dans l'image. Tandis que la résolution spatiale (équation 12) d'une image qui est acquise au nadir est une fonction de la hauteur de vol, de la longueur focale de l'objectif utilisé et de la taille du pixel sur le capteur.

$$R_s = \frac{2H * \arctan(Lp)}{2f} \approx \frac{H * Lp}{f} \quad (12)$$

Où : R_s est la résolution spatiale, H la hauteur de vol et Lp la largeur du pixel sur le capteur.

L'exposition d'une image est la quantité de lumière par unité de surface atteignant le capteur. Un capteur possède une plage d'exposition utile physiquement limitée. Pour une partie quelconque de la photographie, lorsque l'exposition réelle est en dehors de cette plage, le capteur ne peut l'enregistrer précisément. Par exemple, les valeurs hors plage peuvent être enregistrées comme des pixels noirs (sous-exposé) ou blancs (surexposé) au lieu d'obtenir des pixels aux couleurs et aux tons nuancés requis pour décrire le détail (Jacobson et al., 2001). L'exposition générale d'une image est déterminée par trois paramètres fondamentaux soient : l'ISO, l'ouverture du diaphragme et la vitesse d'obturation comme présentée à la Figure 13.




Figure 13: Le triangle de l'exposition affecté par les trois paramètres principaux de la photographie numérique: vitesse d'obturation, ouverture du diaphragme et l'ISO (Source : <https://tinyurl.com/y654carp>).

L'ISO est la sensibilité du capteur qui est déterminée par les caractéristiques physiques de celui-ci et de l'amplification appliquée à sa sortie : lorsque la valeur de ce paramètre augmente, l'exposition de l'image augmente également, mais en introduisant du bruit plus la valeur ISO est élevée. L'ouverture du diaphragme et la vitesse d'obturation déterminent la quantité de lumière qui atteint le capteur. La profondeur de champ est l'étendue des distances sur lesquelles l'objet apparaît en accent et celle-ci est déterminée par l'ouverture du diaphragme. L'ouverture N décrit la taille de l'ouverture où la lumière pénètre vers la lentille et est mesurée par un nombre- f (équation 13).

$$N = \frac{f}{D} \quad (13)$$

Où : N est le nombre- f et D est le diamètre d'ouverture.

Donc, un nombre- F plus grand signifie une ouverture de diaphragme plus étroite et donc moins de lumière incidente vers le capteur de la caméra. En diminuant l'ouverture du diaphragme (augmentant le nombre- F), la profondeur de champ devient plus importante. L'utilisation de petite ouverture permet d'obtenir généralement des images plus nettes comme la profondeur de champ est plus importante. La netteté de l'image est également affectée par l'accent de lentille qui doit être ajustée selon la distance à laquelle la cible

est située. Une image parfaitement nette est produite lorsque la lentille est positionnée de manière à ce que les rayons de lumière réfléchi par la source croisent exactement le plan du capteur. Selon le capteur et la lentille utilisée, une petite ouverture du diaphragme peut être limitée par la diffraction. La tache d'Airy est la figure de diffraction résultant de la traversée d'un trou circulaire par la lumière. Le diamètre du disque d'Airy est utilisé pour comparer la limitation causée par l'ouverture du diaphragme à celle causée par le disque d'Airy. Une image est limitée par la diffraction lorsque le diamètre du disque d'Airy est plus grand que la taille d'un pixel du capteur ce qui disperse la lumière de sa direction de propagation d'origine (McGlone *et al.*, 2013). La limite de diffraction, d , est approximée par le diamètre du disque d'Airy (équation 14) pour une ouverture circulaire qui est mesurée comme suit :

$$\frac{d}{2} = 1.22 \lambda * N \quad (14)$$

Où : λ est la longueur d'onde de la lumière et N est le nombre- f de l'ouverture.

Dans la pratique, il est acceptable que l'image soit limitée par la diffraction pour permettre une assez grande profondeur de champ assurant une image nette (O'Connor *et al.*, 2017).

La vitesse d'obturation détermine le temps que le capteur soit exposé à la lumière, mesuré en fraction de seconde. Plus le temps est court, et plus une cible en mouvement sera nettement captée. Pour des vols aéroportés, la vitesse de vol est la principale cause de flou de mouvement dans les images. Le mouvement de flou, b (en pixels), peut être estimé pour tout vol aérien par l'équation 15 :

$$b = \frac{v * t}{R_s} \quad (15)$$

Où : b est le mouvement de flou (pixel), v est la vitesse de vol (m/s), t est la vitesse d'obturation (s) et R_s est la résolution spatiale (pixel/m). Il est donc nécessaire, lors des acquisitions d'image, de tenir compte de tous ces paramètres et équations gouvernants la qualité de la photographie aérienne que ce soit pour planifier le vol ou configurer la caméra au moment du vol.

2.5.2 Réglementation des vols de drone au Canada

Avant le 1^{er} juin 2019, au Canada, l'utilisation de drones à des fins non récréatives nécessite un certificat d'opérations aériennes spécialisées comprenant des précisions sur la façon d'utiliser l'appareil et les endroits où il est permis (Canada, 2019a).

La nouvelle réglementation différencie les opérations de base et avancées. Une opération de base doit répondre aux trois conditions suivantes (Canada, 2019b) :

- Le drone est piloté dans un espace aérien non contrôlé ;
- Le drone est piloté sur une distance horizontale de plus de 30 mètres (100 pieds) des passants ;
- Le drone n'est jamais piloté au-dessus des passants.

Pour les opérations de base :

- Il est nécessaire d'immatriculer le drone auprès de Transport Canada avant de l'utiliser pour la première fois;
- Inscire le numéro d'immatriculation sur le drone;
- Réussir l'examen « opérations de base »;
- Être en mesure de produire sur demande le certificat de pilote – opérations de base et une preuve d'immatriculation lors de l'utilisation du drone.

Pour les vols en champs agricoles, lorsque le champ est situé dans un espace aérien non contrôlé, les vols de drones requis répondent généralement aux opérations de base.

3 MATÉRIELS ET MÉTHODES

3.1 Dispositif expérimental

Les acquisitions d'images par drone ont été effectuées sur une partie d'une parcelle agricole du producteur de pommes de terre partenaire, Patates Dolbec, à Sainte-Anne-de-la-Pérade. La variété de pommes de terre « Goldrush » a été semée avec un insecticide imidaclopride appliqué au planton réduisant la vulnérabilité des plants en début de saison. La parcelle agricole n'a pas subi de rotation de cultures et par conséquent, lors des dates de visite, celle-ci était densément infestée. Deux sorties terrain comprenant des vols de drones et des activités de dépistage ont été effectuées lors du mois de juillet 2018. Les agronomes de l'entreprise ont surveillé les champs et ont avisé l'équipe au moment où le champ a commencé à être infesté par le DPT.

3.1.1 Campagnes de terrain

Pour la première sortie, quatre parcelles ont été délimitées par des drapeaux de 2 rangs de large x 2 m de longueur dans la parcelle où il y avait des populations de DPT afin d'y effectuer un dépistage manuel. Les notes de dépistage pour ces endroits décrivent le rang dépisté (numéro), le nombre de doryphores visibles (jeunes et vieilles larves et adultes) au sommet de la canopée et le nombre de doryphores cachés en dessous des feuilles (Annexe 1). Des photographies rapprochées de ces mêmes zones de dépistage à l'aide d'une caméra de téléphone cellulaire ont été prises afin de valider les observations sur les photographies aériennes sans effectuer de comptage des individus (Figure 15). Pour la deuxième sortie, un dépistage manuel pour 4 parcelles a été effectué ainsi qu'un dépistage par photographies rapprochées à 25 autres endroits (Figure 14). Les positions géographiques des sites de dépistage ont été relevées avec un GPS de téléphone cellulaire. Pour chaque emplacement où un dépistage a été fait, une cible de photogrammétrie a été déposée au sol et un numéro lui a été associé. Ce numéro est associé à une parcelle de dépistage pour lequel un dépistage conventionnel ou par photographies proximales a été fait à cet endroit.

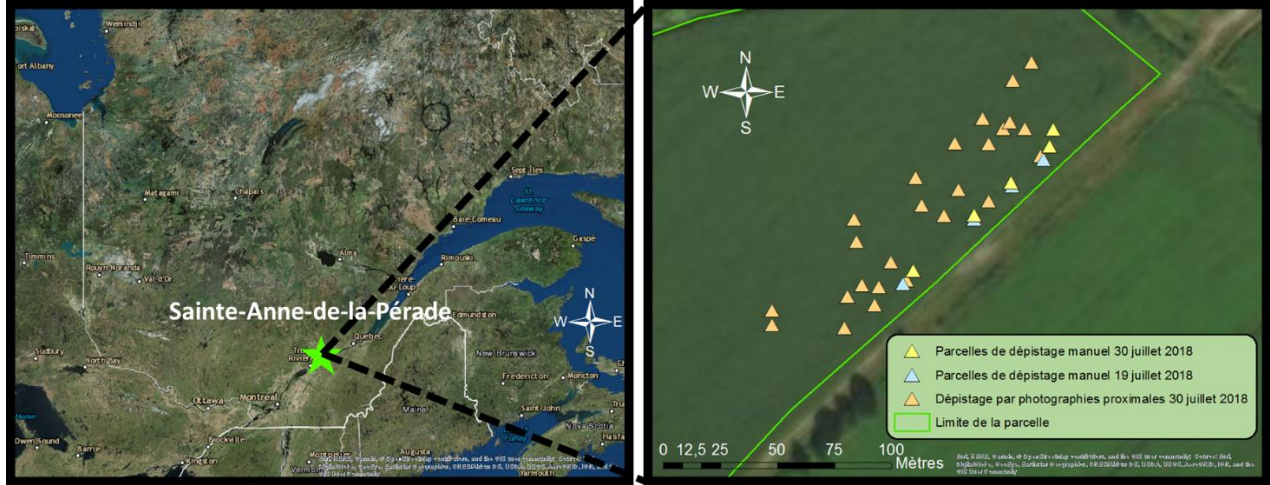


Figure 14: Site d'étude et parcelles de dépistage manuel et photographique pour les deux sorties terrain.



Figure 15: Exemple de dépistage par photographie proximale pour la parcelle de dépistage #23 (30 juillet 2018) (à gauche: photographie par cellulaire, milieu et droite: photographie par drone).

3.1.2 Acquisition des images ultra-haute résolution par drone

Le drone utilisé est un drone hexacoptère à 12 moteurs *OnyxStar HYDRA-12* et la caméra embarquée est une caméra *Sony a6000* (Figure 16) possédant un capteur de type CMOS et de format APS-C d'une taille de 23.50 mm x 15.60 mm offrant un pixel d'une largeur au capteur de 3,92 μm .



Figure 16: Drone *OnyxStar HYDRA-12* (gauche) et caméra *Sony a6000* (droite).

Lors de la première sortie terrain, des tests de paramètres de caméra et de vols de drone ont été effectués. La résolution spatiale des vols de drone a été fixée à 1,18 mm/pixel à une altitude de 15 m avec une lentille d'une longueur focale de 50 mm. Ce choix de paramètre a été déterminé à partir de l'étude de faisabilité effectuée par l'équipe du laboratoire TED (Lhissou *et al.*, 2018) qui a démontré la faisabilité d'identifier les larves de doryphores à partir de cette résolution. La caméra *Sony a6000* génère des images de 4000 x 6000 pixels (24 Mégapixels) offrant une couverture au sol 4,72 m x 7,08 m avec la résolution spatiale choisie. L'acquisition des images s'est fait en mode « laps de temps » afin d'acquérir une photographie par seconde. L'accent de l'appareil photographique a été réglé manuellement à une distance, mesurée à l'aide d'un ruban, de 15 m. Afin qu'il soit possible d'utiliser le système opérationnellement, le drone doit voler à sa vitesse maximale tout en couvrant le territoire au complet. Le drone ne peut donc pas dépasser la vitesse de 4,72 m/s, sans quoi les acquisitions dans la ligne de vol

seront discontinues. Les paramètres de caméra ont été ajustés de manière à ce que le mouvement de flou sur le capteur soit inférieur à 1 pixel, que l'exposition soit normale, et que les images soient nettes tout en minimisant le bruit au capteur (ISO). Selon ces critères préétablis, les vitesses d'obturation de 1/3200 sec et de 1/4000 sec ont été testées pour des vitesses de vol de 0, 2, 3 et 4 m/s. Pour que les photographies soient prises avec un temps d'exposition aussi court, l'éclairage doit être maximal nécessitant des conditions peu nuageuses et vers l'heure du midi. L'ouverture du diaphragme a été testée afin qu'il soit minimal (F2.8) afin de minimiser l'ISO. Selon la qualité de la photographie résultante, l'ouverture du diaphragme a été augmentée afin d'obtenir une image qui est nette et que l'accent soit au sommet de la canopée. Les essais réalisés lors de la première sortie sont présentés dans le Tableau 6.

Pour la deuxième sortie, les paramètres d'acquisition ont été choisis en fonction des tests réalisés lors de la première sortie. Une incertitude dans la vitesse de déplacement du drone de ± 1 m/s a été observée lors des vols précédents et c'est pourquoi une vitesse de vol de 3 m/s a été choisie pour la deuxième sortie afin de ne pas dépasser 4 m/s. De plus, nous avons effectué l'acquisition des données avec une ouverture du diaphragme plus élevée (F4.5) afin de déterminer l'effet causé par une image avec une ISO plus élevée et une image plus limitée par la diffraction. Pour la deuxième sortie, deux vols ont été réalisés avec la même résolution spatiale, mais le premier vol était légèrement en dehors des cibles échantillonnées causé par une erreur lors de la planification du vol. De plus, lors des deux sorties terrain, il y a eu deux vols qui n'ont pas permis d'acquérir des photographies de bonne qualité puisqu'il y a eu un déplacement de l'accent ou celui-ci était mal ajusté. Une incertitude dans la hauteur de vol a également été observée d'environ 0-3 m ce qui affecte la résolution spatiale. La balance des blancs de l'appareil photographique a été réglée selon le mode « Jour éclairé ».

Tableau 6: Paramètres d'acquisition des images lors des différents vols pour les deux sorties terrain

Date	Paramètres de caméra	Vitesses de vol (m/s)	Résolution spatiale (mm/pixel)	Largeur du pixel sur le capteur ($\mu\text{m}/\text{pixel}$)	Diamètre du disque de Airy ($\mu\text{m}/\text{pixel}$)	N pixel flou (pixel)	Résultat
19 juillet 2018 (Sortie 1)	1/3200 sec F 2.8 ISO 160	0 2 3 4	1,17	3,917	3,758	0 0.53 0.8 1.06	Image floue (Profondeur de champ et/ou vitesse trop faible)
19 juillet 2018 (Sortie 1)	1/4000 sec F2.8 ISO 160	0 2 3 4	1,17	3,917	3,758	0 0,43 0,64 0,85	Image floue (Profondeur de champ trop faible)
19 juillet 2018 (Sortie 1)	1/4000 sec F3.2 ISO 250	0 2 3 4	1,17	3,917	4,294	0 0,43 0,64 0,85	Image nette (exposition normale)
30 juillet 2018 (Sortie 2)	1/4000 sec F4.5 ISO 320	3	1,17	3,917	6,039	0,64	Image nette (légèrement sous-exposée) Vol en dehors de la zone d'étude
30 juillet 2018 (Sortie 2)	1/4000 sec F4.5 ISO 320	3	1,17	3,917	6,039	0,64	Image nette (légèrement sous-exposée)

3.2 Algorithme de détection

Différentes avenues sont possibles afin de détecter la présence de larves ou d'adultes de doryphores. On peut penser à des méthodes nécessitant d'extraire les caractéristiques discriminantes manuellement ainsi qu'à des méthodes d'apprentissage automatique telles que les RNCP. Comme les réseaux de neurones convolutifs ont démontré être la méthode la plus efficace pour la détection et la reconnaissance des objets dans les images en offrant des performances faisant l'état de l'art pour plusieurs jeux de données reconnus (DeChant *et al.*, 2017; Ding & Taylor, 2016; Krizhevsky *et al.*, 2012; Mohanty *et al.*, 2016a; Shin *et al.*, 2016; Zheng *et al.*, 2019). Cette méthode a été privilégiée pour la conception de l'algorithme. Il existe plusieurs approches afin d'effectuer la reconnaissance d'objets dans les images. Une approche simple est l'approche par « fenêtres glissantes » qui consiste à diviser l'image acquise en petites fenêtres ou imagerie qui sont ensuite chacune classifiées par le réseau de neurones convolutifs. La taille de la fenêtre dépend de la taille des objets à détecter et un pas de glissement doit être déterminé. La taille d'une grosse larve de doryphores est d'environ 8 mm x 10 mm ce qui équivaut à environ 70 pixels dans une image acquise selon les configurations proposées (résolution de 1.18 mm/pixel). Prenons par exemple une taille de fenêtre de 20x20 pour localiser le doryphore que l'on déplacerait par un pas de 20 pixels dans l'image acquise (de taille 6000x4000) : il y aurait au total 60000 classifications à effectuer. Et prenons une architecture de RNCP comme ResNet-50 avec une taille de fenêtre d'entrée de 64x64, pour une carte graphique localisée sur les machines virtuelles EC2 Amazon Web Services (type d'instance : p2.xlarge, carte graphique : NVIDIA TESLA K80 – 12Go) le temps de calcul (t) pour une image complète serait égal à :

$$t = 60000 \text{ imagerie} * 0,062 \frac{\text{sec}}{\text{imagerie}} = 3720 \text{ sec} = 62 \text{ min} \quad (16)$$

Ce qui est un temps de traitement beaucoup trop long afin que la méthode soit opérationnelle. Sans compter que le nombre de faux positifs augmente proportionnellement avec le nombre d'imagerie à inférer selon la précision de l'algorithme. Une autre approche serait d'utiliser les architectures convolutives/déconvolutives qui permettent d'effectuer des segmentations sémantiques

dans les images, c'est-à-dire d'assigner une classe à chaque pixel de l'image en entrée. Cette avenue a été écartée puisque comme la taille des doryphores est très faible en comparaison aux autres objets de l'image (feuilles, tiges, sol), les opérations de « pooling » atténuent la présence de ces objets et leur discrimination devient presque impossible par une segmentation sémantique. L'approche choisie dans le cadre de cette étude se base sur une détection préliminaire afin d'identifier les zones pouvant être potentiellement un doryphore et sur une classification de chacune de ces zones par un RNCP. La Figure 17 explique le processus de traitement des images à partir de l'acquisition jusqu'à la production des cartes de dépistage.

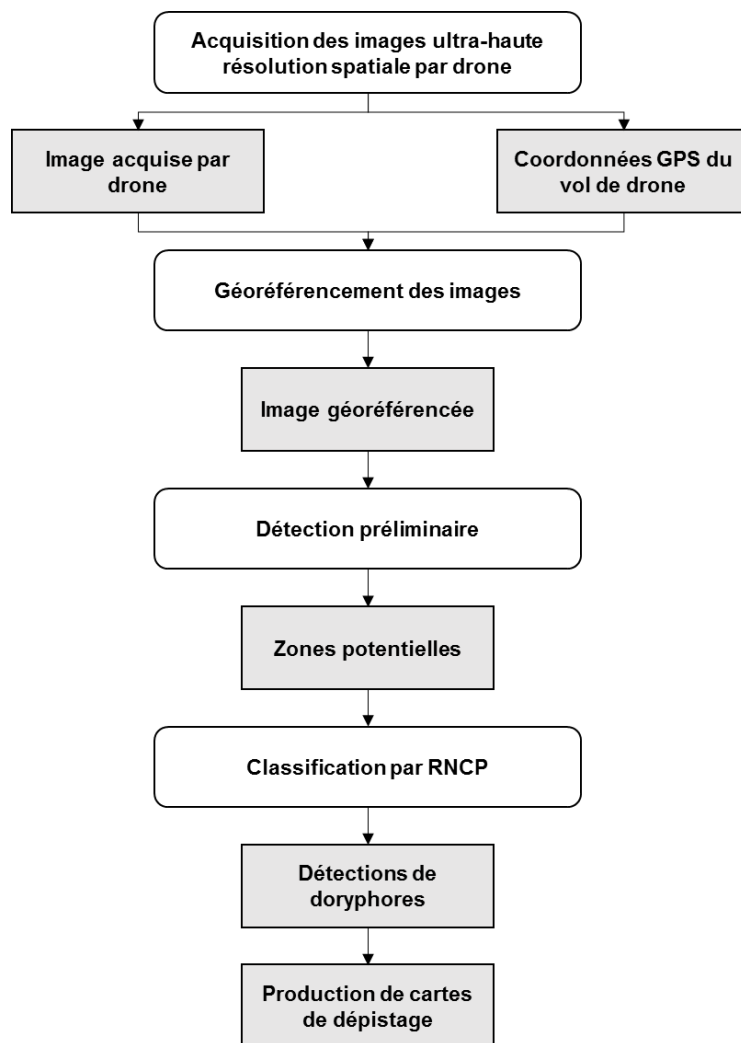


Figure 17: Schéma méthodologique de la méthode de détection et de production de cartes de dépistage du doryphore

3.2.1 Détection préliminaire

La Figure 18 présente le processus de conception de l'algorithme de détection préliminaire.

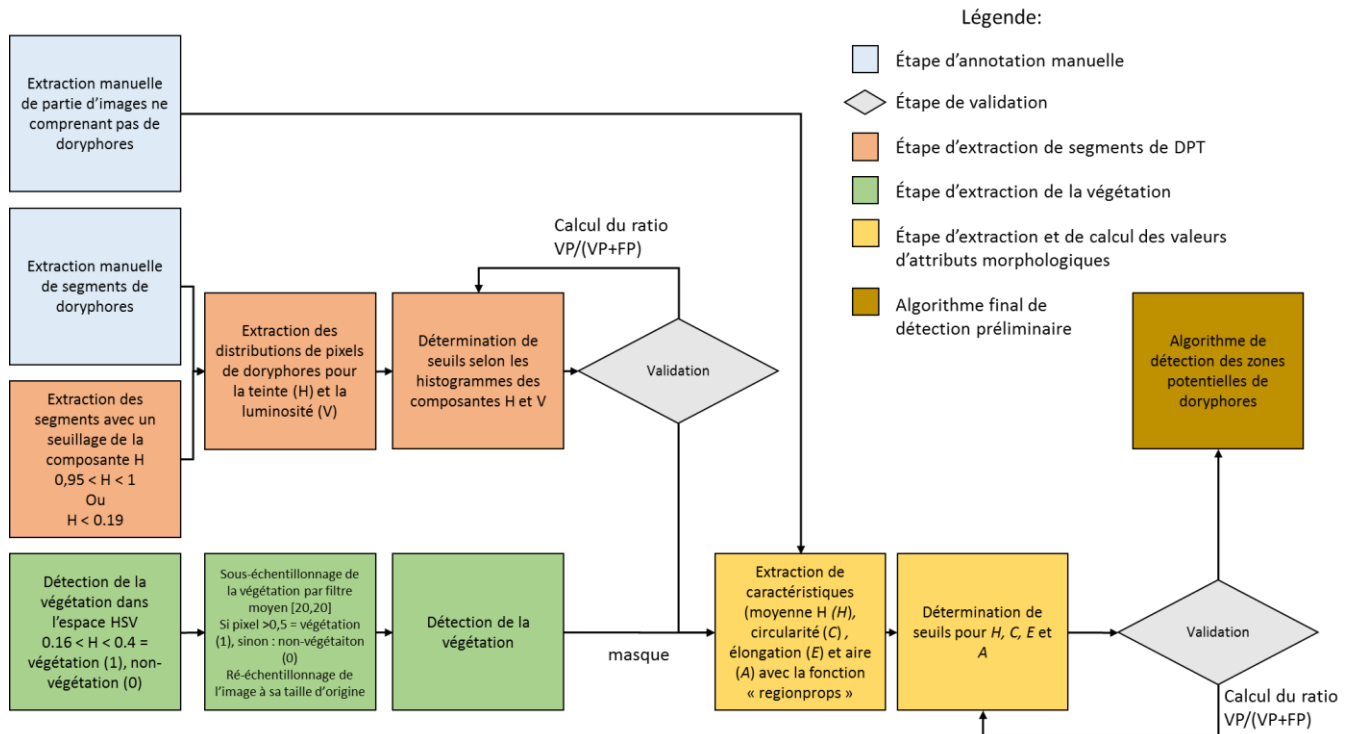


Figure 18: Schéma méthodologique détaillant le processus de conception de l'algorithme de détection préliminaire

L'idée derrière l'algorithme de détection préliminaire est d'inspecter les zones où il y a du feuillage pouvant être potentiellement le ravageur en extrayant les zones qui sont de la couleur recherchée. Afin de détecter la végétation, un seuillage est premièrement appliqué à l'image sur la teinte de l'espace HSV en associant une valeur de 1 aux pixels dont la valeur de teinte est supérieure à 0.16 et inférieure à 0.4. Ensuite, un filtre modal est implémenté à l'aide de la fonction « block_reduce » de la librairie python skimage.measure qui permet de sous-échantillonner l'image avec une fenêtre de dimension 20 x 20 pixels. Les pixels dont la valeur de moyenne est supérieure ou égale à 0.5 sont associés comme étant de la végétation alors que le reste est associé au sol. L'image est ensuite ré-échantillonnée à sa taille originale. Un filtre médian avec une

fenêtre de même taille aurait donné un résultat similaire, mais le temps de traitement aurait été beaucoup plus long.

La deuxième étape consiste à extraire une carte binaire des zones rougeâtres correspondant aux doryphores à l'aide d'un seuillage de la teinte et de la luminosité dans l'espace HSV. Afin de choisir les valeurs des seuils, la première étape a été d'extraire tous les segments connectés dont la valeur de teinte est supérieure à 0.95 et inférieure à 0.19 pour les images d'entraînement/validation. Ensuite, seulement les segments pour lesquels un doryphore a été identifié manuellement ont été conservés. La distribution des valeurs de pixels dans l'espace HSV et un intervalle de valeur pour la teinte (H) et la saturation ont été déterminés à partir de ces segments.

Un masquage des zones sans végétation a été effectué via le produit scalaire entre les cartes binaires de végétation et des zones rougeâtres afin d'extraire les segments potentiels. Par la suite, on extrait des attributs pour les segments de régions non nulles contiguës à l'aide de la fonction « regionprops » de la librairie python skimage.measure. Les attributs utilisés pour chaque segment sont la moyenne de la teinte, la circularité, l'élongation, l'aire et le nombre de pixels de végétation pour une fenêtre de 48x48 centrée sur le centroïde du segment. La circularité C est calculée comme suit (équation 17) :

$$C = \frac{\text{perimètre}^2}{4\pi * \text{Aire}} \quad (17)$$

L'élongation E est calculée comme suit (équation 18) :

$$E = \frac{\text{Longueur du grand axe}}{\text{Longueur du petit axe}} \quad (18)$$

Le périmètre, l'aire, la longueur du grand axe et la longueur du petit axe sont calculés par la fonction « regionprops » pour chacun des segments de pixels connectés. Afin de déterminer les valeurs des seuils d'attributs pour les segments de doryphores, les histogrammes de chaque attribut ont été analysés pour les segments de doryphores et de non-doryphores. L'utilisation d'autres attributs a été étudiée telle que la solidité et l'excentricité, mais leur utilisation n'a pas semblé apporter un gain assez important pour être inclus dans la méthode.

Pour chacune des zones potentielles, une imagerie de dimension variable est extraite. La dimension de la fenêtre est égale à la longueur du plus long côté du segment auquel on ajoute deux pixels. Cette fenêtre de dimension variable a été choisie dans le but de minimiser le bruit autour de la cible d'intérêt. Une fenêtre fixe peut introduire une grande quantité de bruit dans les images et des caractéristiques qui ne sont pas pertinentes à la classification des doryphores tels que des coins de feuilles, des tiges ou des pixels provenant du sol.

L'algorithme de détection préliminaire a été développé dans le langage de programmation Python en utilisant les bibliothèques NumPy, PIL, Scikit-Image et SciPy.

3.2.2 Détection par réseau de neurones convolutifs

Afin de développer un modèle permettant la classification des images extraites par la détection préliminaire, la méthode choisie nécessite de réentraîner un RNCP préalablement entraîné sur le jeu de données ImageNet possédant 1,2 million d'images de 1000 classes différentes. Cette méthode, nommée « transfert d'apprentissage », consiste à réutiliser l'apprentissage effectué préalablement à partir d'un jeu de données complètement différent pour réaliser une tâche de classification pour laquelle il n'a pas été originalement conçu. Pour ce faire, il est nécessaire de remplacer la dernière couche complètement connectée du réseau par un classificateur pouvant comprendre différentes couches cachées et ayant autant de neurones en sortie que de classes à différencier.

L'architecture de RNCP choisie est le ResNet pour différentes profondeurs soient 18, 34 et 50 couches de convolutions. Les architectures ResNet ont démontré des performances de pointes pour plusieurs jeux de données et ont démontré être de très bons extracteurs de caractéristiques (He *et al.*, 2015). La particularité de ce réseau est que les poids appris dans les couches inférieures du réseau sont propagés vers les couches supérieures du réseau (He *et al.*, 2016). La profondeur de l'architecture du réseau de neurones est étudiée afin de déterminer s'il y a un réel gain à utiliser une architecture très profonde par rapport au temps de traitement nécessaire, comme celui-ci augmente avec la profondeur de l'architecture utilisée.

3.3 Stratégies d'entraînement du réseau de neurones convolutif

Lors de la détection préliminaire, la méthode extrait beaucoup de plus de zones potentielles qu'il n'y a de Doryphore présent dans les images. Comme chacune de ces zones doit être classifiée par la suite, il s'agit donc d'un problème de classification non équilibré. Le déséquilibre des classes est un problème qui est relatif au degré de déséquilibre, à la complexité du concept représenté par les données, à la taille du jeu de données d'entraînement et au classificateur qui est utilisé (Japkowicz & Stephen, 2002). Afin de tenir compte du déséquilibre des classes, il est possible d'utiliser différentes stratégies d'entraînement comme le sur-échantillonnage, le sous-échantillonnage, le seuillage de la probabilité d'appartenance et l'apprentissage sensible aux coûts (Buda *et al.*, 2018). Cinq différentes stratégies d'entraînement ont été comparées lors de cette étude pour trois architectures ResNet (ResNet-18, ResNet-34, ResNet-50) pré-entraînées à partir du jeu de données ImageNet :

- le sur-échantillonnage (deux méthodes de sur-échantillonnage);
- le sous-échantillonnage (deux méthodes de sous-échantillonnage);
- l'apprentissage sensible aux coûts.

3.3.1 Stratégies d'entraînement pour faire face au déséquilibre des classes

Pour la stratégie de sur-échantillonnage, deux méthodes ont été comparées :

- Sur-échantillonnage v1 : Classe minoritaire augmentée, classe majoritaire aléatoirement réduite.
- Sur-échantillonnage v2 : Classe minoritaire augmentée synthétiquement (SMOTE), classe majoritaire réduite par la méthode des k-moyennes.

La première méthode (v1) consiste à créer des duplications de la classe minoritaire (classe doryphore) par augmentation de données afin que le nombre d'échantillons de la classe minoritaire soit égal au nombre d'échantillons de la classe majoritaire. Des modifications des images originales ainsi que des copies modifiées sont créées en utilisant aléatoirement différentes opérations telles que des translations, des rotations, des miroirs, des modifications de la teinte, de la saturation et de la luminosité en utilisant

la librairie python Augmentor (Bloice *et al.*, 2019). La classe majoritaire a été sous-échantillonnée aléatoirement.

La deuxième méthode (v2) de suréchantillonnage consiste à utiliser la méthode SMOTE (Synthetic Minority Over-sampling Technique) pour suréchantillonner la classe minoritaire et à utiliser la méthode k-moyennes pour sous-échantillonner la classe majoritaire. La méthode SMOTE nécessite de représenter chaque échantillon dans son espace de caractéristiques et a identifié ses k plus proches voisins. Afin de générer un échantillon synthétique, on prend un échantillon et le vecteur entre cet échantillon et un de ses k plus proches voisins. Ensuite on doit multiplier ce vecteur par un nombre aléatoire compris entre 0 et 1 et l'ajouter à l'échantillon, ce qui résulte en un nouvel échantillon synthétique (Chawla *et al.*, 2002). Le sous-échantillonnage *k-moyennes* nécessite de créer un nombre k de noyaux dans l'espace de caractéristiques à partir des échantillons d'entraînement. Les échantillons synthétiques pour la classe majoritaire sont les centroïdes de chaque noyau. Ces méthodes de génération de données ont été implémentées grâce à la librairie Python Imbalanced-Learn (Lemaître *et al.*, 2017).

Pour la stratégie du sous-échantillonnage, deux méthodes ont également été comparées :

- Sous-échantillonnage v1 : Classe minoritaire augmentée sans ajout d'échantillon, classe majoritaire réduite aléatoirement afin que le rapport des classes soit de 1.
- Sous-échantillonnage v2 : Classe minoritaire augmentée sans ajout d'échantillon, classe majoritaire réduite par la méthode des *k-moyennes* afin que le rapport des classes soit de 1.

La première (v1) consiste à réduire le nombre d'échantillons de la classe majoritaire aléatoirement. Alors que la deuxième (v2), consiste à réduire le nombre d'échantillons de la classe majoritaire avec la méthode k-moyennes. Pour les deux méthodes, les échantillons ont subi des modifications de couleur, de luminosité, de rotation et de miroir aléatoirement avant l'entraînement.

La stratégie de l'apprentissage sensible au coût consiste à entraîner un réseau avec un jeu de données non balancé et en assignant un poids différent à chacune des classes. Le poids est un facteur pondéré introduit dans la fonction de coût qui est utilisée afin de

donner davantage de poids à la classe minoritaire. Afin de sauvegarder le meilleur modèle, la validation a été effectuée en fonction de la valeur minimale de la fonction de coût contrairement aux autres stratégies pour lesquelles la précision globale maximale a été utilisée. Les échantillons de la classe minoritaire ont un poids 15 fois supérieur à celui de la classe majoritaire afin de compenser le déséquilibre des classes.

3.3.2 Les hyperparamètres

Comme la taille des images des jeux de données est relativement faible (maximum 21x21), la taille de l'image d'entrée du RNCP a été fixée à 64x64. De plus, une faible taille d'image d'entrée réduit la quantité d'opérations mathématiques à effectuer et donc le temps de calcul.

Le classificateur est un ensemble de couches rajouté à l'architecture préentraînée remplaçant la dernière couche du réseau. Pour un cas de classification binaire, la dernière couche du réseau choisie peut être composée de 1 perceptron d'activation sigmoïde connecté à une couche précédente. Comme le jeu de données est de petite taille, il est intéressant d'utiliser le Dropout afin de réduire les risques de surapprentissage. Différents tests de classificateurs ont été effectués, par exemple l'ajout d'une couche complètement connectée entre le filtre moyen global et le Dropout, avec différents taux de probabilité de Dropout ou directement du filtre moyen global au perceptron d'activation sigmoïde. Le classificateur choisi est composé de :

- Filtre moyen global;
- couche Dropout avec probabilité de 30%;
- couche d'un perceptron avec activation sigmoïde.

La fonction de coût utilisée pour l'entraînement des modèles est la fonction de l'entropie-croisée binaire avec une taille de lot de 32 échantillons. L'ensemble des couches du réseau incluant le classificateur ont été entraînées avec une fonction d'optimisation adaptée au jeu de données utilisé. Pour les jeux de données suréchantillonnées v1, sous-échantillonné v1 et non balancé, la fonction d'optimisation utilisée est la descente de gradient stochastique avec un taux d'apprentissage fixe de 0.0001 et un momentum de 0.9. Tandis que pour les deux autres jeux de données, la descente de gradient

stochastique avec taux variable a été utilisée. Pour cette méthode d'optimisation, le taux d'apprentissage initial est de 0.01 pour être multiplié par un facteur de 0.5 à toutes les cinq époques avec un momentum de 0.9.

L'entraînement du RNCP s'est fait pour un maximum de 100 époques ou jusqu'à ce qu'il n'y ait aucune amélioration sur la validation pour 20 époques consécutives. Dans ce cas, l'entraînement a été arrêté et le meilleur modèle a été sauvegardé. Pour les différentes stratégies d'apprentissage, l'ensemble des couches de l'architecture ainsi que le classificateur ont été entraînés. Lors de l'entraînement, les échantillons sont mélangés aléatoirement et une augmentation de données pour chaque lot d'échantillons est effectuée différemment à chaque époque. Les transformations appliquées sont : un miroir horizontal, des rotations d'angle de 90° et des translations dans l'axe X et Y de 10% de la taille de l'image appliquée aléatoirement. Afin d'entraîner les différents modèles, des scripts d'automatisation ont été utilisés dans le langage de programmation python en utilisant les bibliothèques Python Keras, TensorFlow, NumPy, Scipy et PIL.

3.4 Création des cartes de dépistage

Comme les populations de larves de doryphores sont très agrégées, des cartes de dépistage sont utilisées afin d'identifier ces agrégations. Ces agrégations se traduisent par une concentration de détections par l'algorithme et permettent de réduire les incertitudes dans la localisation des foyers d'infestations.

Les cartes de dépistage sont calculées en découpant l'image en grille de taille 6x4. Chacune des cases de la grille comprend 1000 x 1000 pixels de l'image originale. Pour chacune des cases de la grille de superficie d'environ 1,17 m, on calcule le nombre de détections positives repérées par l'algorithme. Selon le nombre de détections, on attribue un risque que ce soit un foyer d'infestation. Pour 0 à 1 détection, le risque est faible. Pour 2 à 3 détections, le risque est modéré et pour 4 détections et plus le risque est élevé.

3.5 Validation des algorithmes

3.5.1 Jeux de données d'entraînement, de validation, de test et de foyers d'infestations

Afin d'entraîner un algorithme de détection, il est nécessaire de séparer les données en différents jeux de données. Le jeu de données d'entraînement sert à calibrer le modèle tandis que le jeu de données de validation sert à évaluer ce modèle à chaque itération de calibration. Un troisième jeu de données complètement indépendant (jeu de données tests) est utilisé afin de mesurer la précision des modèles une fois l'entraînement complété de façon complètement indépendante et fidèle aux données évaluées dans un contexte opérationnel. Le ratio optimal afin de séparer les jeux de données d'entraînement, de validation et de test dépend de la complexité du problème de classification (Guyon, 1997). Une bonne pratique est d'utiliser généralement 70% des données pour l'entraînement, 15 % pour la validation et 15% pour le jeu de données tests.

Afin de construire les jeux de données, les images acquises par drones ont été inspectées minutieusement. Les positions des doryphores dans les images (grosses larves et adultes principalement) ont été enregistrées dans un tableur comprenant comme une information le code de l'image et les positions X et Y du centre de l'individu. 53 images acquises par drones ont été utilisées pour la base de données d'entraînement pour un décompte total de 1066 individus. L'algorithme de détection préliminaire a permis de détecter les zones potentielles dans ces images. Les zones communes à l'identification manuelle et à la détection préliminaire ont été extraites et intégrées dans la base de données. Pour les jeux de données de validation et de tests, 6 et 7 images de drone ont été utilisées respectivement avec la même méthode d'extraction des échantillons. Le résultat final comprend 922 DPT pour la base de données d'entraînement, 179 DPT pour la base de données de validation et 199 DPT pour la base de données test. Afin d'extraire des échantillons non-doryphore, des parties d'images ou des images entières comprenant des plants de pommes de terre, mais aucun DPT ont été extraites. L'algorithme de détection préliminaire a extrait les zones potentielles de ces sections d'images et ces zones constituent les échantillons non-doryphores pour la base de données d'entraînement. Tandis que pour les jeux de validation et de test, ce sont les

échantillons pour lesquels aucune identification visuelle ne correspondait à la zone potentielle.

Pour les différents jeux de données, les images ont été choisies afin qu'il y ait peu de chevauchement entre celles-ci afin qu'il n'y ait pas de doublons dans les bases de données. Les images pour lesquelles un dépistage conventionnel a été effectué ont été choisies pour concevoir les jeux de validation et de tests (Figure 19).

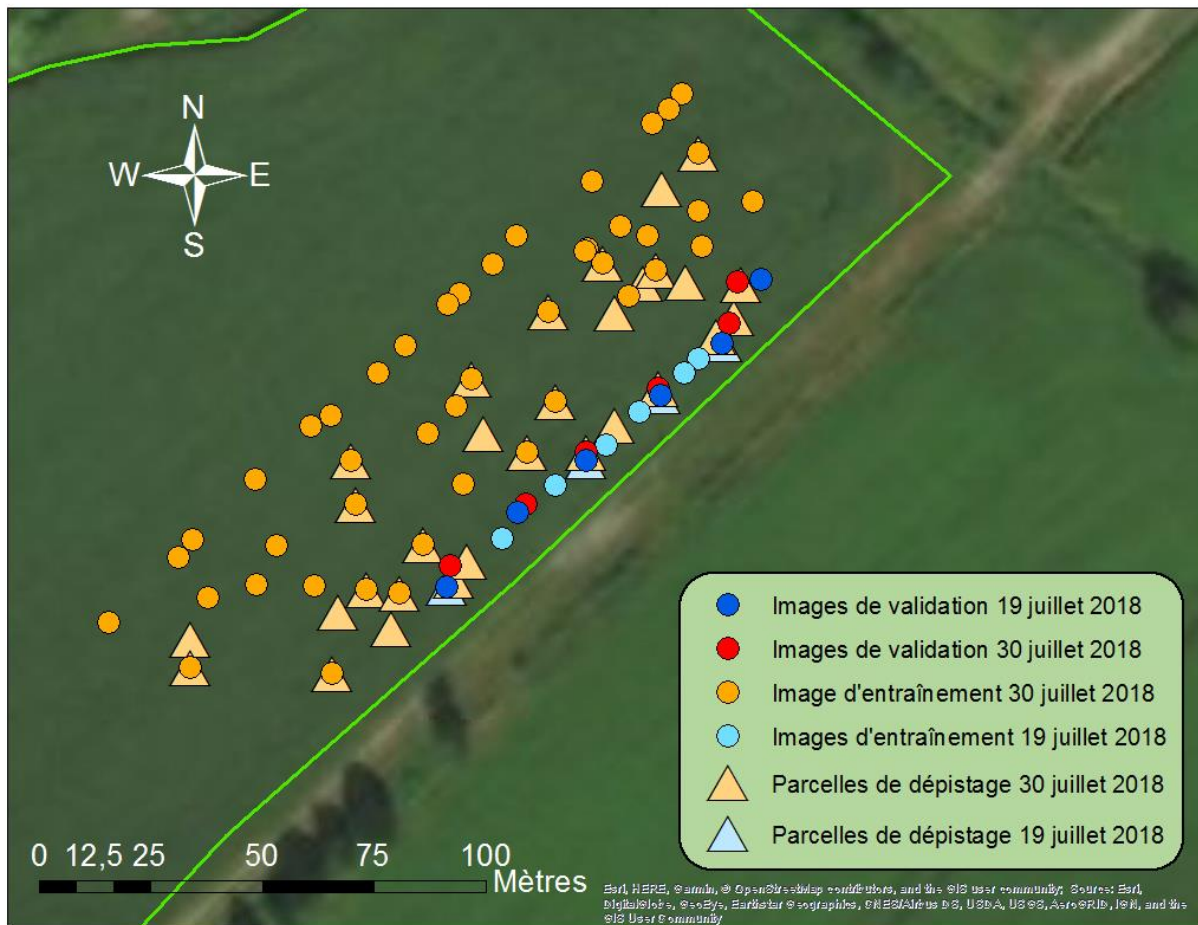


Figure 19: Géolocalisation des parcelles de dépistage et des images acquises par drone utilisées pour les jeux de données d'entraînement, de validation et de tests.

Le Tableau 7 détaille les jeux de données utilisés par les différentes stratégies d'entraînement, le nombre d'échantillons associés pour chacune des classes et la méthode de validation utilisée.

Tableau 7: Différents jeux de données pour les stratégies d'entraînement utilisées comprenant le nombre d'échantillons pour chacune des classes

Stratégies d'entraînement				
Jeux de données	n Doryphore	n Non-Doryphore	Validation	n Images de drone
Sous-échantillonnage - v1	922	922	balancée	54
Sous-échantillonnage - v2	922	922	balancée	54
Suréchantillonnage - v1	8000	8000	Balancée	54
Suréchantillonnage - v2	8000	8000	Balancée	54
Apprentissage sensible au coût (coût de 15 :1)	922	22986	non balancée	54

Selon la stratégie d'entraînement utilisée, il y a eu deux approches différentes pour la validation en cours de calibration de l'algorithme. Pour les jeux de données balancés, le meilleur modèle a été sauvegardé en fonction de la valeur maximale de précision globale du jeu de données de validation balancé. Ce dernier a été conçu en extrayant aléatoirement des échantillons de la classe majoritaire afin que le nombre d'échantillons des deux classes soit équivalent. Tandis que pour la stratégie d'apprentissage sensible au coût avec un jeu de donnée non balancé, le modèle le plus performant a été déterminé selon la valeur de la fonction de coût la plus faible sur un jeu de donnée de validation non balancé, comprenant l'ensemble des échantillons issu des zones potentielles des images acquises par drone. Les jeux de données de validation et de test n'ont pas subi de modifications par augmentation de données ni de rehaussement d'histogramme. Le jeu de données de validation comprend des imagerie issues de 6 images de drone dont 3 avec les paramètres d'acquisition de la première sortie terrain et 3 avec les paramètres d'acquisition de la deuxième sortie. Tandis que le jeu de données tests comprend 3 images de la première sortie et 4 images de la deuxième sortie. Le jeu de données tests a été utilisé afin de comparer les différents modèles de façon complètement indépendante tout en tenant compte du déséquilibre des classes. Les jeux de données sont détaillés dans le Tableau 8.

Tableau 8 : Jeux de données de validation et de tests comprenant le nombre d'échantillons de chacune des classes

Validation/test			
Jeux de données	n Doryphore	n Non-Doryphore	n Images de drone
Validation – balancée	191	191	6
Validation – non balancée	191	6050	6
Test	214	6908	7

Pour chacun des modèles entraînés, une valeur de seuil de probabilité p a été déterminée empiriquement sur le jeu de données de validation non balancé afin de maximiser le f1-score et la précision. Afin de produire des cartes de dépistage permettant l'intervention ciblée, il est important de ne pas trop surestimer la présence de doryphore. C'est pourquoi la mesure de la précision a été choisie afin que celle-ci soit maximisée tout en ayant un f1-score élevé. Ensuite, chacun des modèles est évalué selon le jeu de données tests à partir de cette valeur de p afin de les comparer les uns aux autres.

En plus de la validation des détections de doryphores, une validation à l'échelle des foyers d'infestations a été effectuée. Pour ce faire, à partir des images utilisées dans les phases de validation et de tests, les positions X, Y des centres des foyers d'infestations ont été relevés pour chacune des images. Lorsqu'il y a présence de 5 doryphores ou plus, ceci a été considéré comme un foyer d'infestation. Le jeu de données des foyers d'infestation comprend donc 13 images acquises par drone pour un total de 30 foyers d'infestation. Ce jeu de données servira à valider les cartes de dépistage produites.

De plus, une analyse comparant le dépistage effectué par drone et le dépistage de doryphores de façon conventionnelle sera effectuée en comparant le nombre de doryphores (adultes, 3^e et 4^e stades larvaires) qui était visible au sommet de la canopée lors du dépistage et le nombre de doryphores détectés par la méthode proposée. Des coefficients de détermination seront calculés permettant de comparer les méthodes entre elles.

3.5.2 Métriques de validation

Afin d'évaluer un jeu de données non balancé, il est peu approprié d'utiliser la précision globale (équation 19) comme mesure d'évaluation puisque celle-ci tient compte du nombre total de bonnes prédictions par rapport au nombre total d'échantillons. Si une classe est largement surreprésentée, la précision globale peut être très élevée tout en ayant un faible taux de détection pour la classe minoritaire. Les métriques d'évaluation à privilégier sont par exemple le rappel, la précision et le f1-score. La précision (équation 20) est une mesure de l'exactitude du classificateur, une précision faible indique que le classificateur surestime les éléments positifs (nombre de faux positifs élevés). Tandis que le rappel (équation 21) est une mesure de l'exhaustivité d'un classificateur. Un faible rappel indique une sous-estimation des éléments positifs (un nombre élevé de faux négatifs). Le f1-score (équation 22) est la moyenne harmonique entre la précision et le rappel.

Voici comment les différentes métriques d'évaluation sont calculées :

$$\text{Précision globale} = \frac{VP+VN}{VP+VN+FP+FN} \quad (19)$$

$$\text{Précision} = \frac{VP}{VP+FP} \quad (20)$$

$$\text{Rappel} = \frac{VP}{VP+FN} \quad (21)$$

$$\text{F1-Score} = 2 * \frac{(\text{Précision} * \text{Rappel})}{(\text{Précision} + \text{Rappel})} \quad (22)$$

Où : VP est le nombre de vrais-positifs, VN est le nombre de vrais-négatifs, FP est le nombre de faux positifs et FN est le nombre de faux négatifs.

La matrice de confusion est également utilisée afin de présenter de manière relative ou absolue les résultats de validation. Celle-ci s'exprime comme suit :

$$\begin{bmatrix} VP & FN \\ FP & VN \end{bmatrix}$$

4 RÉSULTATS ET DISCUSSION

4.1 Détection préliminaire

À partir des distributions de pixels de segments connectés, les valeurs de seuils choisis sont celles du 5^e et 80^e percentiles (Figure 20) pour la teinte (H) et la valeur du 10^e percentile a été conservée pour la luminosité (S), afin de seulement éliminer les pixels trop sombres (Figure 21).

Les valeurs des seuils choisies sont les suivantes:

- 0.06 (5^e centile) < teinte ≤ 0.16 (80^e centile)
- 0.35 (10^e centile) < luminosité

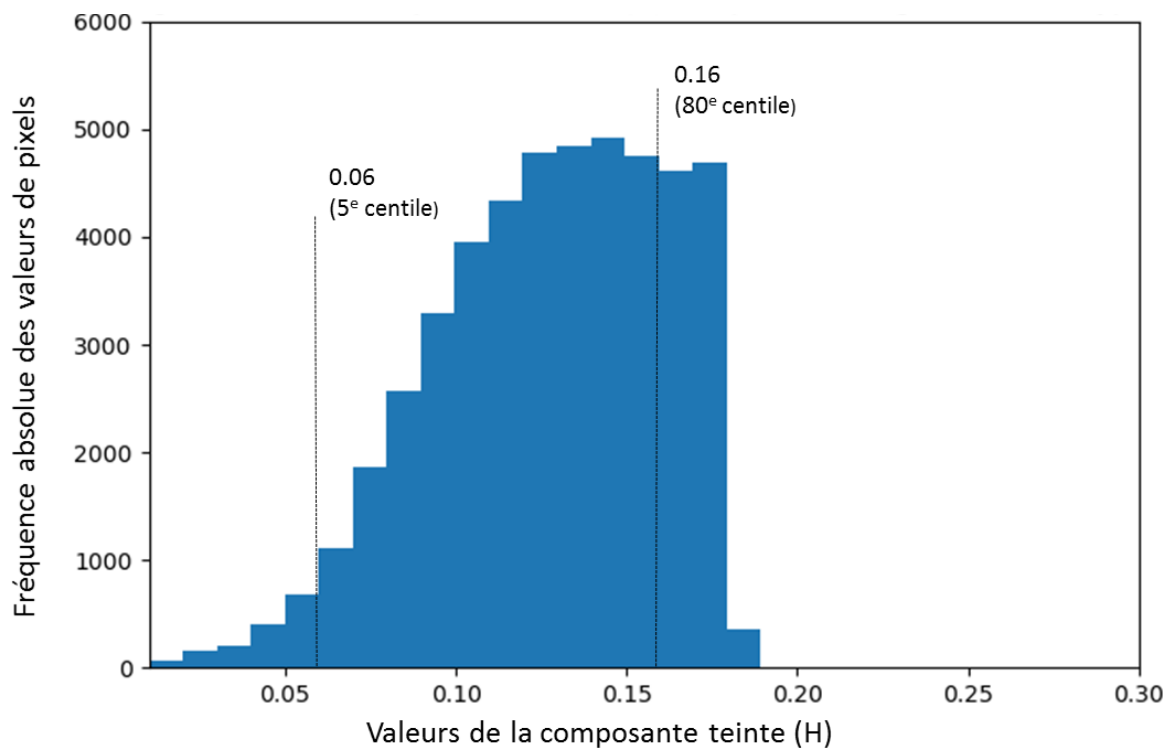


Figure 20: Histogramme de la composante teinte (H) des pixels de segments de doryphores et valeurs de seuils déterminés




Figure 21: Histogramme de la composante luminosité (V) des pixels de segments de doryphores et valeurs de seuils déterminés

Les valeurs de seuils choisis pour les attributs morphologiques sont les suivants :

- $0.07 \leq \text{Moyenne de la teinte (H)} \leq 0.145$
- $0.5 \leq \text{Circularité} \leq 2.3$
- $1 \leq \text{Élongation} \leq 2.3$
- $6 \leq \text{Aire} \leq 100$
- 80% de végétation présente autour du segment dans une fenêtre de 48 x 48 pixels

Ces seuils ont été choisis à partir des distributions à l'échelle des segments de doryphores et non-doryphores présentés dans les figures suivantes (Figure 22 à Figure 25).

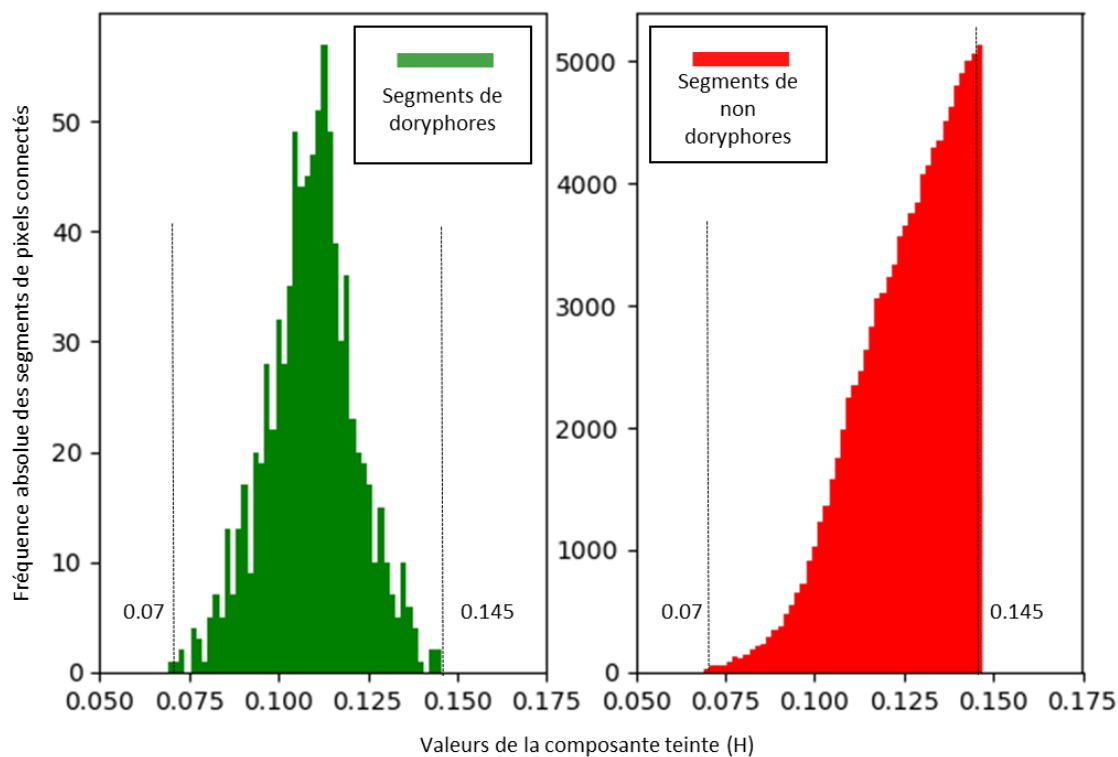


Figure 22: Histogramme de la composante teinte (H) des segments de doryphores et de non-doryphores et valeurs des seuils déterminés

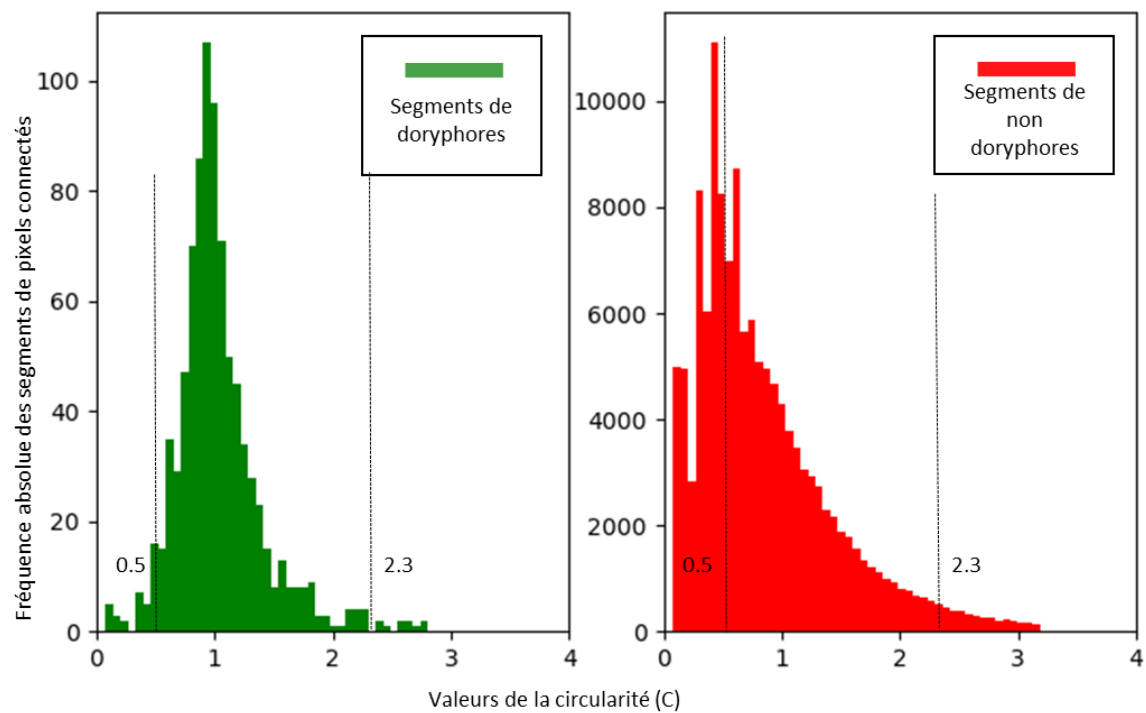


Figure 23: Histogramme de la circularité (C) des segments de doryphores et de non-doryphores et valeurs des seuils déterminés

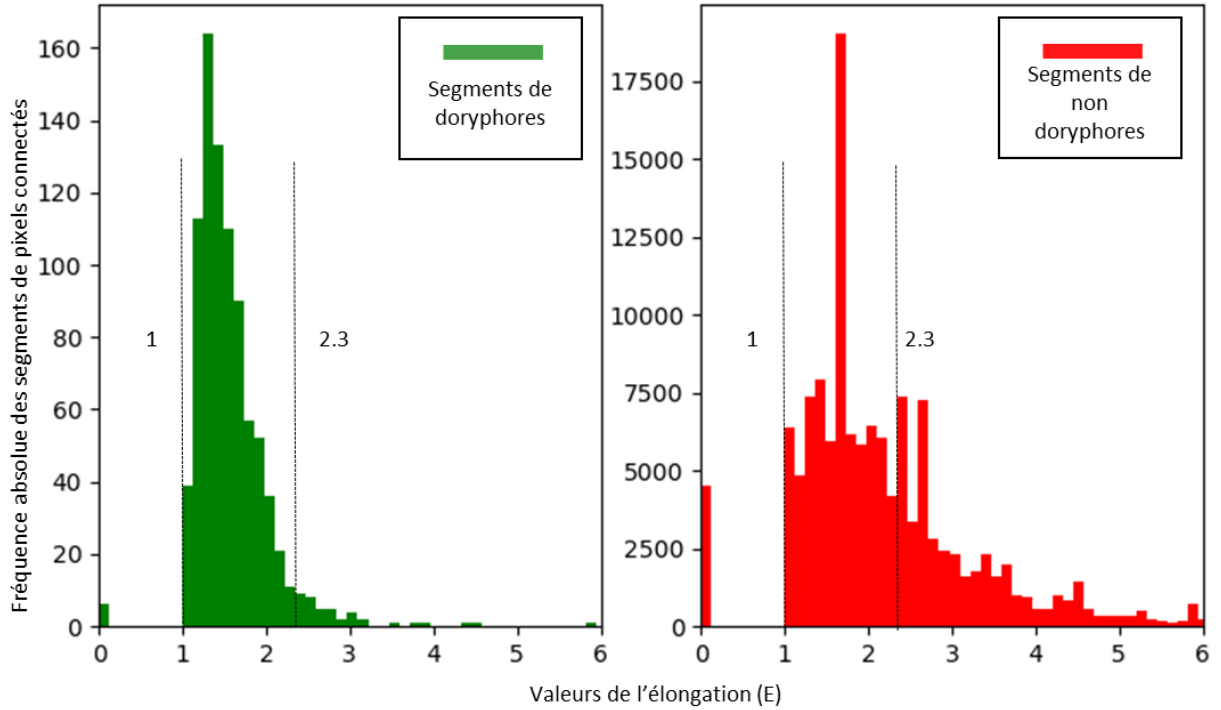


Figure 24: Histogramme de l'élongation (E) des segments de doryphores et non-doryphores et valeurs des seuils déterminés

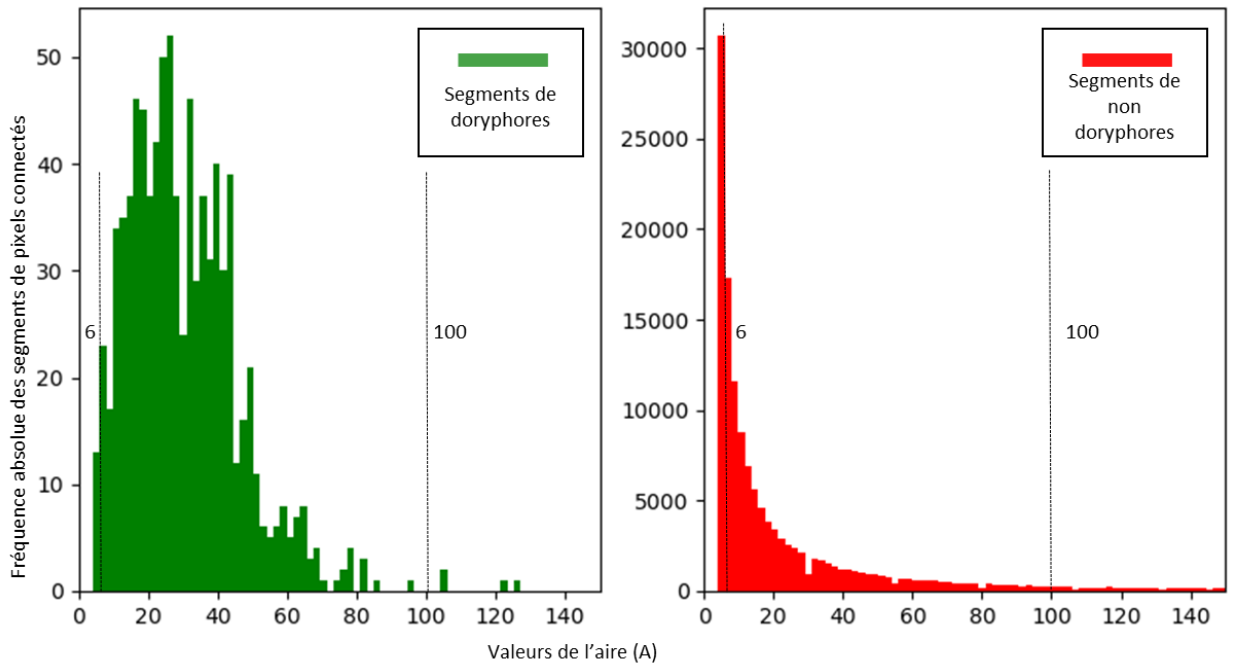


Figure 25: Histogramme de l'aire (A) des segments de doryphores et non-doryphores et valeurs des seuils déterminés

Les valeurs des seuils influencent directement le nombre de zones potentielles qui sera traité par l'algorithme de détection utilisant les RNCP. Donc, plus il y a de zones potentielles, plus le temps de traitement est long. Cependant, il est important d'omettre le moins de doryphores possible à cette étape. Plusieurs essais et erreurs de valeurs de seuils ont permis de déterminer le juste bon compromis entre faible omission de doryphore et plus faible nombre de zones potentielles possible afin de réduire le temps de traitement et le nombre de faux positifs.

Pour l'ensemble des images utilisées, un décompte du nombre de doryphores détectés par rapport au nombre de doryphores présents a été effectué afin de qualifier la précision de l'algorithme de détection préliminaire. Le nombre de zones potentielles pour chacune de ces images a également été calculé afin de pouvoir estimer une moyenne de zone potentielle par image. La mesure du rappel a été choisie afin de qualifier la performance de la méthode compte tenu du nombre élevé de zones potentielles et que l'objectif à cette étape est d'omettre le moins de doryphores. Le tableau suivant (Tableau 9) présente les résultats pour les images des différents jeux de données.

Tableau 9 : Résultat de la détection préliminaire pour les jeux de données d'entraînement, de validation et de tests pour les différentes sorties terrain d'acquisition des images.

Jeux de données	Sortie terrain	n images	moyenne de zones potentielles/image	n Doryphores détectés	n Doryphores présents	Rappel (%)
Entraînement	19-juil-18	6	1031,17	127	141	90,07
Entraînement	30-juil-18	48	940,58	795	934	85,12
Validation	19-juil-18	3	921,00	90	100	90,0
Validation	30-juil-18	3	1159,33	101	115	87,83
Test	19-juil-18	3	895,67	125	140	89,29
Test	30-juil-18	4	1108,75	89	117	76,07
TOTAL		67	965,64	1327	1547	85,78

On observe que le choix des seuils à partir des images d'entraînement permet de repérer les doryphores dans les images de validation et de test avec un taux de succès similaire. À cette étape, environ 14,2% des doryphores présents sont omis pour une moyenne d'environ 965 zones potentielles par images. Les échantillons qui sont omis à cette étape

n'ont pas répondu aux conditions déterminées dans l'algorithme de détection préliminaire. Parfois la forme du segment, l'aire ou la couleur peuvent être responsables de ces omissions. Il ne semble pas y avoir de différence significative entre le nombre de zones potentielles pour les images acquises le 19 ou le 30 juillet. L'exemple ci-dessous (Figure 26) présente la détection de la végétation et des zones potentielles pour un foyer d'infestation. On peut remarquer qu'il y a une omission de deux doryphores collés (encerclé en jaune) au bas de la fenêtre de droite. Cette omission peut être due à l'aire du segment qui dépasse 100 pixels ainsi qu'à la forme du segment. Cependant, plusieurs doryphores isolés sont bien détectés par la détection préliminaire pour cet exemple. Le temps de calcul estimé à l'aide d'un processeur d'ordinateur mobile de 2,8 GHz (i5) est d'environ 22 secondes pour une image complète, ce qui prouve que la méthode développée est assez simple en termes de complexité de calculs. Somme toute, la détection préliminaire parvient à réduire le temps de calcul ainsi qu'à repérer une grande partie des larves et adultes du DPT.




Figure 26: Parcelle de dépistage #4 du 19 juillet 2018 (droite), classification de la végétation (milieu) et les zones potentielles issues de la détection préliminaire (droite).

4.2 Comparaison des stratégies d'entraînement de réseaux de neurones convolutif

L'entraînement des réseaux de neurones est un art en soi puisqu'une multitude d'hyperparamètres peuvent être ajustés et il n'existe pas une seule règle applicable et fonctionnelle à l'ensemble des jeux de données. Plusieurs ajustements doivent être faits afin de déterminer les paramètres optimaux et ainsi maximiser la performance du modèle. Il est important d'inspecter l'allure de la courbe d'entraînement afin de déterminer si l'entraînement est stable d'une époque à l'autre et si celui-ci converge vers le minimum global de la fonction de coût. Ce graphique comprend en l'axe des x les époques parcourues et en axe y la valeur de précision globale ou de coût du modèle. Les Figure 27 à Figure 41 présentent les courbes d'entraînement pour la précision globale et la fonction de coût pour chacun des modèles comparés. À partir de ces graphiques, on peut déjà observer les modèles qui devraient présenter une bonne capacité de généralisation. Par exemple, on peut observer que pour l'ensemble des modèles entraînés avec les jeux de données suréchantillonnés v1 et sous-échantillonné v1, la courbe de validation est relativement rapprochée de celle d'entraînement et que les valeurs de précision globale et de coût sont peu variables d'une époque à l'autre. C'est un bon indice que le modèle a convergé vers la meilleure solution. On remarque que les résultats pour ce jeu de données semblent être meilleurs pour le jeu de données de validation. On peut expliquer ceci par la taille du jeu de données de validation qui est beaucoup plus petite que celle du jeu de donnée d'entraînement. Tandis que pour les modèles entraînés à partir des jeux de données suréchantillonnées v2 et sous-échantillonner v2, il y a un écart considérable entre la validation et l'entraînement. La différence importante de performance du modèle entre les deux jeux de données démontre qu'il y a du surapprentissage. Les fluctuations pour les modèles d'échantillons v2 peuvent également être expliquées par le taux d'apprentissage élevé qui a été utilisé pour entraîner ces modèles et qui diminue de façon incrémentielle à chaque cinq époques (figures 33 - 38). De plus, la valeur de validation est très faible en comparaison avec la courbe d'entraînement pour les modèles sous-échantillonnés v2 ce qui indique un surapprentissage. Pour les modèles entraînés sur le jeu de données non balancé, les fluctuations sont assez importantes pour la courbe de validation, mais demeurent en haut

de 90% de précision globale. Il est important de noter qu'environ 97% des données sont des échantillons non-doryphores pour ces modèles. Comme la validation se fait avec un seuil de probabilité de 0.5, il est normal que la précision globale soit autour de 90%. Il serait plus inquiétant d'obtenir un modèle dont la valeur de précision globale demeure stable autour de 97% puisque cela peut indiquer que l'ensemble des échantillons sont classifiés comme étant des non-doryphores et donc que l'algorithme ne reconnaît pas la classe la plus importante. De plus, on peut observer que la valeur de coût présente des fluctuations importantes pouvant être causées par une pénalité plus élevée due à la pondération de la classe doryphore. L'entraînement de tous les modèles a été arrêté avant d'atteindre 100 époques puisque ceux-ci ont répondu au critère d'arrêt lorsqu'il n'y a pas d'amélioration pour 20 époques consécutives. Le Tableau 10 présente les résultats des meilleures époques utilisées pour l'enregistrement des modèles.

Tableau 10: Époques d'entraînement pour lesquelles les meilleurs modèles ont été sauvegardés

Modèle	Meilleure époque (validation)	Précision globale (validation) (%)	Coût (validation)
ResNet-18 suréchantillonné v1	39	97,21	0,099
ResNet-18 suréchantillonné v2	11	90,78	0,272
ResNet-18 non balancé 15-1	69	96,62	0,089
ResNet-18 sous-échantillonné v1	38	94,41	0,171
ResNet-18 sous-échantillonné v2	12	68,99	0,615
ResNet-34 suréchantillonné v1	21	96,37	0,115
ResNet-34 suréchantillonné v2	19	92,18	0,246
ResNet-34 non balancé 15-1	10	95,88	0,110
ResNet-34 sous-échantillonné v1	71	94,69	0,168
ResNet-34 sous-échantillonné v2	11	67,64	0,715
ResNet-50 suréchantillonné v1	21	97,49	0,097
ResNet-50 suréchantillonné v2	1	91,06	0,214
ResNet-50 non balancé 15-1	34	96,94	0,080
ResNet-50 sous-échantillonné v1	48	94,41	0,167
ResNet-50 sous-échantillonné v2	20	66,20	1,521

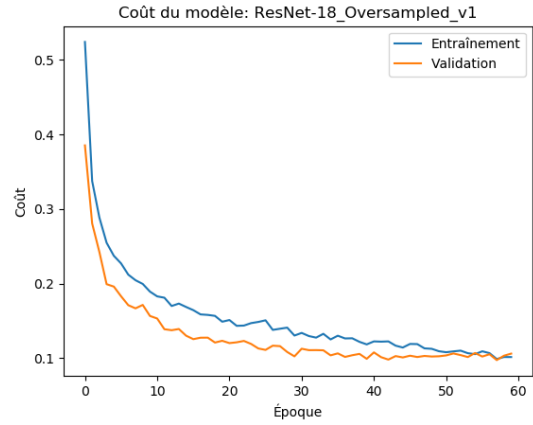
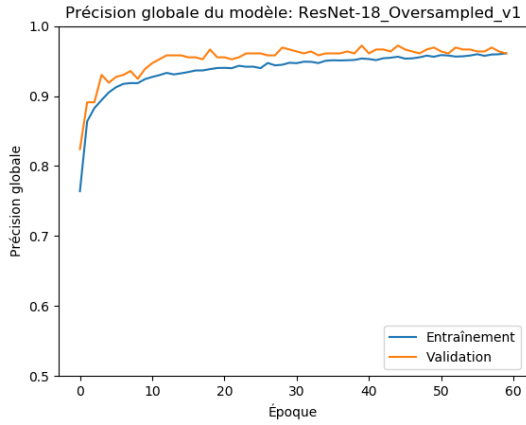


Figure 27: Précision globale (gauche) et fonction de coût (droite) par rapport au nombre d'époques pour l'entraînement et la validation du modèle ResNet-18 suréchantillonné v1





Figure 28: Précision globale (gauche) et fonction de coût (droite) par rapport au nombre d'époques pour l'entraînement et la validation du modèle ResNet-18 suréchantillonné v2


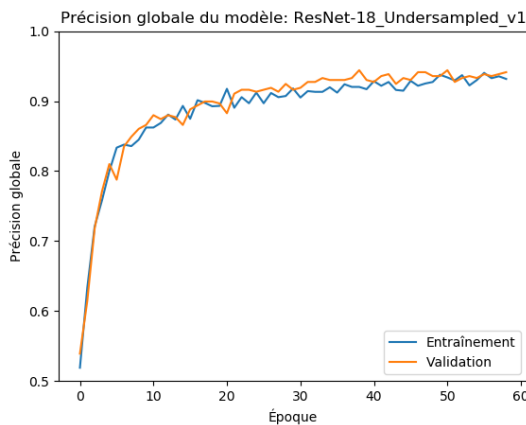


Figure 29: Précision globale (gauche) et fonction de coût (droite) par rapport au nombre d'époques pour l'entraînement et la validation du modèle ResNet-18 sous-échantillonné v1

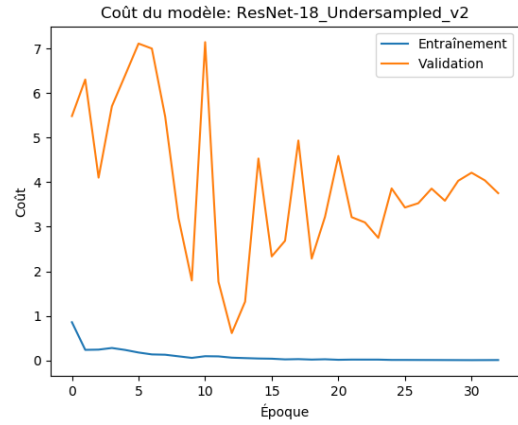



Figure 30: Précision globale (gauche) et fonction de coût (droite) par rapport au nombre d'époques pour l'entraînement et la validation du modèle ResNet-18 sous-échantillonné v2





Figure 31: Précision globale (gauche) et fonction de coût (droite) par rapport au nombre d'époques pour l'entraînement et la validation du modèle ResNet-18 non balancé





Figure 32: Précision globale (gauche) et fonction de coût (droite) par rapport au nombre d'époques pour l'entraînement et la validation du modèle ResNet-34 suréchantillonné v1





Figure 33: Précision globale (gauche) et fonction de coût (droite) par rapport au nombre d'époques pour l'entraînement et la validation du modèle ResNet-34 suréchantillonné v2





Figure 34: Précision globale (gauche) et fonction de coût (droite) par rapport au nombre d'époques pour l'entraînement et la validation du modèle ResNet-34 sous-échantillonné v1





Figure 35: Précision globale (gauche) et fonction de coût (droite) par rapport au nombre d'époques pour l'entraînement et la validation du modèle ResNet-34 sous-échantillonné v2




Figure 36: Précision globale (gauche) et fonction de coût (droite) par rapport au nombre d'époques pour l'entraînement et la validation du modèle ResNet-34 non balancé

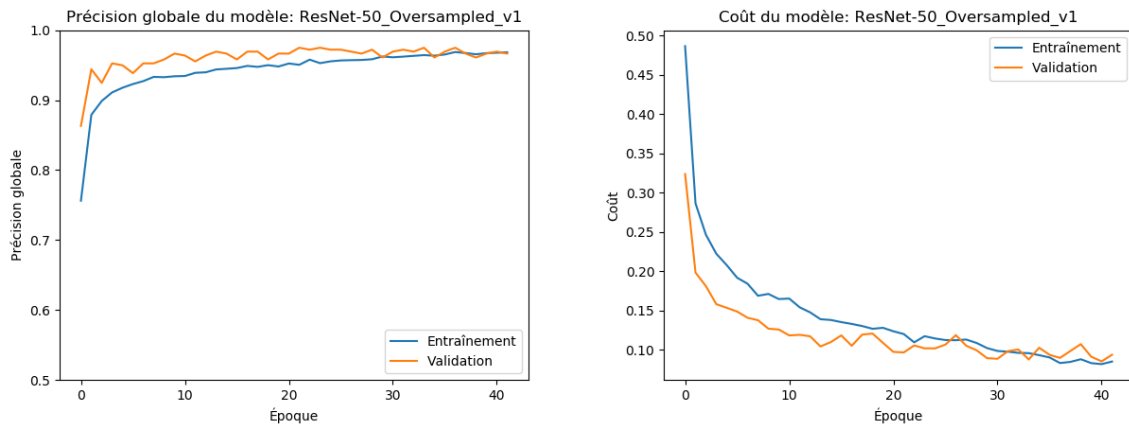


Figure 37: Précision globale (gauche) et fonction de coût (droite) par rapport au nombre d'époques pour l'entraînement et la validation du modèle ResNet-50 suréchantillonné v1




Figure 38: Précision globale (gauche) et fonction de coût (droite) par rapport au nombre d'époques pour l'entraînement et la validation du modèle ResNet-50 suréchantillonné v2





Figure 39: Précision globale (gauche) et fonction de coût (droite) par rapport au nombre d'époques pour l'entraînement et la validation du modèle ResNet-50 sous-échantillonné v1





Figure 40: Précision globale (gauche) et fonction de coût (droite) par rapport au nombre d'époques pour l'entraînement et la validation du modèle ResNet-50 sous-échantillonné v2





Figure 41: Précision globale (gauche) et fonction de coût (droite) par rapport au nombre d'époques pour l'entraînement et la validation du modèle ResNet-50 non balancé

Tableau 11: Résultat des différents modèles pour le jeu de données de validation non balancé

Jeu de données Validation non balancé				
Modèle	Seuil p	Précision (%)	Rappel (%)	F1-score (%)
ResNet-18 suréchantillonné v1	0.06	81.11	76.44	78.71
ResNet-18 suréchantillonné v2	0.03	67.25	60.21	63.54
ResNet-18 non balancé 15-1	0.055	83.04	74.35	78.45
ResNet-18 sous-échantillonné v1	0.06	76.30	69.11	72.53
ResNet-18 sous-échantillonné v2	0.05	23.63	36.13	28.57
ResNet-34 suréchantillonné v1	0.045	82.61	69.63	75.57
ResNet-34 suréchantillonné v2	0.035	57.92	67.02	62.14
ResNet-34 non balancé 15-1	0.09	78.42	78.01	78.22
ResNet-34 sous-échantillonné v1	0.07	71.58	71.20	71.39
ResNet-34 sous-échantillonné v2	0.015	20.26	24.08	22.01
ResNet-50 suréchantillonné v1	0.07	79.78	76.44	78.08
ResNet-50 suréchantillonné v2	0.055	77.93	59.16	67.26
ResNet-50 non balancé 15-1	0.09	75.81	73.82	74.80
ResNet-50 sous-échantillonné v1	0.04	78.44	68.59	73.18
ResNet-50 sous-échantillonné v2	0.01	07.22	79.58	13.24

Pour chacun des modèles, une valeur de probabilité maximisant le f1-score et la précision a été choisie. Pour ce faire, les probabilités de chacun des échantillons du jeu de données de validation non balancé ont été estimées avec chaque modèle. Les fréquences de probabilité pour les deux classes ont été générées (Annexe 210) et à partir de ces distributions de probabilité une étendue de seuils (0.05 à 0.15 par incrément de 0.005) a été testée. Le Tableau 11 présente les résultats des métriques de validation des différents modèles selon le meilleur seuil p choisi. La valeur zéro est associée aux échantillons de doryphore lors de l'entraînement des modèles et c'est pourquoi la probabilité est près de zéro. Lorsque la valeur de probabilité est inférieure au seuil p , l'échantillon se fait assigner la classe doryphore. On peut observer que pour ce jeu de données, le modèle présentant le f1-score le plus élevé est le ResNet-18 suréchantillonné (f1-score = 0.78706). Par contre, le modèle ResNet-18 non balancé présente une valeur de f1-score très rapprochée (f1-score = 0.78453), mais offre une meilleure précision (précision = 0.83041) et donc moins de surestimation. Tous les modèles suréchantillonnés v1 présentent des

f1-score supérieurs à 75% ce qui est très encourageant. De plus, il est très intéressant d'observer que les modèles entraînés à partir du jeu de données sous-échantillonnées v1 présentent des résultats de f1-score supérieurs à 71% malgré que ceux-ci ont presque 9 fois moins d'échantillons que la version suréchantillonnée. Ce qui a été observé dans les courbes d'entraînement et de validation se reflète dans les résultats de validation des modèles utilisant les jeux de données sous-échantillonnés et suréchantillonnés v2. Ces modèles présentent nettement de moins bons résultats surtout pour la version sous-échantillonnée. On peut expliquer cela par les modifications apportées aux échantillons d'entraînement par la méthode SMOTE et *k-moyennes* qui ont modifié les tailles des images variables à une taille fixe (24x24x3) comme ces méthodes nécessitent en entrée un vecteur de caractéristiques de même taille pour tous les échantillons. D'autant plus qu'il est mentionné dans la littérature que cette méthode est peu pratique pour des données de haute dimension (Blagus & Lusa, 2013). Les modifications apportées par les méthodes d'augmentation synthétiques ont modifié les images si bien que les modèles entraînés ont du mal à reconnaître les échantillons non synthétiquement modifiés.

Il est mentionné dans la littérature que les modèles suréchantillonnés offrent une meilleure performance que les modèles sous-échantillonnés pour les réseaux de neurones convolutifs et que ceux-ci ne causent pas le surapprentissage (Buda *et al.*, 2018). À la lumière des résultats obtenus, on peut conclure que les jeux de données utilisés n'en font pas exception. Il aurait pu être intéressant de répéter chacune des expériences pour plusieurs itérations afin de déterminer si un modèle est réellement supérieur à un autre ou si la différence entre les modèles est due au hasard.

Les seuils déterminés ont été appliqués sur les échantillons du jeu de données tests qui n'ont jamais été vues par les modèles. On s'attend à ce que les modèles performant moins bien sur les données tests que sur les données de validation puisque le meilleur modèle a été sauvegardé en fonction du résultat obtenu sur ce dernier. Le Tableau 12 présente les résultats des différents modèles pour le jeu de données tests.

Tableau 12: Résultat des différents modèles pour le jeu de données tests

Jeu de données tests non balancé				
Modèle	Seuil p	Précision (%)	Rappel (%)	F1-score (%)
ResNet-18 suréchantillonné v1	0,060	77,04	70,56	73,66
ResNet-18 suréchantillonné v2	0,030	57,14	54,21	55,64
ResNet-18 non balancé 15-1	0,055	81,92	67,76	74,17
ResNet-18 sous-échantillonné v1	0,060	60,19	59,35	59,77
ResNet-18 sous-échantillonné v2	0,050	13,77	23,36	17,33
ResNet-34 suréchantillonné v1	0,045	80,00	61,68	69,66
ResNet-34 suréchantillonné v2	0,035	51,67	64,95	57,56
ResNet-34 non balancé 15-1	0,090	74,52	72,43	73,46
ResNet-34 sous-échantillonné v1	0,070	70,34	68,69	69,50
ResNet-34 sous-échantillonné v2	0,015	12,77	16,36	14,34
ResNet-50 suréchantillonné v1	0,070	82,45	72,43	77,11
ResNet-50 suréchantillonné v2	0,055	69,87	50,94	58,92
ResNet-50 non balancé 15-1	0,090	76,21	73,36	74,76
ResNet-50 sous-échantillonné v1	0,040	71,52	52,80	60,75
ResNet-50 sous-échantillonné v2	0,010	6,32	78,51	11,70

Pour chacune des architectures comparées, le meilleur modèle a été identifié. On peut observer que pour le jeu de données test, le modèle qui offre le meilleur f1-score est le ResNet-50 suréchantillonné v1 (f1-score de 77.11%) avec une précision de 82,45%. Son rappel est comparable au modèle ResNet-34 non balancé tandis que sa précision est comparable à celle du ResNet-18 non balancé. Des ajustements dans la valeur de p peuvent être effectuées afin que le modèle surestime ou sous-estime. Comme une seule version des modèles a été entraînée, il est difficile de confirmer s'il y a un apport significatif d'utiliser le ResNet-50. De plus, le gain de f1-score est négligeable en comparaison à la réduction du temps de traitement offerte par le ResNet-18. Cette comparaison permet de confirmer que la profondeur de l'architecture résiduelle augmente la performance de l'algorithme, mais pas de façon majeure.

Afin de comprendre les erreurs des modèles, il est intéressant d'observer à quoi ressemblent les échantillons pour lesquels il y a eu des faux positifs et des faux négatifs. Quelques exemples de bonnes et mauvaises détections sont présentés pour les modèles

retenus dans les figures ci-dessous (Figure 42 à Figure 44). On observe que les échantillons de vrais positifs semblent être des doryphores peu obstrués par des feuilles et comprenant peu d'ombre ainsi qu'une couleur rouge vif avec un contraste important. On peut remarquer que l'algorithme identifie les adultes et les larves. Les adultes correspondent aux segments qui sont de couleur beige alors que les larves sont les segments de couleur orangée. Les vrais négatifs semblent être des échantillons de non-doryphores ne comprenant pas de caractéristiques (forme, couleur) semblables aux doryphores. Dans la plupart des cas, les faux positifs sont des exemples qui comprennent la couleur et la forme des doryphores, mais qui sont en fait un agencement de feuilles créant une forme ovale et d'où le sol réfléchit la lumière. Les fleurs des pommes de terre peuvent également ressembler à des doryphores. De plus, dans certains cas, il était très difficile d'identifier correctement s'il s'agissait d'un doryphore ou non. Lorsque le doute était trop important, l'échantillon n'a pas été classé comme doryphore et c'est possible que des erreurs d'omission soient survenues lors de cette interprétation. Les faux négatifs semblent être des échantillons où la fenêtre est partiellement dans l'ombre et où le contraste entre le doryphore et son voisinage est faible. La stratégie d'utiliser une taille de fenêtre variable réduit le bruit dans la fenêtre et permet de réduire la variabilité intraclasse des échantillons. Cette dernière demeure importante malgré ce choix méthodologique. Des tests ont été effectués avec différentes tailles de fenêtres fixes et la stratégie de fenêtre adaptative à la taille du segment est celle qui a présenté les meilleurs résultats. On peut également observer que certaines erreurs ou bonnes prédictions sont communes aux différents modèles.

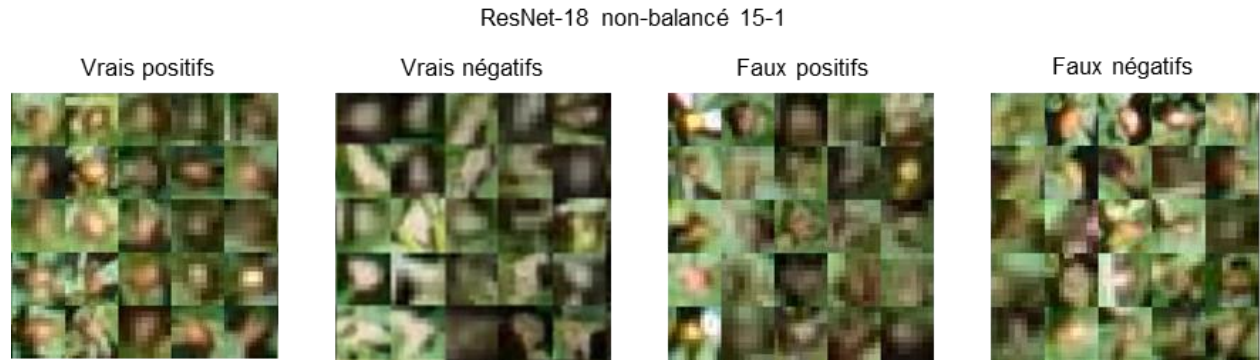


Figure 42: Exemples de vrais positifs, vrai négatifs, faux positifs et faux négatifs pour le modèle ResNet-18 non balancé 15-1.

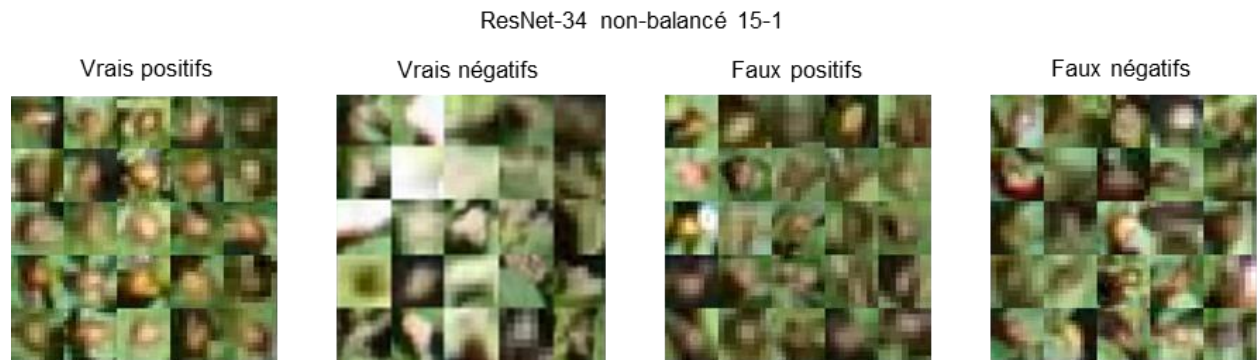


Figure 43: Exemples de vrais positifs, vrai négatifs, faux positifs et faux négatifs pour le modèle ResNet-34 non balancé 15-1.



Figure 44: Exemples de vrais positifs, vrai négatifs, faux positifs et faux négatifs pour le modèle ResNet-50 suréchantillonné v1.

Afin d'évaluer les deux parties de l'algorithme de façon simultanée, les omissions de la détection préliminaire ont été ajoutées aux matrices de confusion des différentes images des bases de données tests et validation (Annexe 3). Le graphique de la page suivante (Figure 45) détaille les valeurs de précision, de rappel et de f1-score par images acquises par drone pour le jeu de données de test pour tous les modèles à l'exception de ceux entraînés avec le sous-échantillonnage v2. Les images acquises lors du 19 juillet 2018 sont identifiées en bleu alors que les images du 30 juillet 2018 sont identifiées en mauve afin de qualifier s'il y a une différence de performance entre les différents paramètres et conditions d'acquisition. Le score total pour toutes les images combinées est identifié en rouge. On observe que les six meilleurs modèles ont une meilleure précision pour les images acquises lors de la première sortie ainsi qu'un meilleur f1-score. Pour le jeu de données tests, l'algorithme de détection préliminaire sous-estime moins d'environ 13%, ce qui explique en partie la meilleure précision. De plus, comme les images de la deuxième sortie sont davantage limitées par la diffraction, les pixels associés à la présence d'un doryphore peuvent être de couleurs moins vives et le contraste peut être moins important, ce qui rend la tâche de classification plus difficile.

Les modèles qui semblent les moins variables et avec la meilleure performance d'une image à l'autre sont le ResNet-50 suréchantillonné v1 ainsi que le ResNet-18 suréchantillonné v1. Par contre, le ResNet-50 suréchantillonné v1 présente la plus haute et la moins variable précision. On peut remarquer aussi que les modèles ResNet-50 et ResNet-18 non balancés v1 atteignent un maximum de f1-score plus élevé pour différentes images. Il est difficile de comprendre pourquoi le modèle ResNet-18 performe mieux que le ResNet-34. On s'attendrait à ce que la performance de ResNet-34 soit intermédiaire entre le ResNet-18 et le ResNet-50. C'est possiblement dû au hasard et plusieurs itérations d'entraînement auraient permis de mieux confirmer la performance du meilleur modèle.

La tâche de classification n'est pas simple en soi puisque les attributs permettant de représenter le doryphore sont peu nombreux (forme, couleur, ligne d'ombrage) et sont variables. En plus que la classe non doryphore est beaucoup plus représentée, il y a beaucoup plus d'attributs pouvant être appris par l'algorithme pour cette classe.




Figure 45: Boîtes à moustaches présentant les résultats de précision, rappel et f1-score des différents modèles entraînés pour les images de la base de données test séparées selon les acquisitions du 19 juillet 2018 (sortie 1 en bleu) et du 30 juillet 2018 (sortie 2 en mauve) ainsi que pour l'ensemble des images du jeu de données test (total en rouge).

4.3 Cartes de dépistage

La validation à l'échelle des foyers d'infestation a été effectuée pour l'ensemble des images de drones (13 images) utilisées dans les bases de données de validation et de test. La prédiction utilisée dans le cadre de cette validation correspond aux zones de la grille pour lesquelles quatre détections de doryphores ou plus ont été estimées. La Figure 46 présente un exemple de cartes de dépistage produites. Les carrés bleus correspondent à des bonnes prédictions (vrais positifs), les carrés rouges correspondent à des erreurs de commission (faux positifs) et les carrés jaunes correspondent à des omissions (faux négatifs). Les tuiles vertes sont des zones avec 0-1 détection (risque faible), les tuiles jaunes sont des zones avec 1 à 4 détections (risque modéré) et les tuiles rouges sont des zones avec 5 détections ou plus (risque élevé).

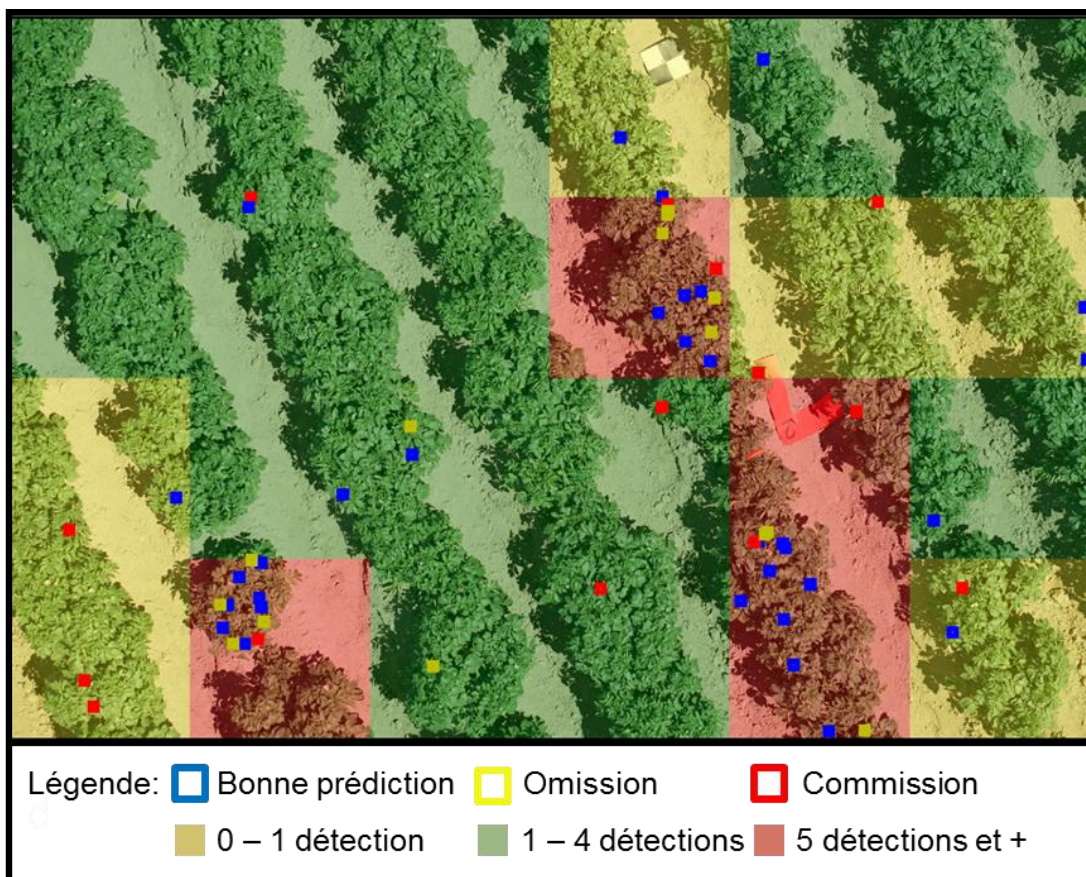


Figure 46: Exemple de carte de dépistage pour l'image 4981 du 19 juillet 2018 produite avec le modèle ResNet-50 suréchantillonné v1.

Le Tableau 13 présente en détail les bonnes prédictions pour les deux classes ainsi que les erreurs d'omission et de commission à l'échelle des foyers d'infestation pour chacune des images validées et pour chacun des modèles. Le Tableau 14 présente la performance des modèles pour l'ensemble des foyers d'infestations.

Tableau 13: Tableau détaillant les vrais positifs (VP), vrais négatifs (VN), faux positifs (FP) et faux négatifs (FN) pour chacune des images utilisées dans le jeu de validation des foyers d'infestation.

	ResNet-18 non balancé 15-1				ResNet-34 non balancé 15-1				ResNet-50 suréchantillonné v1			
IMAGE #	VP	VN	FP	FN	VP	VN	FP	FN	VP	VN	FP	FN
4967	1	23	0	0	1	23	0	0	1	23	0	0
4974	1	23	0	0	1	23	0	0	1	23	0	0
4979	2	22	0	1	2	21	1	1	2	22	0	1
4981	4	20	0	0	4	20	0	0	4	20	0	0
4988	4	20	0	1	3	21	0	2	4	20	0	1
4992	1	23	0	0	1	23	0	0	1	23	0	0
7814	1	23	0	0	1	22	1	0	1	22	1	0
7911	6	18	0	1	6	18	0	1	7	17	0	0
7916	1	23	0	0	1	22	1	0	1	23	0	0
7920	1	21	2	1	2	21	1	0	2	22	0	0
7924	0	15	9	0	0	15	9	0	0	23	1	0
7930	3	21	0	0	3	20	1	0	3	21	0	0
7978	1	23	0	0	1	21	2	0	1	19	4	0
TOTAL	26	275	11	4	26	270	16	4	28	278	6	2

Tableau 14: Performance des trois meilleurs modèles pour le jeu de validation des foyers d'infestation.

Modèle	VP	VN	FP	FN	Précision (%)	Rappel (%)	F1-score (%)	Précision globale
ResNet-18 non balancé 15-1	26	275	11	4	70.27	86.67	77.61	95.25
ResNet-34 non balancé 15-1	26	270	16	4	61.91	86.67	72.22	93.67
ResNet-50 sur échantillon v1	28	278	6	2	82.35	93.33	87.50	97.45

Le modèle ResNet-50 suréchantillonné v1 est celui qui performe le mieux également à l'échelle des foyers d'infestation. On remarque que contrairement à la classification à l'échelle du doryphore, le rappel est beaucoup plus élevé. Cela prouve que l'agrégation naturelle des larves de doryphores est un élément permettant de faciliter la reconnaissance des foyers. Par contre, pour la seule image (# 7924) où il n'y a aucune

agrégation et seulement 7 individus pour toute l'image, on constate que cette image contribue pour la majeure partie des faux positifs. Il est intéressant de voir que les deux modèles ayant 512 activations en sortie (ResNet-18 et ResNet-34) ont une performance similaire alors que le modèle ResNet-50, avec 2048 activations en sortie, performe beaucoup mieux sur l'image # 7924 et moins bien pour l'image # 7978. Il pourrait être intéressant de construire un jeu de données plus grand à l'échelle des foyers d'infestation en utilisant des images qui n'ont pas été exploitées ou de nouvelles acquisitions.

On peut observer que cette étape permet de bien détecter les foyers d'infestations puisque ceux-ci sont très agrégés spatialement. Malgré les omissions causées dans les deux phases de l'algorithme, les foyers d'infestations comprenant un nombre de larves élevé sont peu omis par l'utilisation de cartes de dépistage agrégées.

4.4 Temps de traitement

Le temps de traitement requis pour effectuer la tâche de classification est en proportionnel au nombre de classifications à effectuer, mais diminue exponentiellement avec la performance du processeur graphique utilisé. À titre de comparaison, le temps requis pour classifier les images du jeu de données tests a été comparé pour deux machines :

- Machine virtuelle « Windows Deep Learning AMI » de Amazon Web Services (AWS), instance EC2 - p2.xlarge :
 - Processeur : 4 vCPU 2.7 GHz;
 - Mémoire RAM de 61 Go;
 - Carte graphique Tesla K80 de 12 Go;
 - Disque dur SSD.
- Ordinateur portable :
 - Processeur : i5-3320M CPU @ 2.60GHz
 - Mémoire RAM de 8 Go;
 - Processeur graphique NVIDIA NVS 5200M de 1Go;
 - Disque dur SSD.

Chacune des architectures a été comparée au niveau du temps de traitement requis pour les deux étapes de classification (Tableau 15). On observe que l'architecture ResNet-50 nécessite environ 10 secondes de plus par image pour la machine virtuelle AWS, ce qui est environ 50% plus long que l'architecture ResNet-18. La détection préliminaire utilise des bibliothèques Python qui ne profitent pas des processeurs graphiques des ordinateurs ce qui explique pourquoi cette étape est coûteuse en termes de temps de calcul. Malgré, les 61 Go de mémoire vive de la machine AWS, celle-ci ne parvient pas à obtenir une moyenne de temps pour la détection préliminaire inférieure à 20 secondes/image. Il serait possible de paralléliser sur de multiples processeurs les opérations de la détection préliminaire ce qui permettrait de réduire le temps de calcul. De plus, le script de détection préliminaire pourrait être optimisé afin de réduire le temps de calcul. Il serait également possible d'utiliser une carte graphique plus performante ce qui réduirait le temps de calcul au niveau de la détection par RNCP.

Pour un vol de drone de 12 minutes couvrant environ 1 hectare, on estime environ 720 images à traiter ce qui prendrait environ 6 heures pour une architecture ResNet-18, 7.3 heures pour ResNet-34 et 8 heures pour ResNet-50 avec la machine virtuelle sélectionnée.

Tableau 15: Comparaison du temps de traitement pour une machine virtuelle AWS et un ordinateur portable munie d'un processeur graphique pour les différentes architectures.

Architecture	Machine	Nb de zones potentielles	temps détection préliminaire (sec)	temps détection par RNCP (sec)	temps détection préliminaire /image	temps détection par RCNP /image
ResNet-18	AWS	7122	141,11	66,60	20,16	9,51
ResNet-34	AWS	7122	144,74	111,93	20,68	15,99
ResNet-50	AWS	7122	145,35	139,83	20,76	19,97
ResNet-18	Portable	7122	166,45	152,77	23,78	21,82
ResNet-34	Portable	7122	186,09	279,48	26,58	39,93
ResNet-50	Portable	7122	171,20	383,36	24,46	54,77

4.5 Comparaison entre le dépistage par drone et le dépistage conventionnel

Afin de comparer le dépistage conventionnel à la méthode proposée, les zones dépistées manuellement ont été extraites des images et les trois meilleurs modèles de chaque architecture ont été utilisés pour identifier les doryphores. Les tableaux ci-dessous (Tableau 16 à Tableau 18) exposent les résultats pour les parcelles de dépistage. La performance des modèles à l'échelle des parcelles de dépistage est similaire à ce qui a été observé globalement pour le jeu de données tests. Le coefficient de détermination des vrais positifs par rapport aux individus visibles au sommet de la canopée est supérieur à 60% pour les trois modèles. On peut expliquer les différences entre les deux méthodes par les erreurs qui peuvent avoir été causées lors du dépistage manuel et les erreurs intrinsèques à l'algorithme de détection. Globalement, on peut affirmer que la méthode de dépistage par drone est une bonne estimation du dépistage manuel.

Tableau 16: Résultat de comparaison entre le dépistage conventionnel et le dépistage par drone pour le modèle ResNet-18 non balancé 15-1.

VP : vrais positifs, FP : faux positifs et FN : Faux négatifs.

Parcelle #	Sortie	# Image	N Doryphores dépistés (visibles)			n détections (VP+FP)		n doryphores (VP+FN)		Précision (%)	Rappel (%)	F1-score (%)
			VP	FP	FN							
1	1	4988	20	14	2	9	16	23	87.50	60.87	71.79	
2	1	4981	13	6	4	7	10	13	60.00	46.15	52.17	
3	1	4979	33	21	3	7	24	28	87.50	75.00	80.77	
4	1	4967	34	18	5	12	23	30	78.26	60.00	67.92	
1	2	7978	38	1	4	2	5	3	20.00	33.33	25.00	
2	2	7911	76	36	6	8	42	44	85.71	81.82	83.72	
4	2	7916	35	14	4	4	18	18	77.78	77.78	77.78	
6	2	7920	12	7	5	0	12	7	58.33	100.00	73.68	
7	2	7924	2	3	3	0	6	3	50.00	100.00	66.67	
TOTAL:			263	120	36	49	156	169	7692	7101	73.85	
R ² détection/dépistage			0,6827									
R ² vrais positifs/dépistage			0,6466									

Tableau 17: Résultat de comparaison entre le dépistage conventionnel et le dépistage par drone pour le modèle ResNet-34 non balancé 15-1.

VP : vrais positifs, FP : faux positifs et FN : Faux négatifs.

Parcelle #	Sortie	# Image	N Doryphores dépistés (visibles)			n détections (VP+FP)		n doryphores (VP+FN)		Précision (%)	Rappel (%)	F1-score (%)
			VP	FP	FN							
1	1	4988	20	16	2	7	18	23	88.89	69.57	78.05	
2	1	4981	13	9	4	4	13	13	69.23	69.23	69.23	
3	1	4979	33	24	5	4	29	28	82.76	85.71	84.21	
4	1	4967	34	22	7	8	29	30	75.86	73.33	74.58	
1	2	7978	38	2	4	1	6	3	33.33	66.67	44.44	
2	2	7911	76	37	5	7	42	44	88.10	84.09	86.05	
4	2	7916	35	15	3	3	18	18	83.33	83.33	83.33	
6	2	7920	12	7	5	0	12	7	58.33	100.00	73.68	
7	2	7924	2	3	2	0	5	3	60.00	100.00	75.00	
TOTAL:			263	135	37	34	172	169	0,7849	0,7988	78,49	
R ² détection/dépistage			0,6193									
R ² vrais positifs/dépistage			0,6159									

Tableau 18: Résultat de comparaison entre le dépistage manuel et le dépistage par drone pour le modèle ResNet-50 suréchantillonné v1.

VP : vrais positifs, FP : faux positifs et FN : Faux négatifs.

Parcelle #	Sortie	# Image	N Doryphores dépistés (visibles)	N			n détections (VP+FP)	n doryphores (VP+FN)	Précision	Rappel	F1- score
				VP	FP	FN					
1	1	4988	20	16	2	7	18	23	88.89	69.57	78.05
2	1	4981	13	8	4	5	12	13	66.67	61.54	64.00
3	1	4979	33	24	4	4	28	28	85.71	85.71	85.71
4	1	4967	34	21	6	9	27	30	77.78	70.00	73.68
1	2	7978	38	2	6	1	8	3	25.00	66.67	36.36
2	2	7911	76	39	5	6	44	45	88.64	86.67	87.64
4	2	7916	35	14	3	3	17	17	82.35	82.35	82.35
6	2	7920	12	7	3	0	10	7	70.00	100.00	82.35
7	2	7924	2	3	3	0	6	3	50.00	100.00	66.67
TOTAL:			263	134	36	35	170	169	78.82	79.29	79.06
R² détection/dépistage			0,7007								
R² vrais positifs/dépistage			0,6402								

4.6 Protocole d'acquisition des images ultra-haute résolution

Selon les résultats de validation, les paramètres d'acquisition des images utilisés lors de la campagne de terrain du 19 juillet ont démontré être optimaux. Afin d'effectuer de futures acquisitions d'images, les paramètres de la caméra (*Sony a6000*) et de vol de drone qui devront être utilisés sont les suivants :

- Drone :
 - Altitude de vol : 15 m
 - Résolution spatiale : 1.17 mm/pixel
 - Vitesse de vol : 3 m/sec
 - Recouvrement latéral : inférieur à 10%
- Appareil photographique :
 - Vitesse d'obturation : 1/4000 sec
 - Ouverture du diaphragme : F3.5
 - Sensibilité ISO : Maximum 250
 - Fréquence d'acquisition des images : 1 image/sec

La vitesse d'obturation a été fixée à 1/4000 sec afin de permettre d'acquérir les images avec un déplacement de la plateforme jusqu'à 4 m/sec. Par contre, afin de tenir compte des incertitudes de déplacement du drone, une vitesse de 3 m/sec a été choisie. Comme ce paramètre est fixe et pour une même exposition, le seul paramètre pouvant être ajusté afin de minimiser le bruit au capteur est l'ouverture du diaphragme. L'ouverture du diaphragme a été choisie de façon à ce que l'ISO demeure faible tout en offrant une profondeur de champ permettant de compenser pour les variations d'altitude de la plateforme. De plus, en minimisant l'ouverture du diaphragme l'image est moins limitée par la diffraction ce qui permet de maximiser le contraste entre les DPT et le feuillage. La Figure 47 démontre la différence entre une image acquise avec une ouverture F2.8 et une ouverture F3.5 pour un même foyer d'infestation.



1/4000s F2.8 ISO 160

1/4000s F3.5 ISO 250

Figure 47: Foyer d'infestation photographié avec une ouverture du diaphragme F2.8 (gauche) et F3.5 (droite) pour une même vitesse d'obturation (1/4000 sec)

Il est certain que le choix des paramètres dépend des conditions d'acquisition des images et qu'il est nécessaire que l'éclairage soit maximal pour que l'acquisition des images soit réussie. Il pourrait être intéressant de tester avec un appareil photographique qui offre une meilleure performance en situation à faible lumière (ex. *Sony a7RII*). La sensibilité ISO de ce type d'appareil crée moins de bruit au capteur. De plus, ce type d'appareil utilise un capteur de type plein format ce qui signifie que pour la même résolution la couverture est plus importante. De plus, cet appareil peut descendre à une vitesse d'obturation jusqu'à 1/8000 sec ce qui permettrait d'augmenter la vitesse de vol. Les paramètres d'acquisitions d'images devraient être testés avec ce type d'appareil afin de s'assurer que la qualité des images soit bonne.

Il peut être difficile dans un cadre opérationnel de parcourir l'ensemble d'un champ au complet à cette altitude de vol. Les zones à privilégier sont les bordures du champ comme c'est généralement les zones infestées en premier pour les cultures de rotation. On pourrait suggérer un plan de vol comprenant 2 lignes de vol pour les bordures du champ afin de couvrir environ 14 m de bordure puis ensuite effectuer un tracé en zigzag à l'intérieur du champ. La Figure 48 présente un exemple de plan de vol qui pourrait être utilisé pour un champ d'une superficie d'environ 12 hectares. Le temps de vol nécessaire est d'environ 24 minutes ce qui correspondrait à 2 vols de drone. Ce type de plan de vol

ne couvre pas l'entièreté du champ, mais donne une idée globale de l'infestation et reproduit le type de parcours utilisé dans le dépistage conventionnel, en seulement 24 minutes. Environ 16 heures de traitement informatique seraient nécessaires pour dépister la zone parcourue, ce qui permettrait de produire des cartes de dépistage dans la même semaine.




Figure 48: Exemple de plan de vol priorisant les bordures et parcourant en zigzag l'intérieur de la parcelle agricole qui pourrait être utilisé dans un contexte opérationnel.

5 CONCLUSIONS

L'objectif du présent projet consistait à développer une méthode de dépistage utilisant l'imagerie ultra-haute résolution acquise par drone et l'apprentissage profond afin de détecter les foyers d'infestations de doryphore et de dénombrer ceux-ci de manière rapide et efficace dans le but d'améliorer les méthodes de dépistage actuelles.

Le premier objectif spécifique du projet était de développer un protocole d'acquisition des images avec un drone en déplacement et de déterminer les paramètres optimaux de vol et d'acquisition des images. Différents paramètres d'acquisition ont été testés et les paramètres optimaux ont été identifiés permettant d'acquérir des images nettes avec un drone pouvant se déplacer à une vitesse allant jusqu'à 3 m/sec. L'acquisition des images avec la caméra *Sony a6000* nécessite toutefois des conditions d'éclairage optimales soit une journée peu nuageuse et vers l'heure du midi.

Le deuxième objectif spécifique était de développer un algorithme automatisé de reconnaissance des doryphores en utilisant l'apprentissage profond. La méthode de détection développée est hybride entre une méthode de détection par caractéristiques définies par un expert (détection préliminaire) et une classification utilisant les réseaux de neurones convolutifs. Différentes stratégies d'entraînement ont été comparées pour différentes profondeurs d'architectures. Les deux stratégies offrant les meilleures performances sont le suréchantillonnage par augmentation de données et l'apprentissage sensible au coût. Les méthodes d'échantillonnage par augmentation de données se sont avérées nettement supérieures aux méthodes synthétiques. Le modèle offrant la meilleure performance est le ResNet-50 suréchantillonné par augmentation de données. Ce modèle a permis de détecter les doryphores, pour le jeu de données tests, avec un taux de succès moyen de 77 %. Comme les larves de doryphores sont localisées spatialement en foyers d'infestation, l'utilisation de cartes de dépistage donnant le nombre d'individus par grilles de 1 m² vient compenser les erreurs de l'algorithme de détection. Les cartes de dépistage ont permis ainsi de détecter les foyers d'infestation avec un taux de succès moyen de 87% avec le meilleur modèle. Une comparaison entre le dépistage manuel et le dépistage par drone a été effectuée. Les meilleurs modèles de chacune des architectures ont démontré des coefficients de détermination supérieurs à

60 % entre le dépistage conventionnel (grosses larves et adultes au sommet de la canopée) et le dépistage automatisé par drone.

Le troisième objectif spécifique était d'optimiser la méthode pour que le temps de calcul soit assez court afin que celle-ci puisse être utilisée opérationnellement. L'étape de la détection préliminaire est l'étape la plus exigeante en temps de traitement. Pour cette étape, l'implémentation d'un filtre médian par désagrégation de l'image a permis de réduire le temps de calcul du filtre médian. De plus, seulement l'espace colorimétrique HSV a été utilisé pour détecter les zones potentielles, ce qui réduit la complexité de calcul en comparaison d'utiliser plusieurs espaces colorimétriques différents. De plus, le seuillage de l'histogramme utilisé est une méthode de segmentation très rapide et simple. Sachant que le temps d'inférence augmente avec la profondeur du RNCP, différentes profondeurs de réseaux ont été testées afin de tester l'apport de l'augmentation de la profondeur sur la performance. Les résultats démontrent que l'utilisation de l'architecture ResNet-18 apporte une performance suffisante tout en diminuant le temps de calcul. Le temps requis pour traiter les images acquises pour une superficie d'un hectare est inférieur à 8 heures en utilisant un processeur graphique Tesla K80.

Dans un contexte opérationnel et étant donné que la plupart des parcelles sont cultivées en régie incluant une rotation de culture (alternant pomme de terre et céréales), l'infestation des champs débute par les bordures. Par conséquent, le dépistage se concentre sur la lisière des champs agricoles. Par exemple, un champ de 10 ha de taille de 200 m x 500 m nécessiterait seulement 2 vols de drone d'environ 8 min pour couvrir 14 m de largeur de bordure. Le temps de traitement nécessaire pour les images acquises pour ce champ serait d'environ 16 heures et les coûts de traitement d'environ 22\$. Si l'on compare cela au dépistage conventionnel, un dépisteuse nécessiterait environ 1 heure pour parcourir la même superficie. De plus, la qualité d'information recueillie par le dépistage manuel permet difficilement de produire des cartes aussi riches en information produite par l'approche proposée (localisation des foyers d'infestation avec précision, densité d'infestation, format numérique facilement intégrable avec la machinerie de lutte phytosanitaire, etc.). Par ailleurs, le positionnement géographique du système présente une incertitude de l'ordre de 2 à 3 m. Cependant, cette précision est acceptable étant

donné que l'échelle des interventions phytosanitaires par les rampes d'applications à taux variable est de l'ordre de 10 m.

L'algorithme développé dans le cadre de ce projet permet d'identifier principalement les adultes et les grosses larves de doryphore, mais ne permet pas d'effectuer la distinction entre les deux catégories. Comme les seuils d'intervention phytosanitaire nécessitent de distinguer les différents stades de vies du doryphore, il serait intéressant que les futurs développements permettent cette distinction. De plus, comme toute approche orientée donnée, il demeure possible dans un contexte opérationnel de réentraîner l'algorithme avec de nouvelles acquisitions et d'en améliorer ainsi la performance. Par ailleurs, il est recommandé d'effectuer davantage de travaux afin d'améliorer la performance de la méthode. Par exemple, il serait possible : d'utiliser d'autres architectures préentraînées, d'utiliser d'autres stratégies d'entraînement (p. ex. suréchantillonnage plus important et combinaison du suréchantillonnage avec l'apprentissage sensible au coût), différents hyperparamètres (p. ex. autre classificateur, plus grand nombre d'époques et autre fonction d'optimisation). Il serait également possible d'utiliser le « boot-strapping » des faux positifs et faux négatifs qui consiste à entraîner plusieurs fois un même modèle en mettant l'accent sur les échantillons erronés.

Afin de qualifier l'apport d'une telle méthode de dépistage, une étude technico-économique (coût/bénéfice) est prévue pour l'été 2020. Cette étude comparera une régie phytosanitaire conventionnelle à une régie utilisant le dépistage par drone et les applications d'insecticides à taux variable. Les rendements des différentes régies seront comparés ainsi que les coûts d'intrants nécessaires (main d'œuvre, produits phytosanitaires, carburant, etc.) afin de quantifier l'apport économique. Une étude de marché sera également effectuée auprès des producteurs de pommes de terre afin d'évaluer, à l'échelle régionale, le besoin et les apports de la méthode de dépistage automatisée par drone.

Lorsqu'adoptée, la méthode proposée devrait permettre aux producteurs de pommes de terre de mieux cibler les interventions phytosanitaires. L'adoption de cette pratique de gestion intégrée des ennemis des cultures aura certainement des retombées économiques pour les entreprises agricoles tout en ayant un impact positif sur l'environnement

6 RÉFÉRENCES

- AAC (2017) Revue d'information sur les marchés de la pomme de terre 2015-2016. Édit Sectoriels SDaEDRSLM-DDLHEDEP (Gouvernement du Canada, Canada).
- Alyokhin A (2009) Colorado Potato Beetle Management on Potatoes: Current Challenges and Future Prospects. *Fruit, Vegetable and Cereal Science and Biotechnology*.
- Alyokhin A, Udalov M & Benkovskaya G (2013) The Colorado Potato Beetle. *Insect Pests of Potato*, 10.1016/b978-0-12-386895-4.00002-8. p 11-29.
- Apan A, Held A, Phinn S & Markley J (2004) Detecting sugarcane 'orange rust' disease using EO-1 Hyperion hyperspectral imagery. *International Journal of Remote Sensing* 25(2):489-498.
- Araus JL & Cairns JE (2014) Field high-throughput phenotyping: the new crop breeding frontier. *Trends in plant science* 19(1):52-61.
- Asmare MH, Asirvadam VS & Iznita L (2009) Color Space Selection for Color Image Enhancement Applications. in *2009 International Conference on Signal Acquisition and Processing*, p 208-212.
- Babankumar B, Rangoli S, Ritula T & Gaurav S (2017) A comparison between satellite based and drone based remote sensing technology to achieve sustainable development: a review. *Journal of Agriculture and Environment for International Development (JAEID)* 111(2).
- Backoulou GF, Elliott NC, Giles KL & Mirik M (2015) Processed multispectral imagery differentiates wheat crop stress caused by greenbug from other causes. *Computers and Electronics in Agriculture* 115:34-39.
- Barbedo JGA (2014) Using digital image processing for counting whiteflies on soybean leaves. *Journal of Asia-Pacific Entomology* 17(4):685-694.
- Bendig J, Yu K, Aasen H, Bolten A, Bennertz S, Broscheit J, Gnyp ML & Bareth G (2015) Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation* 39:79-87.
- Berni J, Zarco-Tejada PJ, Suarez L & Fereres E (2009) Thermal and Narrowband Multispectral Remote Sensing for Vegetation Monitoring From an Unmanned Aerial Vehicle. *IEEE Transactions on Geoscience and Remote Sensing* 47(3):722-738.
- Bhattacharya BK & Chattopadhyay C (2013) A multi-stage tracking for mustard rot disease combining surface meteorology and satellite remote sensing. *Computers and Electronics in Agriculture* 90:35-44.
- Blagus R & Lusa L (2013) SMOTE for high-dimensional class-imbalanced data. *BMC Bioinformatics* 14(1):106.
- Blaschke T (2010) Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 65(1):2-16.

- Bloice MD, Roth PM & Holzinger A (2019) Biomedical image augmentation using Augmentor. *Bioinformatics* 10.1093/bioinformatics/btz259.
- Boiteau G, Alyokhin A & Ferro DN (2003) The Colorado potato beetle in movement. *The Canadian Entomologist* 135(1):1-22.
- Boiteau G, Pelletier Y, Misener GC & Bernard G (1994) Development and Evaluation of a Plastic Trench Barrier for Protection of Potato from Walking Adult Colorado Potato Beetles (Coleoptera: Chrysomelidae). *Journal of Economic Entomology* 87(5):1325-1331.
- Bongiovanni RL-D, J. (2004) Precision Agriculture and Sustainability. *Precision Agriculture* 5(4):359-387.
- Bora DJ, Gupta AK & Khan FA (2015) Comparing the Performance of L*A*B* and HSV Color Spaces with Respect to Color Image Segmentation. *International Journal of Emerging Technology and Advanced Engineering* 5(2):192-203.
- Bouchard S (1992) *Plantation des pommes de terre.*, <https://www.agrireseau.net/pdt/documents/plantationpdt%20%20.pdf>
- Bouroubi, Bugnet, Nguyen-Xuan, Gosselin, Bélec, Longchamps & Vigneault (2018) Pest Detection on UAV Imagery using a Deep Convolutional Neural Network. *International conference on precision agriculture*. (Montréal, Québec, Canada, Agriculture TISOP (Édit.).
- Brown M (2004) *Advanced Digital Photography*. Media Publishing Pty, Limited. https://books.google.ca/books?id=nTWr_Lvkzu8C
- Buda M, Maki A & Mazurowski MA (2018) A systematic study of the class imbalance problem in convolutional neural networks. *Neural Networks* 106:249-259.
- Burnett C & Blaschke T (2003) A multi-scale segmentation/object relationship modelling methodology for landscape analysis. *Ecological Modelling* 168(3):233-249.
- Canada T (2019a) *Utiliser votre drone de façon sécuritaire et légale (avant le 1er juin 2019)*. <https://www.tc.gc.ca/fr/services/aviation/securite-drones/utiliser-drone-facon-securitaire-legale-regles-actuelles.html>
- Canada T (2019b) *Utiliser votre drone de façon sécuritaire et légale (après le 1er juin 2019)*. <https://www.tc.gc.ca/fr/services/aviation/securite-drones.html>
- Candiago S, Remondino F, De Giglio M, Dubbini M & Gattelli M (2015) Evaluating Multispectral Images and Vegetation Indices for Precision Farming Applications from UAV Images. *Remote Sensing* 7(4).
- Chawla NV, Bowyer KW, Hall LO & Kegelmeyer WP (2002) SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research* 16:321-357.
- Cheng HD, Jiang XH, Sun Y & Wang J (2001) Color image segmentation: advances and prospects. *Pattern Recognition* 34(12):2259-2281.
- Córcoles JI, Ortega JF, Hernández D & Moreno MA (2013) Estimation of leaf area index in onion (*Allium cepa* L.) using an unmanned aerial vehicle. *Biosystems Engineering* 115(1):31-42.

- CRAAQ (2015) Réflexion sur l'état d'adoption des technologies d'agriculture de précision au Québec. (Centre de référence en agriculture et agroalimentaire du Québec, Québec).
- DeChant C, Wiesner-Hanks T, Chen S, Stewart EL, Yosinski J, Gore MA, Nelson RJ & Lipson H (2017) Automated Identification of Northern Leaf Blight-Infected Maize Plants from Field Imagery Using Deep Learning. *Phytopathology* 107(11):1426-1432.
- Desaulniers J (1996) *Utilisation du «boum» d'éclosion des masses d'oeufs pour déterminer le moment optimal de la première application d'insecticides contre les jeunes larves du doryphore de la pomme de terre Leptinotarsa decemlineata Say (Coleoptera: Chrysomelidae)*. (Université du Québec à Trois-Rivière). 90 p
- Ding W & Taylor G (2016) Automatic moth detection from trap images for pest management. *Computers and Electronics in Agriculture* 123:17-28.
- Dripps JE & Smilowitz Z (1989) Growth Analysis of Potato Plants Damaged by Colorado Potato Beetle (Coleoptera: Chrysomelidae) at Different Plant Growth Stages. *Environmental Entomology* 18(5):854-867.
- Effigis (2017) *Acquisition et traitement d'images satellite*. <http://www.effigis.com/wp-content/uploads/2017/06/Fiche-IMAGES-SATELLITE-la-terre-sous-tous-ses-angles-juin-2017.pdf>
- Estrada J, Sánchez H, Hernanz L, Checa JM & Roman D (2017) Enabling the Use of Sentinel-2 and LiDAR Data for Common Agriculture Policy Funds Assignment. *ISPRS International Journal of Geo-Information* 6(8).
- FAO (2019) *AGP - Integrated Pest Management*. <http://www.fao.org/agriculture/crops/core-themes/theme/pests/ipm>
- Federici BA (1999) *Bacillus thuringiensis* in Biological Control. 10.1016/B978-012257305-7/50068-0. p 575-593.
- Ferro DN, Alyokhin AV & Tobin DB (1999) Reproductive status and flight activity of the overwintered Colorado potato beetle. *Entomologia Experimentalis et Applicata* 91(3):443-448.
- Ferro DN, Logan JA, Voss RH & Elkinton JS (1985) Colorado Potato Beetle (Coleoptera: Chrysomelidae) Temperature-dependent Growth and Feeding Rates. *Environmental Entomology* 14(3):343-348.
- Fitzgerald GJ, Maas SJ & Detar WR (2004) Spider Mite Detection and Canopy Component Mapping in Cotton Using Hyperspectral Imagery and Spectral Mixture Analysis. *Precision Agriculture* 5(3):275-289.
- Fuentes A, Yoon S, Kim CS & Park SD (2017) A Robust Deep-Learning-Based Detector for Real-Time Tomato Plant Diseases and Pests Recognition. *Sensors* 17(9).
- Gago J, Douthe C, Coopman RE, Gallego PP, Ribas-Carbo M, Flexas J, Escalona J & Medrano H (2015) UAVs challenge to assess water stress for sustainable agriculture. *Agricultural Water Management* 153:9-19.

- Gandhi R, Nimbalkar S, Yelamanchili N & Ponkshe S (2018) Plant disease detection using CNNs and GANs as an augmentative approach. *2018 IEEE International Conference on Innovative Research and Development (ICIRD)*. 11-12 May 2018), p 1-5.
- Gavelle E (2015) *Surveillance phytosanitaire des cultures de pommes par aéronefs sans pilote*. Mémoire de maîtrise (Université de Sherbrooke). 82 p
- Glorot X, Bordes A & Bengio Y (2011) Deep Sparse Rectifier Neural Networks. (PMLR), p 315-323.
- Goodfellow I, Bengio Y & Courville A (2016) *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>
- Grafius E (1997) Economic Impact of Insecticide Resistance in the Colorado Potato Beetle (Coleoptera: Chrysomelidae) on the Michigan Potato Industry. *Journal of Economic Entomology* 90(5):1144-1151.
- Guyon I (1997) *A Scaling Law for the Validation-Set Training-Set Size Ratio*.
- Ha JG, Moon H, Kwak JT, Hassan SI, Dang M, Lee ON & Park HY (2017) *Deep convolutional neural network for classifying Fusarium wilt of radish from unmanned aerial vehicles*. SPIE. 1-14, 14 p. <https://doi.org/10.1117/1.JRS.11.042621>
- Harcourt DG (1971) POPULATION DYNAMICS OF LEPTINOTARSA DECEMLINEATA (SAY) IN EASTERN ONTARIO: III. MAJOR POPULATION PROCESSES. *The Canadian Entomologist* 103(7):1049-1061.
- Hare JD (1990) Ecology and Management of the Colorado Potato Beetle. *Annual Review of Entomology* 35(1):81-100.
- He K, Zhang X, Ren S & Sun J (2015) *Deep Residual Learning for Image Recognition*. <https://arxiv.org/abs/1512.03385>
- He K, Zhang X, Ren S & Sun J (2016) Identity Mappings in Deep Residual Networks. .
- Hecht E (2002) *Optics*. Addison-Wesley. <https://books.google.ca/books?id=7aG6QgAACAAJ>
- Hornik K, Stinchcombe M & White H (1989) Multilayer feedforward networks are universal approximators. *Neural Networks* 2(5):359-366.
- Hunt ER & Rondon SI (2017) Detection of potato beetle damage using remote sensing from small unmanned aircraft systems. *Journal of Applied Remote Sensing* 11(2).
- Hurst GW (1975) *Meteorology and the Colorado potato beetle*. Secretariat of the World Meteorological Organization, Geneva. 51 p
- Huseth AS, Groves RL, Chapman SA, Alyokhin A, Kuhar TP, Macrae IV, Szendrei Z & Nault BA (2014) Managing Colorado Potato Beetle Insecticide Resistance: New Tools and Strategies for the Next Decade of Pest Control in Potato. *Journal of Integrated Pest Management* 5(4):A1-A8.
- ISQ (2019) *Faits saillants de l'Enquête sur la pomme de terre au Québec*. http://www.stat.gouv.qc.ca/statistiques/agriculture/pommes-terre/FS_pt19.pdf
- Jacobson RE, Axford N, Ray S & Attridge GG (2001) *Manual of Photography: Photographic and Digital Imaging*. Butterworth-Heinemann. 464 p

- Jannoura R, Brinkmann K, Uteau D, Bruns C & Joergensen RG (2015) Monitoring of crop biomass using true colour aerial photographs taken from a remote controlled hexacopter. *Biosystems Engineering* 129:341-351.
- Japkowicz N & Stephen S (2002) The class imbalance problem: A systematic study. *Intelligent Data Analysis* 6(5):42-449.
- Jernelöv A (2017) The Colorado (Potato) Beetle. *The Long-Term Fate of Invasive Species*, 10.1007/978-3-319-55396-2_8. p 105-116.
- Jin X, Liu S, Baret F, Hemerlé M & Comar A (2017) Estimates of plant density of wheat crops at emergence from very low altitude UAV imagery. *Remote Sensing of Environment* 198:105-114.
- Khelifi M, Laguë C & de Ladurantaye Y (2007) *Physical Control of Colorado Potato Beetle: A Review*. 557-569 p
- Krizhevsky A, Sutskever I & Hinton GE (2012) ImageNet classification with deep convolutional neural networks. in *Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1* (Curran Associates Inc., Lake Tahoe, Nevada), p 1097-1105.
- Kumar A, Lee WS, Ehsani RJ, Albrigo LG, Yang C & Mangan RL (2012) Citrus greening disease detection using aerial hyperspectral and multispectral imaging techniques. *Journal of Applied Remote Sensing* 6(1):23.
- Lague C, Khelifi M, Gill J & Lacasse B (1999) Pneumatic and thermal control of Colorado potato beetle. *Can. Agric. Eng.* 41(1):53-57.
- Lan Y, Huang Y, E. Martin D & C. Hoffmann W (2009) Development of an Airborne Remote Sensing System for Crop Pest Management: System Integration and Verification. *Applied Engineering in Agriculture* 25(4):607-615.
- Lecun Y, Bottou L, Bengio Y & Haffner P (1998) Gradient-based learning applied to document recognition. *Proceedings of the IEEE* 86(11):2278-2324.
- Lemaître G, Nogueira F & Aridas CK (2017) Imbalanced-learn: A Python Toolbox to Tackle the Curse of Imbalanced Datasets in Machine Learning. *Journal of Machine Learning Research* 18(17):1-5.
- Lhissou R, Chokmani K, Gill-Fortin J, Agili H, Poulin J & Bergeron D (2018) *Dépistage automatique des doryphores dans la culture de pomme de terre à l'aide de l'imagerie par drone et de la vision artificielle : Étude de faisabilité*. Institut National de la Recherche Scientifique - Centre Eau Terre Environnement, Québec, Canada <http://espace.inrs.ca/7330/1/R1794.pdf> (Consulté e Date Accessed)
- Li X, Lee WS, Li M, Ehsani R, Mishra AR, Yang C & Mangan RL (2015) Feasibility study on Huanglongbing (citrus greening) detection based on WorldView-2 satellite imagery. *Biosystems Engineering* 132:28-38.
- Liu C-a, Chen Z-x, Shao Y, Chen J-s, Hasi T & Pan H-z (2019) Research advances of SAR remote sensing for agriculture applications: A review. *Journal of Integrative Agriculture* 18(3):506-525.

- MAPAQ (2014) Indicateur de la gestion intégrée des ennemis des cultures , Résultats 2012.).
- Martel P, Belcourt J, Choquette D & Boivin G (1986) Spatial Dispersion and Sequential Sampling Plan for the Colorado Potato Beetle (Coleoptera: Chrysomelidae). *Journal of Economic Entomology* 79(2):414-417.
- McCornack B, Bhattarai GP, Witt T, Gonzalez F, Hamilton G, Vanegas F, Froese J, Sandino J, Weiss J & Peff G (2018) Optimising surveillance protocols using unmanned aerial systems. (Plant Biosecurity Cooperative Research Centre).
- McGlone JC, Lee GYG, American Society for P & Remote S (2013) *Manual of photogrammetry*. ASPRS, American Soc. for Photogrammetry and Remote Sensing, Bethesda, Md
- Mirik M, Jones DC, Price JA, Workneh F, Ansley RJ & Rush CM (2010) Satellite Remote Sensing of Wheat Infected by Wheat streak mosaic virus. *Plant Disease* 95(1):4-12.
- Mohanty SP, Hughes DP & Salathé M (2016a) Using Deep Learning for Image-Based Plant Disease Detection. *Frontiers in plant science* 7:1419-1419.
- Mohanty SP, Hughes DP & Salathé M (2016b) Using Deep Learning for Image-Based Plant Disease Detection. *Frontiers in Plant Science* 7(1419).
- Mulla DJ (2013) Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems Engineering* 114(4):358-371.
- O'Connor J, Smith MJ & James MR (2017) Cameras and settings for aerial surveys in the geosciences: Optimising image data. *Progress in Physical Geography: Earth and Environment* 41(3):325-344.
- OAQ (2019) GUIDE DE BONNES PRATIQUES VISANT À RÉDUIRE L'UTILISATION ET LES RISQUES DES INSECTICIDES DE LA FAMILLE DES NÉONICOTINOÏDES DANS LA CULTURE DE POMMES DE TERRE.).
- Rangarajan AK, Purushothaman R & Ramesh A (2018) Tomato crop disease classification using pre-trained deep learning algorithm. *Procedia Computer Science* 133:1040-1047.
- Sankaran S, Khot LR, Espinoza CZ, Jarolmasjed S, Sathuvalli VR, Vandemark GJ, Miklas PN, Carter AH, Pumphrey MO, Knowles NR & Pavek MJ (2015) Low-altitude, high-resolution aerial imaging systems for row and field crop phenotyping: A review. *European Journal of Agronomy* 70:112-123.
- Santesteban LG, Di Gennaro SF, Herrero-Langreo A, Miranda C, Royo JB & Matese A (2017) High-resolution UAV-based thermal imaging to estimate the instantaneous and seasonal variability of plant water status within a vineyard. *Agricultural Water Management* 183:49-59.
- Sexson DL & Wyman JA (2005) Effect of Crop Rotation Distance on Populations of Colorado Potato Beetle (Coleoptera: Chrysomelidae): Development of Areawide Colorado Potato Beetle Pest Management Strategies. *Journal of Economic Entomology* 98(3):716-724.
- Shin H, Roth HR, Gao M, Lu L, Xu Z, Noguees I, Yao J, Mollura D & Summers RM (2016) Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning. *IEEE Transactions on Medical Imaging* 35(5):1285-1298.

- Singh AK, Ganapathysubramanian B, Sarkar S & Singh A (2018) Deep Learning for Plant Stress Phenotyping: Trends and Future Perspectives. *Trends in plant science* 23(10):883-898.
- SPQA Cdsedcdlspqea (2011) Stratégie phytosanitaire québécoise en agriculture 2011-2021. (Ministère de l'Agriculture, des Pêcheries et de l'Alimentation), p 25.
- Srinivasan A (2006) *Handbook of Precision Agriculture Principles and Applications*. CRC Press, Boca Raton, Florida, USA. 683 p
- Srivastava N, Hinton G, Krizhevsky A, Sutskever I & Salakhutdinov R (2014) *Dropout: A Simple Way to Prevent Neural Networks from Overfitting*. 1929-1958 p
- Sugiura R, Tsuda S, Tamiya S, Itoh A, Nishiwaki K, Murakami N, Shibuya Y, Hirafuji M & Nuske S (2016) Field phenotyping system for the assessment of potato late blight resistance using RGB imagery from an unmanned aerial vehicle. *Biosystems Engineering* 148:1-10.
- Torres-Sánchez J, Peña JM, de Castro AI & López-Granados F (2014) Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. *Computers and Electronics in Agriculture* 103:104-113.
- Vanegas F, Bratanov D, Powell K, Weiss J & Gonzalez F (2018) A Novel Methodology for Improving Plant Pest Surveillance in Vineyards and Crops Using UAV-Based Hyperspectral and Spatial Data. *Sensors* 18(1):260.
- Vega FA, Ramírez FC, Saiz MP & Rosúa FO (2015) Multi-temporal imaging using an unmanned aerial vehicle for monitoring a sunflower crop. *Biosystems Engineering* 132:19-27.
- Wang J, Lin C, Ji L & Liang A (2012) A new automatic identification system of insect images at the order level. *Knowledge-Based Systems* 33:102-110.
- Weber DC (2003) Colorado Beetle: pest on the move. *Pesticide Outlook* 14:256-259.
- Weber DC (2013) Chapter 14 - Biological Control of Potato Insect Pests. *Insect Pests of Potato*, Academic Press, San Diego <https://doi.org/10.1016/B978-0-12-386895-4.00014-4>. p 399-437.
- Weisz R, Fleischer S & Smilowitz Z (1995) Site-Specific Integrated Pest Management for High Value Crops: Sample Units for Map Generation Using the Colorado Potato Beetle (Coleoptera: Chrysomelidae) as a Model System. *Journal of Economic Entomology* 88(5):1069-1080.
- Weisz R, Fleischer S & Smilowitz Z (1996a) Site-Specific Integrated Pest Management for High-Value Crops: Impact on Potato Pest Management. *Journal of Economic Entomology* 89(2):501-509.
- Weisz R, Smilowitz Z & Fleischer S (1996b) Evaluating Risk of Colorado Potato Beetle (Coleoptera: Chrysomelidae) Infestation as a Function of Migratory Distance. *Journal of Economic Entomology* 89(2):435-441.
- Wiseman G, Kort J & Walker D (2009) Quantification of shelterbelt characteristics using high-resolution imagery. *Agriculture, Ecosystems & Environment* 131(1):111-117.
- Wright RJ (1984) Evaluation of Crop Rotation for Control of Colorado Potato Beetles (Coleoptera: Chrysomelidae) in Commercial Potato Fields on Long Island. *Journal of Economic Entomology* 77(5):1254-1259.

- Xia D, Chen P, Wang B, Zhang J & Xie C (2018) Insect Detection and Classification Based on an Improved Convolutional Neural Network. *Sensors (Basel, Switzerland)* 18(12):4169.
- Yang C (2018) High resolution satellite imaging sensors for precision agriculture. *Front. Agr. Sci. Eng.* 5(4):393-405.
- Yao Y, Rosasco L & Caponnetto A (2007) On Early Stopping in Gradient Descent Learning. *Constructive Approximation* 26(2):289-315.
- Yu N, Li L, Schmitz N, Tian LF, Greenberg JA & Diers BW (2016) Development of methods to improve soybean yield estimation and predict plant maturity with an unmanned aerial vehicle based platform. *Remote Sensing of Environment* 187:91-101.
- Zarco-Tejada PJ, González-Dugo V & Berni JAJ (2012) Fluorescence, temperature and narrow-band indices acquired from a UAV platform for water stress detection using a micro-hyperspectral imager and a thermal camera. *Remote Sensing of Environment* 117:322-337.
- Zehnder G, Encill AM & Speese IIIJ (1995) Action Thresholds Based on Plant Defoliation for Management of Colorado Potato Beetle (Coleoptera: Cbrysomelidae) in Potato. *Journal of Economic Entomology* 88(1):155-161.
- Zhang C & Kovacs JM (2012) The application of small unmanned aerial systems for precision agriculture: a review. *Precision Agriculture* 13(6):693-712.
- Zheng Y-Y, Kong J-L, Jin X-B, Wang X-Y, Su T-L & Zuo M (2019) CropDeep: The Crop Vision Dataset for Deep-Learning-Based Classification and Detection in Precision Agriculture. *Sensors* 19(5).
- Zhou X, Zheng HB, Xu XQ, He JY, Ge XK, Yao X, Cheng T, Zhu Y, Cao WX & Tian YC (2017) Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery. *ISPRS Journal of Photogrammetry and Remote Sensing* 130:246-255.

7 ANNEXES

ANNEXE 1

NOTES DE DÉPISTAGE POUR LES SORTIES TERRAIN DU 19 ET 30 JUILLET 2018

Dépistage 18 juillet 2018

Section de ≈3m à 2 rangs

v = visible c = caché

Lj = larve jeune

Lv = larve vieille

N° Section	N° Rang	Larve		Adulte	Masse d'œufs	Commentaires
		Jeune	Vieille			
3	Rang 9	23v 5c	43v 10c	0	-	Au centre du rang de la cible
	Rang 8	11v 8c	4v	0	-	Jeunes larves sont trop petite (elles n'auront pas assez de pixels)
	Total	34v 13c	47v 10c	0	-	-
2	Rang 9	0	19v 8c	0	-	Au centre du rang de la cible
	Rang 8	0	3v	0	-	-
	Total	0	22v 8c	0	-	-
4	Rang 7	19v 16c	34v 8c	0	-	5v2c Lj et 30v6c Lv dans le coin à marque rouge et 14v14c Lj et 4v2c Lv dans l'autre coté du rang
	Rang 8	0	0	0	-	-
	Total	19v 16c	34v 8c	0	-	-
1* (après le vol)	Rang 8	4v 4c	16v 10c	1c	-	L'adulte parfois sous les feuilles parfois au-dessus
	Rang 7	0	4v	0	-	-
	Total	4v 4c	20v 10c	1c	-	-

Section de ≈3m à 2 rangs

Section	N° Rang	Larve		Adulte	Masse d'œufs	Commentaires
		Jeune	Vieille			
2* (après le vol)	Rang 9	0	12v 9c	0	-	-
	Rang 8	0	1v	0	-	-
	Total	0	13v 9c	0	-	-

3* (après le vol)	Rang 8	7v 7c	4v 1c	0	-	-
	Rang 9	15v 6c	29v 7c	0	-	-
	Total	22v 13c	33v 8c	0	-	-

Dépistage 30 juillet 2018

Section de ≈3m à 2 rangs

v = visible c = caché

Lj = larve jeune

Lv = larve vieille

N° Section	N° Rang	Larve		Adulte	Commentaires	Nombre de Photos
		Jeune	Vieille			
1	Rang 10	3v 0c	8v 2c	2v	Adultes sur l'extrémité (à côté de la marque en carton)	1
	Rang 11	2v 1c	22v 2c	6v	Adultes sur l'extrémité (à côté de la marque en carton)	3
	Total	5v 1c	30v 4c	8v	Adultes sur l'extrémité (à côté de la marque en carton)	

2	Rang 8	14v 13c	60v 8c			4
	Rang 9	3v 2c	16v 7c	1c		2
	Total	17v 15c	76v 15c	1c		

N° Section	N° Rang	Larve		Adulte	Commentaires	Nombre de photos
		Jeune	Vieille			
4	Rang 9	4v	30v 10c	5v	2 Adultes à côté du drapeau	2
	Total	4v	30v 10c	5v		

6	Rang 10	1v	4v 3c			1
	Rang 11	0	4v 1c	4v 1c		1
	Total	1v	8v 4c	4v 1c		

Section de ≈4m à 2 rangs

entre la cible 7 et la cible 8

v = visible c = caché

Lj = larve jeune

Lv = larve vieille

N° Section	N° Rang	Larve		Adulte	Commentaires	Nombre de photos
		Jeune	Vieille			
Entre le carton 7 et 8	Rang 11	5v 1c	1c	0		2
	Rang 12	1v	1v 1c	1v	Adultes sur l'extrémité (à côté de la marque 7 en carton)	2
	Total	6v 1c	1v 2c	1v		

ANNEXE 2

**DISTRIBUTION DE FRÉQUENCE DE PROBABILITÉ POUR LES ÉCHANTILLONS
DE LA BASE DE DONNÉES DE VALIDATION POUR LES DIFFÉRENTS MODÈLES**




Figure 1: Fréquence de probabilité pour les deux classes pour l'ensemble des échantillons de validation pour le modèle ResNet-18 suréchantillonné v1




Figure 2: Fréquence de probabilité pour les deux classes pour l'ensemble des échantillons de validation pour le modèle ResNet-18 suréchantillonné v2




Figure 3: Fréquence de probabilité pour les deux classes pour l'ensemble des échantillons de validation pour le modèle ResNet-18 non balancé 15-1




Figure 4: Fréquence de probabilité pour les deux classes pour l'ensemble des échantillons de validation pour le modèle ResNet-18 sous-échantillonné v1




Figure 5: Fréquence de probabilité pour les deux classes pour l'ensemble des échantillons de validation pour le modèle ResNet-18 sous-échantillonné v2

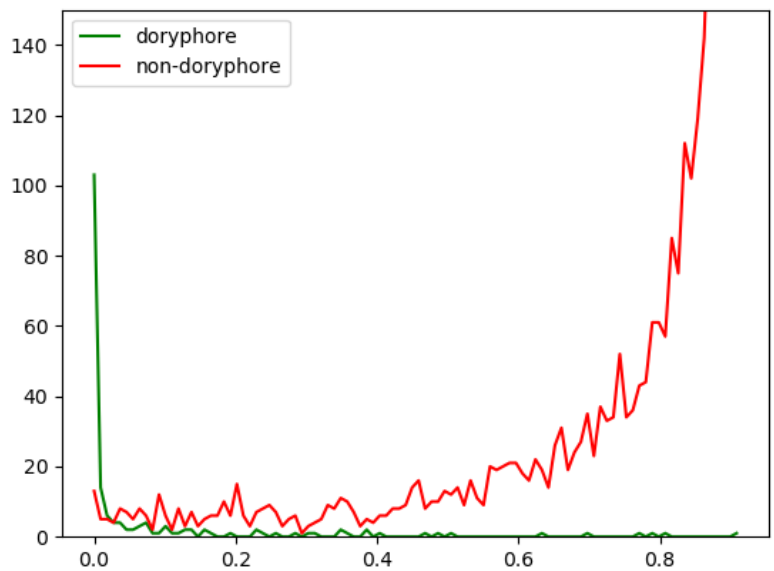


Figure 6: Fréquence de probabilité pour les deux classes pour l'ensemble des échantillons de validation pour le modèle ResNet-34 suréchantillonné v1




Figure 7: Fréquence de probabilité pour les deux classes pour l'ensemble des échantillons de validation pour le modèle ResNet-34 sur échantillonné v2




Figure 8: Fréquence de probabilité pour les deux classes pour l'ensemble des échantillons de validation pour le modèle ResNet-34 non balancé 15-1




Figure 9: Fréquence de probabilité pour les deux classes pour l'ensemble des échantillons de validation pour le modèle ResNet-34 sous-échantillonné v1




Figure 10: Fréquence de probabilité pour les deux classes pour l'ensemble des échantillons de validation pour le modèle ResNet-34 sous-échantillonné v2




Figure 11: Fréquence de probabilité pour les deux classes pour l'ensemble des échantillons de validation pour le modèle ResNet-50 suréchantillonné v1

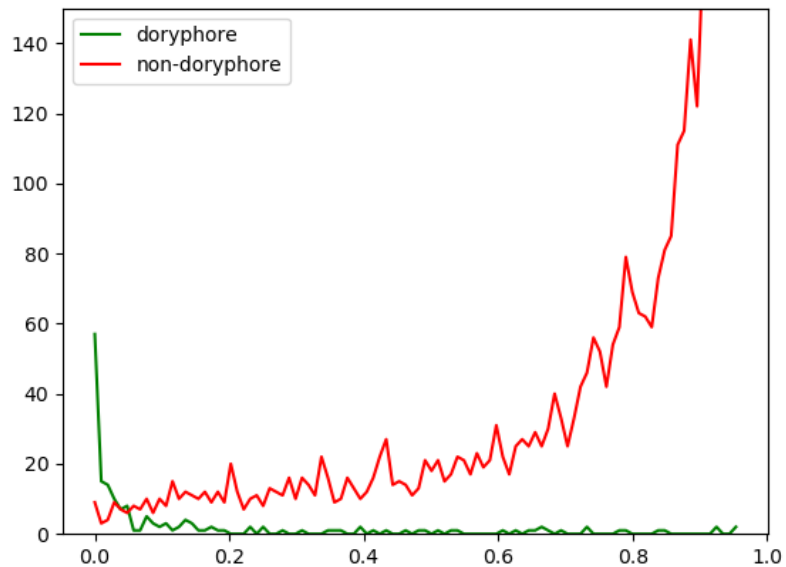


Figure 12: Fréquence de probabilité pour les deux classes pour l'ensemble des échantillons de validation pour le modèle ResNet-50 sous-échantillonné suréchantillonné v2




Figure 13: Fréquence de probabilité pour les deux classes pour l'ensemble des échantillons de validation pour le modèle ResNet-50 non balancé 15-1




Figure 14: Fréquence de probabilité pour les deux classes pour l'ensemble des échantillons de validation pour le modèle ResNet-50 sous-échantillonné v1

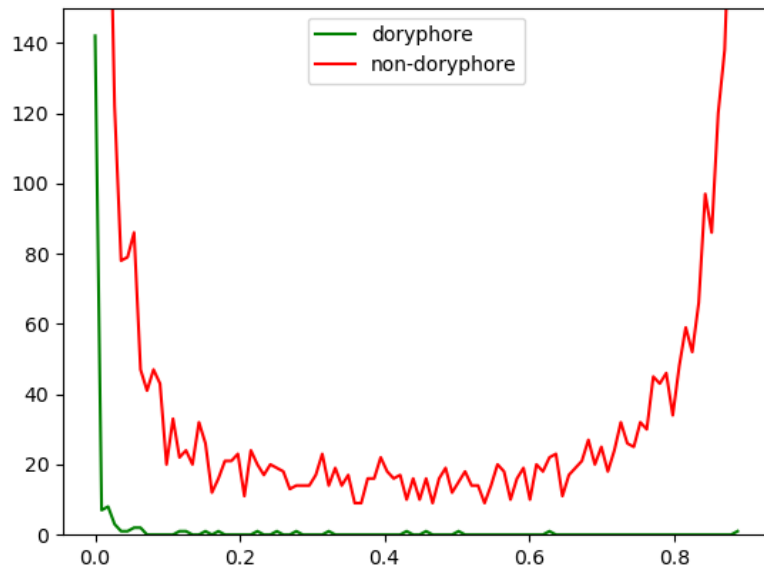


Figure 15: Fréquence de probabilité pour les deux classes pour l'ensemble des échantillons de validation pour le modèle ResNet-50 sous-échantillonné v2

ANNEXE 3

MATRICES DE CONFUSION POUR LE JEU DE DONNÉES TESTS DES DIFFÉRENTS MODÈLES

MATRICE DE CONFUSION :

$$\begin{bmatrix} VP & FN \\ FP & VN \end{bmatrix}$$

ResNet-18 suréchantillonné v1

$$\begin{bmatrix} 151 & 104 \\ 45 & 6863 \end{bmatrix}$$

ResNet-18 suréchantillonné v2

$$\begin{bmatrix} 116 & 139 \\ 87 & 6821 \end{bmatrix}$$

ResNet-18 non balancé 15 :1

$$\begin{bmatrix} 145 & 110 \\ 32 & 6876 \end{bmatrix}$$

ResNet-18 sous-échantillonné v1

$$\begin{bmatrix} 127 & 128 \\ 84 & 6824 \end{bmatrix}$$

ResNet-18 sous-échantillonné v2

$$\begin{bmatrix} 50 & 205 \\ 313 & 6595 \end{bmatrix}$$

ResNet-34 suréchantillonné v1

$$\begin{bmatrix} 132 & 123 \\ 33 & 6875 \end{bmatrix}$$

ResNet-34 suréchantillonné v2

$$\begin{bmatrix} 139 & 116 \\ 130 & 6778 \end{bmatrix}$$

ResNet-34 non balancé 15 :1

$$\begin{bmatrix} 155 & 100 \\ 53 & 6855 \end{bmatrix}$$

ResNet-34 sous-échantillonné v1

$$\begin{bmatrix} 147 & 108 \\ 62 & 6846 \end{bmatrix}$$

ResNet-34 sous-échantillonné v2	$\begin{bmatrix} 35 & 220 \\ 239 & 6669 \end{bmatrix}$
ResNet-50 suréchantillonné v1	$\begin{bmatrix} 155 & 100 \\ 33 & 6875 \end{bmatrix}$
ResNet-50 suréchantillonné v2	$\begin{bmatrix} 109 & 146 \\ 47 & 6861 \end{bmatrix}$
ResNet-50 non balancé 15 :1	$\begin{bmatrix} 157 & 98 \\ 49 & 6859 \end{bmatrix}$
ResNet-50 sous-échantillonné v1	$\begin{bmatrix} 113 & 142 \\ 45 & 6863 \end{bmatrix}$
ResNet-50 sous-échantillonné v2	$\begin{bmatrix} 168 & 87 \\ 2491 & 4417 \end{bmatrix}$