



## Marie-Pia d'Argaignon

### SICOM

## 2021/2022

INRAE GAFL et EMMAH Centre de Recherche Provence-Alpes-Côte d'Azur, Domaine Saint Paul 228 route de l'Aérodrome Site Agroparc - CS 40509 84914 Avignon

# Phénotypage des traits de vigueur et de floraison chez les Prunus à l'aide de l'analyse d'images et du deep learning

Février 2022 - Juillet 2022

Sous la supervision de :

- Maitre de stage : Morgane Roth <u>morgane.roth@inrae.fr</u> et Marie Weiss <u>marie.weiss@inrae.fr</u>
- Co-encadrants : Sylvain Jay <u>sylvain.jay@inrae.fr</u>, Etienne David <u>edavid@hiphen-plant.com</u>
- Tuteur école : Alice Caplier

Confidentialité : non











Ce travail a bénéficié d'une aide de l'État gérée par l'Agence Nationale de la Recherche au titre du programme d'Investissements d'Avenir portant la référence ANR-16-CONV-0004

This work was supported by the French National Research Agency under the Investments for the Future Program, referred as ANR-16-CONV-0004.

# Remerciements

Je tiens à remercier Marie Weiss et Morgane Roth qui m'ont proposé ce sujet de stage et plus généralement mes quatre encadrants Morgane, Marie, Sylvain Jay et Etienne David pour leur bienveillance et leurs conseils pendant tout ce stage et pour leur aide à la rédaction du rapport.

Je remercie aussi toute l'équipe Prunus et en particulier à Marie Serrie, Sabrina, Véronique, Morgane, Léo et Jean-Marc pour leur aide pour les photos et pour toutes les notations en vergers et sur photos.

Un grand merci à Micheline Debroux, Frederic Venault, Morgane et Sylvain pour leur patience et leur précision dans l'annotation des images pour l'entrainement des réseaux de deep.

Merci à Mme Caplier, ma tutrice école, pour ses conseils tout au long du stage.

Merci à Ayoub qui s'est occupé de toutes mes images en sortie de LITERAL et qui m'a prêté son bureau.

Merci à Hortense et Hugo et Pierre pour leurs conseils à la relecture de mon rapport.

# **Table des illustrations**

Figure 1: Carte de la répartition des core-collections d'abricotiers et de pêchers du GAFL	.9
Figure 2: note de floribondité du GAFL en fonction de la distribution spatiale des fleurs	10
Figure 3: illustration du système LITERAL	12
Figure 4: Exemple de photos pour la mesure de vigueur pêcher à gauche abricotier à droite	12
Figure 5: exemple de photo pêcher (1 et 2) et abricotier (3) utilisées pour mesurer la floribondit	té
photos prises avec LITERAL.	13
Figure 6: Distribution des pêchers selon la classe de floribondité	14
Figure 7:exemple d'annotation pour la segmentation du bois	15
Figure 8: exemples d'annotations de fleurs	15
Figure 9: Pipeline pour l'estimation de la circonférence proposée par Sylvain Jay(2022)	16
Figure 10:résultats de l'estimation de la circonférence avec la méthode d'origine sur les	10
arbres sélectionnés	16
Figure 11: étapes pour l'identification de l'arbre d'intérêt	18
Figure 12: sections du tronc pour l'estimation de la circonférence selon les méthodes	19
Figure 12: méthode 1 : estimation de la circonférence sur la marque bleue	19
Figure 14: Méthode 2 : estimation de la circonférence et du volume sur 15cm de hauteur	20
Figure 15: Calcul de la floribondité	20
Figure 16:méthode de calcul des distances entre fleurs et exemple de courbe de distribution d	les
distances pour un arbre avec une note floribondité de 4	22
Figure 17: superposition des courbes de distribution des distances entre fleurs évaluées à par	tir
de la notation visuelle en verger (à gauche) ou des images (à droite), chaque couleur de cour	be
est associée à une note allant de 1 à 4	22
Figure 18: Evolution des performances du réseau de segmentation du bois au cours de se	on
apprentissage	23
Figure 19: segmentation du bois par deep learning, sur pêcher en janvier (1) et en mai (2) et s	sur
abricotier (3)	24
Figure 20: exemple de détection des fleurs avec le réseau Mask-RCNN	24
Figure 21: Estimation de la circonférence : influence de la méthode de segmentation	25
Figure 22: estimation du biais	25
Figure 23: Estimation de la circonférence pour l'ensemble des arbres photographiés apr	rès
segmentation par deep learning	25
Figure 24: Croissance de la circonférence (à gauche) et du volume (à droite) entre janvier	et
mai 2022 estimés par analyse d'image en fonction des données in situ mesurées au mètre rub	an
mar 2022 estimes par anaryse d'image en fonction des données in situ mésurées au mété rub	26
Figure 25: Relation entre les estimations du nombre de fleurs par volume de bois sur pêche	ers
de manière manuelle et par analyse d'image	26
Figure 26: Estimation nombre de fleurs par volume de bois sans voisins sur pêchers estimé p	ar
une movenne sur plusieurs images en fonction de la valeur obtenue à l'aide d'une seule ima	ge
	27
Figure 27: estimation du nombre de fleurs par volume de bois sur abricotier	27
Figure 28: Etablissement d'une note proposée par clustering de courbes	28
Figure 29: Estimation du stade de floraison	29
Figure 30: Images correspondent à des décalages importants entre estimation visuelle et p	 Jar
analyse d'image du stade de floraison identifiés en figure 20	2Q
Figure 31: architecture UNFT	27
	51

# Table des matières

Remerciements	
Table des illustrations	
GLOSSAIRE	7
Présentation du laboratoire	
1. INTRODUCTION	
2. Matériel et Méthodes	
2.1. Matériel	
2.1.1. Photos	
2.1.2. Données Terrain	
2.1.3. Annotation	
2.2. Méthodes d'analyse	
2.2.1. Circonférence du tronc	
2.2.3. Floribondité et date de fl	oraison20
3. Résultats	
3.1. Performances des méthodes o	le deep learning pour la segmentation et la détection . 23
3.1.1. A. Segmentation du boi	s
3.1.2. B. Détection des fleurs.	
3.2. Estimation de la circonférence	e du tronc
3.3. Floribondité : rapport du non	bre de fleurs par volume de bois
<ul><li>3.4. Floribondité prenant en com</li><li>28</li></ul>	pte l'homogénéité de répartition des fleurs dans l'arbre
3.5. Stade de Floraison	
4. Discussion	
4.1. Les images RGB: de nouveau	ax vecteurs prometteurs pour le phénotypage
4.2. Perspectives et améliorations	des méthodes développées
5. CONCLUSION	
Bibliographie	
ANNEXES	
Annexe 1 : Définitions utiles pour le	es réseaux de Deep Learning
Annexe 2 : réseau MaskRCNN	
Annexe 3: Réseau Unet pour la segr	nentation
Annexe 3 : Stéréovision pour calcul Block Matching	er la carte 3D d'une image par algorithme Semi-Global 
Annexe 4 : Calcul de la résolution a	u niveau du tronc

Annexe 5 : illustration : diversité des fleurs photographiées	40
Annexe 6 : description des données d'entraînement pour la détection	41
Annexe 7: courbes d'apprentissage du réseau de détection des fleurs	41
Annexe 8 : performance du réseau de détection sur les données test	41
Annexe 9: précision de la mesure de circonférence en verger	42
Annexe 10: Précision de la notation de floribondité	43
Annexe 11 : Synthèse de la bibliographie phénotypage digital	44
Diagramme de GANTT	48
Résumé	49
Abstract	49

# GLOSSAIRE

**Bouquet de mai :** Rameau très court qui porte des bourgeons à fleurs regroupés et un unique bourgeon végétatif

**Charpentière :** Branche qui part directement du tronc et contribue à l'architecture principale de l'arbre. Sur ces branches se développent des rameaux secondaires.

**Core-collection :** Collection d'une espèce donnée où les individus sont génétiquement tous différents et en nombre réduit et optimisé pour être représentatif de la diversité génétique.

**Deep-Learning:** le deep-learning est une partie de l'intelligence artificielle dédié à l'analyse des données non-structurées. Le deep-Learning repose sur un système de plusieurs couches de neurones reliées entre elles, chaque couche apprend des informations qu'elle reçoit de la précédente et plus il y a de couche plus le réseau est dit profond (deep).

**Génotypage** : consiste à acquérir l'information génétique d'un individu. Les séquences ou marqueurs génétiques sont analysés par biologie moléculaire après extraction d'ADN ou d'ARN.

**Génotype :** Le génotype désigne au sens large l'ensemble des gènes constituant l'ADN (identité et constitution génétique) d'un organisme. Au sens strict, le plus couramment employé, ce terme désigne l'identité d'un individu telle que reflétée par ses variants génétiques, par exemple par ses allèles à des endroits donnés du génome).

**Phénologie :** Étude de l'évolution dans le temps des phénomènes qui caractérisent le cycle biologique des êtres vivants.

**Phénotype :** Le terme « phénotype » fait référence aux propriétés physiques observables d'un organisme ; ceux-ci incluent l'apparence, le développement et le comportement de l'organisme. Le phénotype d'un organisme est déterminé par son génotype et par les influences environnementales. Considérant les plantes, les phénotypes incluent par exemple la taille ou le nombre de fleurs, ils comprennent aussi des caractéristiques observables qui peuvent être mesurées en laboratoire comme la concentration de chlorophylle.

**Phénotypage** : C'est la mesure des caractéristiques visuelles, physiques et/ou biochimiques d'un individu dans un environnement donné

**Rameau mixte :** Rameau qui porte des feuilles et des fleurs contrairement au rameau à bois qui ne porte que des bourgeons végétatifs (à feuilles)

La segmentation d'images : c'est l'identification des pixels appartenant à l'objet qu'on souhaite reconnaître dans une image (en les distinguant du fond) ; La segmentation se fait par méthodes classiques (non supervisées) ou par apprentissages (méthodes supervisées).

**Traits d'un phénotype :** ensemble des caractéristiques observables de l'arbre qui permettent la prédiction et la détection de maladies, la mesure de la croissance (vigueur) ou encore la prédiction et la quantification de la production

**Vigueur d'un arbre :** Le terme « vigueur » caractérise la capacité à pousser rapidement et se mesure classiquement par le taux de croissance du bois par rapport à celui des feuilles

# Présentation du laboratoire

Ce stage a été réalisé à INRAE, au sein des deux unités GAFL et CAPTE.

INRAE (Institut national de recherche pour l'agriculture, l'alimentation et l'environnement), est né en 2020 de la fusion d'INRA (Institut National de la Recherche Agronomique, fondé en 1946) et d'IRSTEA (Institut de Recherche en Sciences et Technologies pour l'Environnement et l'Agriculture). Il est un organisme de recherche spécialisé sur les domaines de l'agronomie, l'agriculture, l'alimentation et l'environnement et agit en proposant, par la recherche, l'innovation et l'appui aux politiques publiques, de nouvelles orientations pour accompagner l'émergence des systèmes agricoles et alimentaires durables.

INRAE est partenaire de 33 sites universitaires et se divise en 20 centres de recherche et plus de 150 implantations dans lesquels travaillent 11 027 employés dont 2005 chercheurs, 3179 ingénieurs, 3045 techniciens et administratifs, et 2798 contractuels. Son réseau international lui permet de collaborer avec les meilleures équipes en Europe et dans le monde.

L'unité de recherche GAFL, Génétique et Amélioration des Fruits et Légumes, se situe sur le centre INRAE PACA à Avignon. Le GAFL se divise en deux équipes : ReDD (Résistance aux pathogènes et aux ravageurs, Diversité et Durabilité) et DADI (Diversité, Adaptation, Déterminants et Intégration) qui étudient les Solanacées (aubergine, piment, tomate), les cucurbitacées (melon, concombre) et les *Prunus* (fruits à noyau). Ses recherches suivent quatre axes : la diversité des espèces, les bases génétiques et moléculaires de la qualité des fruits, la caractérisation des interactions plantes/pathogènes et la résistance aux maladies.

L'Unité Mixte Technologique CAPTE a été créée en 2014 et rassemble l'équipe CAPTE de l'unité EMMAH (Environnement Méditerranéen et Modélisation des AgroHydrosystèmes) d'INRAE et les entreprise ARVALIS et Hiphen autour des problématiques de caractérisation de l'état et le fonctionnement des grandes cultures (blé, maïs, tournesol...) par CAPteurs et TElédétection, en particulier pour le phénotypage.

Ce stage est financé par l'Institut de Convergences #DigitAg, qui réunit 17 acteurs, organismes publics de recherche et d'enseignement ou entreprises, autour du développement de l'agriculture numérique et des entreprises du domaine.

# **1.INTRODUCTION**

L'agriculture fait face aujourd'hui à un défi majeur : produire suffisamment pour satisfaire la consommation agricole, qui doit augmenter de 60% d'ici 2050 (José Graziano Da Silva, 2016) [1], en utilisant à bon escient les ressources disponibles et en s'adaptant aux contraintes climatiques. Dans ce contexte, la sélection des variétés les plus productives et les plus résistantes avec le meilleur rapport production/ressources utilisées est très importante. Les variétés sélectionnées sont aussi celles qui s'adaptent bien au changement climatique et qui nécessitent peu d'intrants chimiques, en particulier par leurs résistances ou tolérances aux maladies.

L'intelligence artificielle et les différents capteurs RGB (Red, Green, Blue), infra-rouge, LiDAR, utilisés en Proxi détection, par UAV (Unmanned Aerial Vehicle) ou par satellite, sont une nouvelle source de données pour ce travail de sélection. S'ils sont déjà bien exploités pour les grandes cultures (blé, maïs), le travail sur les arbres fruitiers est encore exploratoire et est surtout développé pour la pomme ou la vigne (voir Annexe 11 : Synthèse de la bibliographie phénotypage digital).

Le laboratoire DADI du GAFL, et en particulier l'équipe DADI-Prunus qui travaille sur la résilience des arbres fruitiers du genre *Prunus* (ici pêcher, abricotier, amandier), étudie les différentes variétés de ces arbres fruitiers et compare leurs comportements en verger dans différentes situations climatiques et épidémiologiques. En exposant les mêmes génotypes à ces différents contextes, l'objectif est d'identifier l'héritabilité des traits étudiés, c'est à dire quelle proportion de la variabilité phénotypique est due à l'effet du génotype et ainsi sélectionner les variétés à privilégier par les producteurs. Des vergers bas-intrants situés dans différents sites du bassin de production français et rassemblant une sélection d'arbres représentant la diversité pour chaque espèce ('core-collection') sont dédiés à cette étude. On compte 5 vergers rassemblant 206 variétés de pêchers, et 150 d'abricotiers (Figure 1).



Figure 1: Carte de la répartition des core-collections d'abricotiers et de pêchers du GAFL

Pour faire une étude comparative les expérimentateurs doivent réaliser un phénotypage étendu, c'est-à-dire suivre au cours du temps chacun des arbres individuellement et relever l'ensemble des caractéristiques observables (ou "traits") qui permettront la prédiction et la détection de maladies, la mesure de la croissance, de la vigueur, ou encore la prédiction et la quantification de la phénologie et de la production.

Pour certains relevés, les agents doivent passer plusieurs fois par semaine. Cette étude mobilise donc beaucoup de personnel et de temps et certaines mesures sont très dépendantes de l'effet de l'observateur car elles restent difficiles à objectiver malgré l'existence de protocoles détaillés. L'équipe DADI du GAFL s'est donc associée à l'équipe CAPTE ainsi qu'à la société Hiphen, pour mettre en place des outils de phénotypage pour les arbres fruitiers par analyse d'image et Deep Learning qui seront moins sensibles à l'effet notateur et prendront moins de temps. Pendant ce stage, nous avons ciblé trois traits à étudier pour le pêcher et l'abricotier : (i) la vigueur, (ii) la floribondité, et (iii) le stade de floraison.

(i) La vigueur d'un arbre peut être définie par sa vitesse de croissance. Pour réaliser le suivi de ce trait, le GAFL mesure la circonférence des troncs pour calculer leur croissance d'une année sur l'autre. Le tronc d'un arbre en bonne santé peut grossir de quelques millimètres de diamètre par mois au printemps. La mesure de la circonférence se fait pour l'instant au mètre ruban, une fois par an. Une méthode par analyse d'image permettrait de faire cette mesure plus régulièrement et de ne plus dépendre de la précision du positionnement du mètre ruban sur le tronc. Elle serait également insensible aux erreurs de lecture ou de report.

Thomas et al [2] propose une mesure de la circonférence du tronc par analyse d'images prises face à l'arbre. Il est proposé de prendre deux photos selon des axes perpendiculaires, et de mesurer ensuite la circonférence en prenant en compte l'inclinaison, mesurée sur l'arbre ou par analyse d'image et la forme du tronc. Cette méthode donne de bons résultats(r<sup>2</sup>=0.92 entre la mesure image et la mesure au mètre ruban) mais est contraignante au moment de la prise d'image (éclairage au flash, deux photos, utilisation d'une mire) et la segmentation du tronc doit être faite à la main. L'objectif est de proposer une méthode plus précise que le mètre ruban mais aussi qui permette des relevés plus réguliers. Le protocole d'acquisition des images doit donc être simple et rapide.

(ii) **La floribondité** est liée à la densité et la répartition des fleurs dans un arbre, et donne une indication sur la production potentielle en fruits de l'arbre mais aussi sur la sensibilité à certaines maladies qui pénètrent le système vasculaire de l'arbre via les fleurs (ex. monilia sur abricot [3]).

De manière générale la floribondité est représentée par le rapport du nombre de fleurs sur la longueur de rameaux mixtes, c'est-à-dire porteurs de feuilles et de fleurs. Au GAFL, la floribondité est mesurée par une note de 1 à 4 attribuée à chaque arbre et qui qualifie la quantité de fleurs mais aussi leur répartition dans l'arbre. Cette note doit être attribuée lorsque l'arbre est en pleine floraison pour que le notateur ne soit pas influencé par la



*Figure 2: note de floribondité du GAFL en fonction de la distribution spatiale des fleurs* 

quantité de fleurs ouvertes ou fermées, qui pourrait biaiser son jugement. Comme les vergers rassemblent différents génotypes, la floraison est étalée sur près d'un mois au cours duquel les agents doivent passer deux fois par semaine observer et noter chaque arbre de chaque verger. L'abricotier n'ayant pas la même architecture que le pêcher et ses fleurs étant souvent rassemblées en bouquets de mai (groupes de fleurs portés directement par une charpentière), la

notation n'est donc pas exactement la même que celle du pêcher : si les notes vont aussi de 1 à 4, elles prennent également en compte la quantité de bouquets de mai et leurs répartitions dans l'arbre, une note élevée reflétant une bonne homogénéité de la répartition des fleurs (cf Figure 2).

L'analyse d'images permettrait d'évaluer la floribondité en passant moins souvent dans le verger, puisqu'il n'y aurait pas besoin d'attendre d'être en pleine floraison, et d'avoir une notation qui ne dépendrait plus de l'observateur.

La littérature propose déjà plusieurs méthodes pour mesurer la floribondité des arbres fruitiers par image RGB. Lopez et al [4], Comas et al [5] et Horton et al [6] utilisent des images acquises par UAV. Ils segmentent les pixels fleurs par seuillage des couleurs ou de la luminosité. Horton divise ensuite le nombre de pixels fleur par le volume de l'arbre déterminé par OBIA (Object-Based Image Analysis, division des images du drone en sous-image pour chaque arbre) sur les images des UAV pour avoir une densité de fleurs. Dans Underwood et al [7] un travail sur des images RGB dans le rang, et une estimation de la floribondité en divisant le nombre de pixel fleurs, déterminé par analyse des couleurs, par le nombre de pixel de l'arbre segmenté par lidar sont proposés. Vanbrabant et al [8] analyse des images UAV et propose une segmentation des fleurs par machine learning (stochastic Gradient Boosting) et rassemble ensuite les pixels en fleurs par clustering. Ces méthodes sont parfois performantes mais elles dépendent beaucoup des conditions d'acquisition et sont peu robustes au changement de luminosité. Par ailleurs, comme l'illustre l'Annexe 5 : illustration : diversité des fleurs photographiées, les vergers étudiés par le GAFL rassemblent une grande diversité de génotypes distincts avec des couleurs et des formes de fleurs qui varient beaucoup, une simple analyse des couleurs ne serait pas suffisante. L'étude de Dias et al [9] propose une segmentation des fleurs par deep Learning et cette méthode a l'avantage de pouvoir détecter des fleurs de différentes couleurs ou formes et indépendamment des conditions d'acquisition. Mais ce modèle fait seulement la segmentation et ne permet donc pas d'estimer directement le nombre de fleurs et leurs positions dans l'image. Identifier les fleurs par algorithme de clustering après la segmentation parait compliqué dans certains cas où les fleurs se chevauchent beaucoup (exemple Figure 5 image du milieu). Les méthodes d'évaluation de la floribondité proposées dans la littérature sont donc plutôt développées pour l'analyse par UAV, et exploitent les complémentarités entre les données RGB et LIDAR pour obtenir le volume de bois ; ils ne sont valides que sur des arbres ayant des fleurs uniformes. La méthode proposée ici travaille uniquement sur photos RGB prises dans le rang, moins couteuses à acquérir que les données LiDAR elle utilise le deep Learning pour détecter les fleurs indépendamment de leur forme ou de leur couleur et permet ainsi de comparer la floribondité d'arbres de variétés différentes.

(iii) Le stade de floraison indique le pourcentage de fleurs ouvertes sur l'ensemble des fleurs de l'arbre. Lors de leur passage dans les vergers, deux fois par semaines, les expérimentateurs indiquent pour chacun des arbres s'il est à 0, 10,50 ou 100% de fleurs ouvertes.

Ce stage s'est donc déroulé entre les deux équipes DADI et CAPTE et la société Hiphen, et avait pour objectif de développer de nouveaux outils permettant d'évaluer ces traits de floribondité et de vigueur à partir de photos RGB des arbres acquis sur le rang.

La première partie de ce rapport présente le matériel d'étude et les méthodes d'analyse proposées, une seconde partie expose les résultats obtenus et la dernière partie est consacrée à la discussion de ces résultats et aux perspectives d'amélioration.

# 2. Matériel et Méthodes

## 2.1. Matériel

### 2.1.1. Photos

Pour la phase d'acquisition des données les photos ont été réalisées avec la perche LITERAL [10] développée par l'unité CAPTE pour le phénotypage des grandes cultures. Ce système portatif comprend deux caméras fixées et calibrées pour pouvoir utiliser la vision stéréo. Les photos sont de type RGB, et définies sur 3200\*4800 pixels.



Figure 3: illustration du système LITERAL

Le jeu de données est constitué de photos des pêchers et d'abricotiers plantés dans des vergers de type 'core collection' présentés dans l'introduction.

Pour estimer la circonférence des troncs 76 pêchers du verger des Garrigues à Avignon et 14 abricotiers du verger de,Gotheron à Saint-Marcel les valences ont été photographiés perpendiculairement au rang à 2m50 de l'arbre, en janvier ou février, puis en mai avec la perche LITERAL (Figure 4).



Figure 4: Exemple de photos pour la mesure de vigueur, pêcher à gauche, abricotier à droite

Pour caractériser la floribondité, 101 pêchers et 30 abricotiers ont été photographiés à différents stades de floraison (fleurs bourgeons, fleurs ouvertes, fleurs fanées) pour représenter toute la diversité de fleurs possible (Annexe 5 : illustration : diversité des fleurs photographiées).

Les photos ont été prises en contre-plongée pour avoir un fond uniforme (le ciel) et éviter d'avoir derrière tous les autres rangs qui auraient pu perturber la mesure. Sur une photo toutes les fleurs ne sont donc pas toujours visibles et l'arbre n'est pas toujours représenté dans son entièreté.



Figure 5: exemple de photo pêcher (1 et 2) et abricotier (3) utilisées pour mesurer la floribondité, photos prises avec LITERAL.

### 2.1.2. Données Terrain

La circonférence du tronc des arbres a été mesurée au mètre ruban dans tous les vergers au mois de janvier et une marque bleue de plusieurs centimètres de large a été faite à l'endroit de la mesure. Sur dix arbres la circonférence a de nouveau été mesurée en mai à l'endroit de la marque bleue dessinée en janvier.

Pour la floribondité des notes de 1 à 4 qualifiant la floribondité ont été données à chacun des arbres à leur pleine floraison par differents agents du GAFL à l'aide d'un protocole commun. La Figure 6 (gauche) présente la distribution des arbres selon la classe de floribondité pour le pêcher.

Pour vérifier que les photos sont suffisamment représentatives des arbres, plusieurs agents réalisant les notations en routine en verger ont attribué une note de floribondité en observant les photos d'arbres individuels. Tous ont souligné la difficulté de noter sur ces photos qui ne présentent pas bien l'arbre dans ses trois dimensions (ex. volume). L'exercice a été proposé à trois agents. L'Annexe 10: Précision de la notation de floribondité, présente les résultats de ces comparaisons. (et met en évidence la variabilité de note d'un agent à l'autre et donc la nécessité de trouver un outil qui uniformise et objective la notation. Cette étude souligne aussi que les photos ne sont pas parfaitement représentatives des arbres puisque les notes données sur images ne concordent pas toujours avec celles données à l'arbre entier en verger. La Figure 6 (droite) présente la distribution des arbres selon la classe de floribondité sur image pour le pêcher.

Pour chaque arbre les agents ont aussi donné une note pour le stade de floraison qui indique si 10, 50 ou 100% des fleurs sont ouvertes au jour de la photo.

Enfin sur 111 des arbres photographiés pour la floribondité, le nombre de fleurs par mètre de rameau a aussi été mesuré en sélectionnant quelques rameaux représentatifs de l'arbre sur un minimum de deux mètres linéaires rameaux.

Date	Lieu	Espèce	Nombre d'arbres photographiés	Condition d'éclairement	Nombre de note/ images	Nombre de mesure fleurs/m rameaux
02/03/2022	Garrigues (Avignon)	Pêcher	20	Nuageux	3	16
14/03/2022	Gotheron (Saint Marcel lès Valence)	Abricotier	30	Nuageux	3	29
17/03/2022	SEFRA (Etoile sur Rhone)	Pêcher	26	Nuageux	3	17
21/03/2022	SEFRA (Etoile sur Rhone)	Pêcher	24	Ciel bleu	3	21
24/03/2022	SEFRA (Etoile sur Rhone)	Pêcher	30	Ciel bleu	3	28



Figure 6: Distribution des pêchers selon la classe de floribondité

### 2.1.3. Annotation

Pour l'entrainement du réseau de segmentation du bois 107 images sont annotées, issues de chaque session d'acquisition en verger, pour la circonférence ou la floribondité. Ces images sont annotées avec le logiciel V7-Darwin (https://www.v7labs.com/) par deux agents du

laboratoire EMMAH et moi-même. Les images ont été annotées en distinguant deux classes : rameaux et charpentière. Pour entrainer le modèle de détection du bois ces deux classes ont été rassemblées.



Figure 7: exemple d'annotation pour la segmentation du bois

Ce jeu de données est complété par 22 images déjà annoté par le CTIFL, qui est un autre organisme de recherche publique qui s'intéresse au phénotypage des pommiers et abricotiers. Ainsi trois espèces fruitières sont représentées et les images sont issues d'au moins cinq sessions d'acquisition dans quatre vergers différents pour éviter le sur-apprentissage. Les images sont découpées ensuite en 565 patchs de 512\*512 pixels.

Pour l'entrainement du réseau de détection des fleurs, 85 images de pêchers et d'abricotiers sont annotées sur le logiciel V7-Darwin pour identifier trois classes : 'fleurs ouvertes', 'fleurs fermées' et 'fleurs fanées' (Figure 8: exemples d'annotations de fleurs). Malgré leur nombre restreint, ces images ont été sélectionnées dans chaque session d'acquisition pêcher et abricotier pour représenter la diversité des fleurs à détecter : fleurs fermées, ouvertes ou fanées, blanches, roses ou framboise, campanulées, rosacées, fleurs doubles et bouquet de mai (Annexe 5 : illustration : diversité des fleurs photographiées).



Figure 8: exemples d'annotations de fleurs

L'Annexe 6 : description des données d'entraînement pour la détection décrit la représentation des trois classes dans les données d'entrainement. Sur les 85 images annotées, 28 sont gardées pour la validation du modèle.

## 2.2. Méthodes d'analyse

### 2.2.1. Circonférence du tronc

#### 2.2.2.1. Méthode de départ par segmentation manuelle

Pour cette mesure Sylvain Jay de l'unité CAPTE a fourni un code d'analyse au début de ce projet de stage, qui est basé sur la segmentation manuelle des pixels de bois et présente de très bonnes performances sur 10 arbres sélectionnés.



Figure 9: Pipeline pour l'estimation de la circonférence proposée par Sylvain Jay(2022)



Figure 10:résultats de l'estimation de la circonférence avec la méthode d'origine sur les 10 arbres sélectionnés

Si les résultats sont très précis, (Figure 10) il faut tester la robustesse de cette méthode sur un plus grand nombre d'arbres et automatiser la segmentation des images pour que le GAFL puisse obtenir les données rapidement en entrant simplement les photos sans intervenir durant le traitement.

Pour pouvoir automatiser la mesure, un des objectifs de mon stage a été d'automatiser la segmentation du bois puis de généraliser la méthode d'analyse pour qu'elle fonctionne sur tous

les arbres. Une mesure du volume du tronc est proposée qui pourrait être moins sensible que la circonférence du tronc à l'endroit où est effectuée la mesure.

### 2.2.2.2. Méthode proposée

L'analyse reprend les étapes proposées par Sylvain Jay (Figure 9) : à partir des images LITERAL la carte de profondeur est calculée d'une part et le bois segmenté d'autre part. Ces résultats permettent d'identifier le tronc d'intérêt. La marque bleue est ensuite détectée et deux méthodes sont proposées pour le calcul du diamètre du tronc en pixel. La résolution de l'image au niveau du tronc est déterminée avec l'image stéréo pour obtenir la circonférence en millimètres.

### 2.2.2.3. Segmentation du bois

Un modèle Deep Learning de segmentation pour le bois a été proposé qui permet, si assez d'images sont annotées dans des contextes différents, une segmentation moins sensible aux conditions d'acquisition de l'image (luminosité, arbre avec feuille/sans feuilles-fleurs, distance à la caméra, espèce de l'arbre...) qu'une segmentation par analyse de couleur par exemple.

Un module disponible dans le groupe de recherche CAPTE permet ((1) de préparer des données en les augmentant, (2) d'entrainer des modèles de segmentation sémantique, (3) de calculer les performances des modèles entrainés et la prédiction.

Augmenter les données consiste à appliquer différentes fonctions (pour modifier la luminosité ou les contrastes, ajouter du bruit ou du flou par exemple) aux images d'entrainement pour agrandir artificiellement le jeu d'entrainement, être moins dépendant des conditions d'acquisition et éviter le sur-apprentissage. Le jeu de données étant assez réduit pour la segmentation du bois du fait de la difficulté d'annotation, cette étape est très importante. L'augmentation des données, comprise dans le module de CAPTE est codée à partir de la librairie Albumentations [10].

L'entrainement des modèles consiste à déterminer le type de réseau, son architecture, les hyperparamètres et les fonctions d'activation et de "loss"qui lui sont associées. L'annexe 1 présente les différentes définitions des fonctions utilisées pour ce réseau : un modèle U-Net est sélectionné (présenté en Annexe 3: Réseau Unet pour la segmentation), performant pour la segmentation sémantique des végétaux, il utilise la fonction d'activation sigmoïde, la fonction perte DiceLoss, et est optimisé par l'algorithme d'Adam. L'initialisation des poids est faite à partir d'un premier apprentissage sur la base de données imagenet. Le pas d'apprentissage (learning rate) est le coefficient qui pondère l'erreur lors de la mise à jour les paramètres du réseau : il est initialisé à 0.001. La taille d'un batch est le nombre d'échantillons (ici de patchs 512\*512 pixels) utilisés pour calculer l'erreur avant une mise à jour des paramètres du réseau, ici un batch est égal à 4 patchs. Une epoch correspond à un passage de tout le jeu de données d'entrainement dans le réseau. Le réseau est entrainé sur 90 epochs à l'aide de 113 des images annotées, 16 etant gardées pour la validation.

Les performances du modèle de DeepL sont évaluées par la métrique Intersection Over Union (IOU).

2.2.2.4. Détection du tronc étudié

L'arbre d'intérêt est l'arbre au premier rang le plus proche du milieu de l'image. Le premier rang est obtenu à partir du masque de segmentation du bois et de la carte de profondeur obtenue avec la stéréovision.



Figure 11: étapes pour l'identification de l'arbre d'intérêt

Les codes d'extraction du tronc d'intérêt et de stéréovision ont été fournis par Sylvain Jay, et ont été très peu modifiés. La carte de profondeur (calculée comme la distance z des points de l'image à la caméra) est obtenue par l'algorithme SGBM de la librairie opencv [11] (expliqué en Annexe 3 : Stéréovision pour calculer la carte 3D d'une image par algorithme Semi-Global Block Matching). Les matrices de calibration des caméras de stéréovision sont intégrées dans le système LITERAL.

Après avoir identifié le premier rang, la partie supérieure de l'image est enlevée (pour éliminer les petites branches et ne garder que les pixels susceptibles d'appartenir à un tronc) et la position des troncs est identifiée sur les colonnes ayant le plus de pixels bois. Enfin le tronc le plus centré est gardé (Figure 11).

### 2.2.2.5. Estimation de la vigueur de l'arbre

La marque bleue, qui sert de repère pour la mesure manuelle interannuelle de circonférence, est d'abord détectée sur le tronc par analyse des couleurs RGB dans l'image : Elle correspond aux pixels du tronc qui sont tels que  $\frac{B-R}{B+R} > 0.15$  (Figure 12). Ensuite, deux méthodes sont proposées, décrites ci-après, pour estimer la vigueur de l'arbre. La première méthode se rapproche de la mesure au mètre ruban pour la mesure de la circonférence tandis que la seconde méthode propose d'accéder à un deuxième trait, en principe plus robuste et plus représentatif de la croissance du tronc, qui est le volume de tronc sur une section de 15cm.



Figure 12: sections du tronc pour l'estimation de la circonférence selon les méthodes

#### Méthode 1 : Estimation de la circonférence du tronc au niveau de la marque bleue

La première méthode, proposée par Sylvain Jay, sélectionne les contours du tronc sur la hauteur de la marque bleue. Elle fait l'hypothèse que le tronc est un cylindre parfait et trace deux droites sur les contours pour diminuer l'influence des aspérités du tronc. Un seul diamètre est calculé dans ce cas, il correspond à la distance entre les deux droites.



Figure 13: méthode 1 : estimation de la circonférence sur la marque bleue

# Méthode 2 : Estimation de la circonférence du tronc et du volume sur une section de 15 cm

La seconde méthode sélectionne le tronc sur 15 cm centrée sur la marque bleue. Ces 15 cm sont découpés en sous-sections de la hauteur d'un pixel. Le tronc n'est plus considéré comme un cylindre parfait, en revanche chaque section est considérée comme circulaire. La circonférence est calculée par l'estimation du diamètre pour chacune de ces sections et la valeur médiane est gardée. Les circonférences estimées prennent en compte l'inclinaison du tronc.



Figure 14: Méthode 2 : estimation de la circonférence et du volume sur 15cm de hauteur

A partir des circonférences estimées le volume du tronc sur les 15cm de hauteur est également calculé comme la somme de toutes les sections mesurées.

Les diamètres en pixel sont ensuite convertis en diamètre réel selon la distance entre la caméra et le tronc, estimé avec la stéréovision (Annexe 4 : Calcul de la résolution au niveau du tronc).

Les méthodes proposées permettent donc une estimation de la circonférence ou du volume des troncs qui permettrons de suivre la vigueur des arbres.

### 2.2.3. Floribondité et date de floraison

Pour l'analyse de la floribondité la première étape est de détecter les fleurs sur les photos pour ensuite analyser leur répartition ou leur densité ou encore estimer le stade de floraison.

### 2.2.3.1. Détection des fleurs par deep learning

Pour la détection des fleurs, nous avons utilisé MaskRCNN, un modèle de Deep Learning dérivé des réseaux fasterRCNN qui permettent d'identifier des boîtes autour des objets recherchés. MaskRCNN ajoute en parallèle la segmentation de ces objets, plus de détails sur ce type de réseau sont présentés en Annexe 2 : réseau MaskRCNN. Bien que ce type de réseau soit moins rapide qu'un modèle de détection d'objet comme YOLO souvent utilisé dans des applications temps réel, MaskRCNN répond mieux à nos attentes car il présente de meilleures performances pour la détection de petits objets (ici les fleurs) et quand les objets sont proches les uns des autres [12]. Pour l'analyse, seules les box en sortie seront finalement utilisées.

Comme pour la segmentation du bois, le module pour l'entrainement de réseaux de détection codé à partir de la librairie mmdetection [13] proposé par l'équipe CAPTE est utilisé. Les annotations sont chargées sous le format COCO pour entrainer le modèle. La taille d'un batch est de 2 patchs de 512\*512pixels, le réseau est entrainé sur 80 epochs.

Les 57 images d'entrainement sont découpées en 285 patchs pour entrainer le réseau à détecter trois classes : "fleur ouverte", "fleur fermée", "fleur fanée". Cette dernière classe est très peu représentée dans les images d'entraînement (annexe 1).

# 2.2.3.2. Caractérisation de la floribondité : rapport du nombre de fleurs par volume de bois

Pour estimer le nombre de fleurs par volume de bois il ne faut prendre en compte que les rameaux mixtes, c'est-à-dire porteur de fleurs. Dans un premier temps il a été envisagé d'entraîner un réseau pour distinguer le tronc et les charpentières des rameaux mixtes, mais le temps requis pour acquérir et annoter suffisamment d'images n'était pas compatible avec la durée de ce stage. Nous avons donc développé une approche basée sur de l'analyse d'image classique en utilisant la morphologie mathématique pour la détection des rameaux mixtes.

Après avoir segmenté le bois avec le réseau U-Net entrainé précédemment pour estimer la circonférence des troncs (partie Segmentation du bois) les plus grosses branches, considérées comme un tronc ou une charpentière sont gommées par opération morphologique white top-hat (image d'origine-ouverture). Les branches étant généralement orientées verticalement dans l'image, un rectangle de 100\*10 pixels est utilisé comme élément structurant pour filtrer les branches sur leur épaisseur.



Figure 15: Calcul de la floribondité

2.2.3.3. Caractérisation de la floribondité : prise en compte de la distribution des fleurs sur les rameaux

La note de floribondité attribuée aux arbres par le GAFL qualifie la quantité de fleurs et leur homogénéité de répartition dans l'arbre. L'hypothèse est faite que la distance entre fleurs augmente plus graduellement si leur répartition est homogène et leur densité élevée. Pour analyser la distribution des fleurs dans un arbre, il a été proposé de calculer, pour chaque fleur, la distance à chacune des autres fleurs(distance en pixel sur l'image 2D).

La valeur médiane et les quartiles 10 et 90 de la distance entre deux fleurs voisines au nième rang sur l'arbre sont ensuite calculées (Figure 16) et on utilise le résultat obtenu pour classer les courbes en fonction des notes attribuées aux arbres en verger ou sur les images elles-mêmes (Figure 17)



Figure 16:méthode de calcul des distances entre fleurs et exemple de courbe de distribution des distances pour un arbre avec une note floribondité de 4



Figure 17: superposition des courbes de distribution des distances entre fleurs évaluées à partir de la notation visuelle en verger (à gauche) ou des images (à droite), chaque couleur de courbe est associée à une note allant de 1 à 4

Des différences sensibles sont observées entre les notes attribuées aux images et celles attribuées en verger. La répartition par classe est assez différente (seulement 3 arbres notés 1 par notation sur image contre 12 arbres en verger). Cette différence est essentiellement due à un problème d'échantillonnage qui se réduit à une partie de l'arbre pour la notation à partir d'images alors que pour la notation en verger, l'ensemble des rameaux de l'arbre sont considérés. Nous choisirons par la suite d'utiliser la notation en verger comme référence car elle est plus représentative de chaque arbre. Elle permet ainsi de mieux séparer les cas extrêmes (note de 1 et 4). Il n'y a pas assez de données pour faire un apprentissage supervisé des classes en fonction de ces courbes mais une classification non supervisée par l'algorithme agglomerative\_clustering de sklearn [14] est testée pour évaluer le potentiel de ces courbes à représenter la classe de floribondité.

L'algorithme prend en paramètre le nombre final de classes souhaité (e.g. 4), et rassemble récursivement les courbes par paires jusqu'à l'avoir atteint. Les groupes sont rassemblés de sorte à minimiser la variance intra-groupe et utilise la distance euclidienne.

### 2.2.3.4. Estimation du stade de floraison

Le réseau étant entraîné pour détecter les trois classes fleurs ouvertes, fleurs fermées, fleurs fanées, il permet d'estimer la proportion de fleurs ouvertes et donc le stade de floraison.

# **3.**Résultats

Cette partie présente les résultats obtenus pour les réseaux de détections et de segmentation et pour les analyses de chaque trait présenté dans la partie précédente.

#### Performances des méthodes de deep learning 3.1. pour la segmentation et la détection

#### 3.1.1. Α. Segmentation du bois

La Figure 18 présente les performances du réseau de segmentation (IoU et fonction perte). Il est testé sur 16 images de validation soit 80 patchs de 512\*512 pixels, prises dans toutes les sessions d'acquisitions. Les courbes roses évaluent le réseau en fonction des itérations (epochs) sur les données de validation, et les bleues sur les données d'entrainement.



Figure 18: Evolution des performances du réseau de segmentation du bois au cours de son apprentissage



3

Figure 19: segmentation du bois par deep learning, sur pêcher en janvier (1) et en mai (2) et sur abricotier (3)

Le réseau converge au bout de 90 itérations, après une stabilisation à environ cinquante itérations et atteint une IOU de 0.72 sur les données de validation. Ces performances restent cependant légèrement optimistes car si les images de validation n'ont pas servi à l'entrainement, il existe toujours au moins une image correspondant à la même session d'acquisition qui fait partie du jeu d'apprentissage. Le jeu de données de validation n'est donc pas totalement neutre.

### 3.1.2. B. Détection des fleurs

Le modèle est évalué sur 28 images de 768\*768 pixels qui représentent en partie la diversité des fleurs à détecter, sur ces images l'IOU (équation 2) obtenue pour les fleurs fermées est de 0.48 et de 0.49 pour les fleurs ouvertes (Annexe 8 : performance du réseau de détection sur les données test). Sur les images de validation 67% des fleurs sont détectées. Les fleurs fanées, très peu représentées dans le jeu d'entrainement et seulement sur une image dans le jeu de test, sont détectées comme des fleurs ouvertes.



Figure 20: exemple de détection des fleurs avec le réseau Mask-RCNN

## 3.2. Estimation de la circonférence du tronc

La Figure 21 présente les performances des deux méthodes d'estimation de la circonférence du tronc décrites en 2.2.2.4 (au niveau de la marque bleue, vs sur section de 15cm) en comparaison



#### Figure 21: Estimation de la circonférence ; influence de la méthode de segmentation

Les circonférences estimées sur l'image sont systématiquement biaisées par rapport à la circonférence mesurée en verger pour les deux méthodes. Un biais similaire est observé avec les deux méthodes appliquées sur des images segmentées à la main (huit images de la session d'acquisition de janvier et huit de mai aux garrigues, en orange sur la Figure 21 ce qui indique qu'il ne semble pas dû à la phase de segmentation automatique.



Figure 22: estimation du biais

L'origine de ce biais restant incertaine, nous avons choisi de proposer une correction statistique du biais pour chaque méthode. Celui-ci est d'abord évalué sur une sélection d'arbres (Figure 22) puis appliqué à l'ensemble du jeu de données (Figure 23:Estimation de la circonférence pour l'ensemble des arbres photographiés après segmentation par deep learningFigure 23).



Figure 23: Estimation de la circonférence pour l'ensemble des arbres photographiés après segmentation par deep learning

Sur les quelques arbres pour lesquels les photos et mesures de circonférence ont été faites en janvier et en mai, la Figure 24 présente la croissance de la circonférence (gauche) et du volume (droite) calculés sur image en fonction de celle mesurée en verger.



Figure 24: Croissance de la circonférence (à gauche) et du volume (à droite) entre janvier et mai 2022 estimés par analyse d'image en fonction des données in situ mesurées au mètre ruban

# 3.3. Floribondité : rapport du nombre de fleurs par volume de bois

Dans un premier temps la floribondité est estimée comme le rapport du nombre de fleurs par le volume de bois. Pour chaque arbre, une photo est choisie, jugée visuellement la plus représentative de l'arbre. La Figure 25 présente les résultats d'estimation de la floribondité sur les 101 pêchers photographiés pendant les trois sessions d'acquisition à la SEFRA et la session aux Garrigues. Les résultats obtenus sur les images entières n'étant pas satisfaisants (forte dispersion des points, Figure 25 gauche), nous avons montré l'influence des rameaux appartenant aux arbres voisins en les masquant manuellement sur la photo (Figure 25, droite).





Figure 25: Relation entre les estimations du nombre de fleurs par volume de bois sur pêchers de manière manuelle et par analyse d'image

Pour chaque arbre deux ou trois photos ont été prises pour le représenter dans son ensemble : la Figure 26 présente l'estimation moyenne de la floribondité sur toutes les photos disponibles pour chaque arbre (2 à 4 selon les arbres) en fonction de la floribondité estimé sur l'image qui semblait la plus représentative, utilisée pour la Figure 25, pour les trois sessions d'acquisition à la SEFRA.



Figure 26: Estimation nombre de fleurs par volume de bois sans voisins sur pêchers estimé par une moyenne sur plusieurs images en fonction de la valeur obtenue à l'aide d'une seule image

Les floribondités estimées sont très corrélées ( $R^2=0.87$ ), montrant que l'échantillonnage de l'arbre à l'aide d'une seule image semble suffisant.

La floribondité est estimée avec la même méthode pour les photos d'abricotiers en fleur prises à Gotheron (Figure 27).



Figure 27: estimation du nombre de fleurs par volume de bois sur abricotier

Pour ces arbres le même protocole de comptage que sur pêcher a été appliqué en verger : comptage du nombre de fleurs sur certains rameaux et mesure de la longueur des rameaux qui

portent les fleurs. Les abricotiers n'ont pas la même architecture que les pêcher et les fleurs sont souvent portées par des bouquets de mai), ce protocole ne rend donc pas bien compte de la densité de fleurs dans l'arbre pour cette espèce. Dans la suite, les résultats sur la floribondité ne seront donc présentés que pour les pêchers.

# 3.4. Floribondité prenant en compte l'homogénéité de répartition des fleurs dans l'arbre

L'algorithme de scikit-learn agglomérative Clustering permet de diviser les arbres en quatre classes en fonction des courbes de distribution de fleurs. A chacune de ces classes une note 1, 2, 3 ou 4 est ensuite attribuée selon leur position (Figure 28). La matrice de confusion est calculée avec les notes données en verger et avec les notes données aux photos par les agents.



*Figure 28: Etablissement d'une note proposée par clustering de courbes* 

Tableau 2: Matrice d	e confusion note pa	er clustering, note en	verger et, note sur	· image

Matrice de c agglomérativ clustering verger	Aatrice de confusion : gglomérative elustering vs note vergerPrécision : 0,48				Matrice de c agglomérativ clustering image	onfusion : re vs note	Précision	: 0,38	
	Note clustering					Note cluste	ering		
Note verger	1	2	3	4	Note image	1	2	3	4
1	8	4	0	0	1	2	1	0	0
2	12	22	8	2	2	14	13	3	0
3	0	9	9	6	3	4	16	13	8
4	1	4	1	5	4	0	5	5	6

La classification par clustering ne semble pas bien corréler avec la notation en verger ou sur image de manière globale, toutefois les classes extrêmes (1,4) semblent mieux correspondre

entre les deux méthodes que les classes intermédiaires (2,3) (Tableau 2) . La notation visuelle sur image a une précision par rapport à la notation verger de 0.45 à 0.49 selon les notateurs (Annexe 10: Précision de la notation de floribondité).

## 3.5. Stade de Floraison

La Figure 29 présente, pour les 101 pêchers photographiés, le stade de floraison attribué à l'arbre au jour de la photo par les agents du GAFL par rapport à la proportion de fleurs ouvertes sur l'ensemble des fleurs détectées par le réseau de deep learning.



Figure 29: Estimation du stade de floraison



Figure 30: Images correspondant à des décalages importants entre estimation visuelle et par analyse d'image du stade de floraison, identifiés en figure 29

Le stade de floraison estimé sur l'image est continu contrairement à la note donnée par le GAFL, les deux variables ont un coefficient de corrélation de 0.75(Figure 29). Les valeurs estimées par le modèle qui ne sont pas cohérentes avec les notes données en verger semblent cohérentes avec le stade de floraison visible sur les images (Figure 31) donc soit les photos n'échantillonnent pas bien l'arbre soit la note de floraison en verger n'est pas correcte.

Les méthodes proposées ont permis d'estimer la circonférence des troncs d'abricotier et pêcher. Elles permettent aussi d'évaluer le stade de floraison et la floribondité des pêchers assez précisément mais doivent être encore adaptées pour l'étude de la floribondité des abricotiers.

# **4.Discussion**

## 4.1. Les images RGB: de nouveaux vecteurs prometteurs pour le phénotypage

En six mois, un premier jeu de données pour le phénotypage des prunus par proxi-détection RGB a été rassemblé et des méthodes ont été proposées pour estimer les traits de vigueur et de floribondité des arbres.

Les performances sont assez satisfaisantes : l'estimation de la circonférence à l'image corrèle assez bien avec la circonférence mesurée en verger ( $r^2=0.66$ , Figure 23) avec une erreur médiane absolue après correction du biais de 13.5mm et 9.5mm selon les méthodes. La seconde méthode proposée permet une estimation de la circonférence plus précise et plus représentative du tronc que la première puisqu'elle prend en compte une plus grande section.

Le réseau MaskRCNN de détection des fleurs permet une bonne estimation du stade de floraison, les valeurs aberrantes s'expliquent surtout par une mauvaise représentation de l'arbre avec une seule photo, le modèle semble toutefois cohérent avec les images. Il faudrait améliorer le protocole d'échantillonnage pour acquérir plusieurs images de chaque arbre afin de moyenner les valeurs de floribondité obtenues pour mieux représenter l'arbre dans son entièreté. La méthode n'est toutefois aujourd'hui pas encore entièrement automatisée puisque les arbres voisins ont été masqués manuellement.

L'estimation du nombre de fleurs par pixel bois a un coefficient de corrélation de 0.47 (Figure 25) avec le nombre de fleurs par mètre de rameaux mixtes (avec voisins masqués). Ces résultats permettent d'espérer une classification correcte des arbres par analyse d'image sur ce critère. Les mesures de floribondité sur une image ou sur plusieurs sont corrélées à 0.87(Figure 26), ce qui permet de rester confiant sur la répétabilité de la méthode.

Pour l'abricotier en revanche, la floribondité n'étant pas estimée de la même manière que pour le pêcher, il faudrait, pour être plus précis, adapter les mesures terrain en tenant compte par exemple du nombre de bouquets de mai par longueur de charpentière puis adapter l'analyse pour proposer une variable qui puisse bien représenter leur floribondité.

Les méthodes proposées par analyse d'image ont l'avantage d'être automatiques, donc de ne pas introduire le biais du jugement du notateur, elles sont donc répétables et objectives. Les annexes 9 et 10 montrent que les notations manuelles ne le sont pas. Pour la circonférence la précision du mètre ruban n'est pas encore évaluée mais une étude est en cours et les premières données (présentées en Annexe 9: précision de la mesure de circonférence en verger) montrent que selon la hauteur à laquelle est placé le mètre ruban, sur un même tronc il peut y avoir un écart de 42mm entre les circonférences mesurées (arbre 1\_12). Les classes de floribondité sont très dépendantes du notateur, l'annexe 10 montre que dans 40 à 50% des cas les notateurs ne sont pas d'accord entre eux. Cette incertitude sur les mesures manuelles complique d'ailleurs l'analyse d'image parce que la référence pour valider les modèles comporte une variabilité que l'analyse ne peut pas prendre en compte (celle du notateur). Pour la classification des arbres selon la floribondité, le modèle est entrainé sur les notes vergers mais les notes images ne sont pas toujours classées de la même manière que les notes verger. Pour l'estimation de la circonférence on compare, pour la deuxième méthode au moins, une circonférence estimée sous l'hypothèse d'un tronc cylindrique, sur une section de 15cm de tronc avec une circonférence

mesurée à un endroit du tronc. La variable proposée peut permettre de suivre la vigueur de l'arbre mais pour évaluer sa précision il faudrait la comparer à un diamètre pris face à l'arbre, correspondant à l'angle des photos.

L'analyse d'image propose en plus des nouvelles variables continues comme le nombre de fleurs par rapport au volume de l'arbre ou l'estimation du volume du tronc qui complètent les notations manuelles discrètes. L'analyse d'image permet aussi des mesures moins contraignantes, l'acquisition des images peut ne pas être à pleine floraison par exemple, et il sera possible d'extraire plusieurs traits d'une image. Les méthodes proposées ont des protocoles d'acquisition simples et rapides et ne travaillent qu'en photo RGB dans le rang, contrairement à la littérature qui demandait des images par drone ou des données LIDAR pour la floribondité ou un protocole d'acquisition compliqué pour la circonférence. Ces méthodes seront donc bien adaptées pour le phénotypage haut-débit car elles pourraient permettre de gagner du temps sur les mesures et donc de faire des relevés plus régulièrement.

Enfin l'analyse d'image permet d'avoir des mesures traçables et donc de refaire les analyses à posteriori si les algorithmes sont améliorés et/ou si la base de données est élargie.

# 4.2. Perspectives et améliorations des méthodes développées

Si les résultats sont prometteurs, les méthodes ont encore besoin d'être améliorées car la classification des arbres sur la floribondité à partir des images ne reflète pas celle que propose le GAFL en verger, et les estimations de circonférences ne sont pas suffisamment précises pour suivre une croissance de quelques millimètres par mois comme le montre la Figure 24.

Il serait déjà possible de gagner en précision en améliorant les réseaux en annotant plus de données, avec plus de conditions d'acquisitions différentes (luminosité, type de troncs...) mais aussi en cherchant les paramètres d'apprentissage optimaux (Learning rate, taille de batch, fonction coût...).

Pour la détection il faudrait surtout annoter des images représentant des fleurs fanées, classe très peu représentée pour l'instant (Annexe 6 : description des données d'entraînement pour la détection) et des fleurs pompons (pétales surnuméraires) qui sont difficiles à annoter et mal détectées. Pour ce genre de fleur et pour les bouquets de mai, il est difficile de faire la distinction entre les fleurs voisines : ajouter une classe 'groupe de fleur' pourrait simplifier l'annotation et permettrait de gagner en précision.

Pour la mesure de la circonférence la résolution au niveau du tronc est autour de 0.7mm/pixel, donc un pixel d'erreur de chaque côté du tronc sur la segmentation donne une erreur de 4.5mm (= 2 pixels \*0.7\*pi) environ sur la circonférence. La précision du réseau de segmentation est donc importante.

Annoter davantage d'images pour la segmentation pourrait aussi permettre de faire la distinction 'rameau mixte', 'charpentière' et donc gagner en précision sur l'analyse de la floribondité pour laquelle cette distinction est faite par opération morphologique seulement pour l'instant.

Il faudrait aussi collecter plus de données pour avoir des algorithmes plus robustes et mieux adaptés à chaque cas. Pour l'abricotier, qui a été moins bien caractérisé dans cette étude et qui diffère du pêcher par la répartition de ses fleurs, il n'y a pas encore assez de données pour proposer une bonne étude de la floribondité. Avoir plus de données pêcher permettra aussi une meilleure classification des arbres avec des méthodes supervisées par exemple. Celles-ci ne sont pas encore applicables à cause de la taille limitée du jeu de données (seulement quelques arbres de références pour les notes 1 et 4 par exemple (Figure 6).

Pour améliorer les modèles il faudrait aussi mieux exploiter la stéréovision. L'algorithme SGBM d'open cv, utilisé pour l'instant, est assez sensible à la luminosité, il est plutôt adapté aux images d'intérieur avec peu de texture et ne donne pas de très bons résultats sur les images de circonférence prises en mai par exemple quand les arbres ont beaucoup de feuilles, ou pour les images de floribondité. Un nouvel algorithme de stéréovision plus robuste et plus précis, comme l'algorithme block-Matching [15] qui est pourrait être mieux adapté pour les images avec beaucoup de texture comme celles avec les arbres en fleurs ou avec des feuilles, permettrait de gagner en précision sur l'estimation de la circonférence. La stéréovision pourrait alors aussi être utilisée pour pondérer le nombre de pixels bois par leur distance à la caméra pour la mesure de la floribondité. La distance réelle entre les fleurs pourrait également être mesurée, et plus seulement la distance sur l'image 2D, les données de distribution des fleurs dans l'arbre seraient alors plus proches de la réalité et la classification des arbres selon leur floribondité serait peut-être meilleure.

La carte de profondeur pourrait permettre d'éliminer au moins en partie les arbres voisins qui perturbent l'analyse de la floribondité, mais il arrive que les branches des arbres se croisent et dans ce cas la stéréovision ne pourra pas suffire.

Enfin pour améliorer et valider les modèles il faudra répéter les acquisitions spatialement, en prenant plusieurs photos du même arbre pour chaque trait et temporellement pour suivre et lisser l'évolution des traits dans le temps pour chaque arbre.

# **5.CONCLUSION**

Ainsi, l'objectif de ce projet était d'évaluer la possibilité de faire du phénotypage des arbres fruitiers à partir d'image RGB prises dans le rang des vergers à l'aide de l'outil LITERAL/PHENOMAN. Deux traits ont été étudiés sur le pêcher : la vigueur et la floribondité des arbres, les méthodes proposées sont prometteuses mais manquent encore de précision pour un emploi routinier. Les résultats mettent en évidence les avantages du phénotypage par image RGB sur le phénotypage manuel : un phénotypage objectif, répétable et traçable et qui propose de nouvelles mesures qui ne sont pas accessibles manuellement. Il sera intéressant d'évaluer le système sur d'autres traits comme la teneur chlorophylle ou la détection de symptômes de maladies, et de les comparer avec d'autres méthodes d'acquisition comme le phénotypage par drone.

# **Bibliographie**

- [1] https://www.un.org/fr/chronicle/article/nourrir-la-planete-de-maniere-durable.
- [2] Thomas, Analyse des formes de troncs par photogrammétrie pour caractériser la qualité des bois, Application au pin sylvestre de Lozère, 2020.
- [3] Brun, Suivre la contamination des fleurs par monilinia laxa, 2021.
- [4] Lopez, An\_efficient\_RGB-UAV-based\_platform\_for field almond tree phenotyping: 3D architecture and flowering traits, 2019.
- [5] Comas, Automatic apple tree blossom estimation from UAV RGB imagery, 2019.
- [6] Horton, Peach Flower Monitoring Using Aerial Multispectral Imaging, 2017.
- [7] Underwood, Mapping Almond Orchard Canopy Volume Flowers Fruit, 2016.
- [8] Vanbrabant, Pear Flower Cluster Quantification using RGB Drone Imagery, 2020.
- [9] Dias, Multispecies fruit flower detection using a refined semantic segmentation network, 2018.
- [10] https://github.com/albumentations-team/albumentations.
- [11] https://docs.opencv.org/3.4/d2/d85/classcv\_1\_1StereoSGBM.html.
- [12] Sanchez&al, A review: Comparison of performance metrics of pretrained models for object detection using the TensorFlow framework, 2020.
- [13] https://mmdetection.readthedocs.io/en/latest/.
- [14] https://scikitlearn.org/stable/modules/generated/sklearn.cluster.AgglomerativeClustering.html.
- [15] Xianxiang, 3D Reconstruction Analysis Based on SGBM Algorithm and BM Algorithm, 2019.
- [16] Gul, Sustainable Materials for Oil and Gas Applications, 2021.

# ANNEXES

### Annexe 1 : Définitions utiles pour les réseaux de Deep Learning

Un réseau de deep learning est composé de plusieurs couche successives de neurones connectées entre elles. Chaque couche reçoit une combinaison linéaire des sorties de la couche précédente et leur applique une fonction non linéaire (fonction d'activation) avant de les envoyer à la couche suivante. Les paramètres du réseau sont les coefficients des combinaisons linéaires entre chaque couche (poids et biais). Lors de la phase d'apprentissage le modèle ajuste ses paramètres pour répondre le mieux possible à la tache demandée sur les données d'entrainement, l'algorithme utilisé pour cette mise à jour est appelé algorithme d'optimisation et met à jour les poids par rétropropagation du gradient. La rétropropagation du gradient peut être faite sur l'ensemble des données d'entrainement : en Full-batch (le réseau propose une prédiction pour chaque échantillon d'entrainement et l'erreur sur chaque échantillon est utilisée pour faire la mise à jour des paramètres) les calculs sont alors très longs et la convergence n'est pas certaine. En mini-batch les données sont découpées en groupe d'échantillons (batch), les paramètres sont mis à jour après le passage de chaque batch en utilisant l'erreur sur chaque échantillons du batch. Enfin la rétropropagation peut être stochastique : la mise à jour des paramètres est faite après le passage de chaque batch en utilisant l'erreur moyenne sur le batch. Un batch est donc composé d'un ou plusieurs des échantillons d'entrainement qui va passer dans le réseau et sur lequel l'erreur du réseau va être calculé avec la fonction perte. Cette erreur est ensuite pondérée par le pas d'apprentissage pour mettre à jour les paramètres par rétropropagation du gradient : après chaque passage d'un batch chaque paramètre est calculé, en partant de ceux de la dernière couche, de façon à minimiser la fonction perte. Une epoch correspond à un passage de toutes les données d'apprentissages dans le réseau.



Pour la segmentation, il faut attribuer à chaque classe un pixel, pour cela des réseaux de convolution sont utilisés. Les réseaux de convolutions sont divisés en deux blocs : un premier bloc extrait les features des images (contour, point ou zone d'intérêt qui permettra de distinguer deux classes) avec des filtrage convolutifs. En sortie de ce premier bloc il y a donc des 'features maps' qui seront en entrée du second bloc de deep classique. Sur la dernière couche les probabilités de chaque classe sont calculées en utilisant une **fonction d'activation**.

Exemple de fonction perte : fonction qui estime l'erreur du réseau au passage de chaque batch, erreur utilisée pour mettre à jour les paramètres du réseau.

$$Dice_{loss} = 1 - \frac{2 * \sum_{pixels} classe \ predité * classe \ réelle}{\sum_{pixels} classe \ predite + \sum_{pixels} classe \ réelle}$$
[1]

$$cross\ entropy\ loss = -\sum_{classe\_i} classe\ r\acute{e}\acute{e}le * \log(p(classe\_i))$$
[2]

$$L1_{loss} = mean(L), where L = \{l_1, \dots, l_N\}, l_n = |x_n - y_n|,$$
  
x est la classe predite et y la classe réelle [3]

Exemple de fonction d'activation :

$$sigmoïde(x) = \frac{1}{1 + e^{-x}}$$
[4]



Exemple de métriques (fonctions permettant de mesurer les performances du réseau) :

$$Precision = \frac{VP}{VP + FP} \ et \ Rappel = \frac{VP}{VP + FN}$$
[5]

$$IOU = \frac{\text{Precision * Rappel}}{\text{Precision + Rappel} - \text{Precision * Rappel}} = \frac{VP}{VP + FP + FN}$$
[6]

Où VP désigne les pixels bois prédits bois, FP les pixels background prédits bois et FN les pixels bois prédits background.

Exemple d'algorithme d'optimisation :

Descente de gradient stochastique : Chaque paramètre x est actualisé après le batch k :

$$x[k+1] = x[k] - alpha[k]\Delta f(x[k])$$
<sup>[7]</sup>

Ou alpha est le pas d'apprentissage et  $\Delta f$  le gradient de la fonction coût.

Algorithme d'Adam : L'algorithme d'Adam est une rétropropagation du gradient stochastique mais qui met à jour les paramètres d'apprentissage (ex pas d'apprentissage) à chaque itération.



Les différentes étapes du MaskRCNN :

1 : Un réseau de convolution transforme l'image d'entrée en une carte des caractéristiques (features) qui sera en entrée de la couche suivante

2 : Un réseau de proposition de région divise la carte des caractéristiques en régions et analyse un objet est présent ou non dans chacune des régions

3 : Sur les régions proposées par l'étape précédente le réseau propose une classification (softmax) et une box. Dans notre cas la fonction perte pour utiliser pour la classification est la cross-entropy (annexe 1) et pour la détection par box la L1loss

4 : A partir des régions d'intérêt proposées par l'étape 2 dans lesquelles un objet est détecté par l'étape 3 le modèle génère des masques de segmentation

## Annexe 3: Réseau Unet pour la segmentation

Pendant ce stage un module d'entrainement de deep learning a été utilisé, je ne suis donc pas entrée précisément dans le code et les détails des réseaux choisis mais je présente ici les structures utilisées.

Les réseaux de type Unet ont d'abord été développés pour la segmentation sémantique d'images médicales mais se sont révélés performant pour la segmentation des végétaux. Unet fonctionne comme un réseau de classification pour chaque pixel de l'image.

Un reseau Unet fonctionne en encodeur-décodeur. L'encodeur capture le contexte de l'image, il s'agit d'un assemblage de couche de convolution qui extraient une carte de caractéristiques (feature map) de l'image qui sera en entrée du décodeur. Le décodeur est le symétrique de l'encodeur et propose en sortie l'image segmentée (Figure 31).



Figure 31: architecture UNET

L'architecture de l'encodeur est appelée Back-bone, plusieurs architectures sont possibles proposées par py-torch et pour ce modèle l'architecture resnet18 et choisie, elle a déjà donné de bons résultats sur les autres projets de segmentation sémantique de l'équipe CAPTE. Au début de l'entrainement les paramètres du réseau sont initialisés par transfert learning (transfert d'apprentissage) sur les données imagenet. Le transfert learning permet de réutiliser les poids d'un modèle de même architecture entrainé pour une tache similaire à celui développé, pour un cas comme ici où peut de données sont disponibles pour l'entrainement c'est une étape très importante. Imagenet classes plus de 14 millions d'images en 1000 catégories, ce jeu de données constitue donc une bonne base pour l'apprentissage.

## Annexe 3 : Stéréovision pour calculer la carte 3D d'une image par algorithme Semi-Global Block Matching

La stéréovision est une méthode de calcul des coordonnées 3D d'une image dans le référentiel de la caméra. Elle utilise deux cameras fixées l'une par rapport à l'autre et déduit la position

des objets de l'image par triangulation à partir des correspondances de points entre les images prises par les deux cameras. [16]



Donc la disparité d, qui est la distance entre les points correspondants dans les deux images est :

$$d = (u_L - u_R) = f \frac{b}{z_A}$$
[10]

Etapes pour la stéréovision par SGBM:

1 : la calibration des caméras : détermine les paramètres internes (ex distance focale, paramètres de la lentille) et externes (ex : distance b) des caméras.

2 : A partir des paramètres de calibration des caméras les images sont corrigées pour avoir le même alignement.

3 : L'algorithme cherche les pixels dans les deux images qui représentent le même sujet :

1 : Filtre l'image pour normaliser la luminosité et les contrastes

2 : Recherche des correspondances le long des lignes epipolaires (ligne qui coupe les plans epipolaires de chaque camera, plan epipolaire : plan qui passe par un point objet de la scène observée et par les centres de projection des deux cameras).

3 : filtrage pour éliminer les mauvaises correspondances

4 : calcul de la disparité avec les formules données ci-dessus.

### Annexe 4 : Calcul de la résolution au niveau du tronc

La résolution de l'image donne la correspondance entre la taille en pixel d'un objet dans l'image et sa taille réelle.

Pour convertir le diamètre du tronc estimé en pixel dans l'image en diamètre réel il faut donc connaitre la résolution de l'image pour les objets situé à la distance du tronc.



$$Resolution = \frac{Taille \ R\acute{e}elle}{Taille \ en \ pixel} = \frac{FOV}{nbr \ de \ pixel}$$
[11]

$$FOV = \frac{taille \ du \ capteur * distance \ de \ travail}{distance \ focale}$$
[12]

$$Resolution = \frac{taille \ du \ capteur * distance \ a \ l'objet \ consider \ e}{distance \ focale * nombre \ de \ pixel}$$
[13]

# Annexe 5 : illustration : diversité des fleurs photographiées







Fleurs de pêcher à pétales surnuméraires

Fleurs de pêcher rosacées



Fleurs de pêcher campanulées



Fleurs de pêcher fanées



Fleurs abricotier



Fleurs de pêcher fermées





Bouquets de mai sur abricotier

# Annexe 6 : description des données d'entraînement pour la détection



# Annexe 7: courbes d'apprentissage du réseau de détection des fleurs

Précision et fonction perte, évaluées sur le jeu d'entrainement, en fonction des itérations. Une itération correspond au passage d'un batch donc une epoch correspond à 143 itérations (284 images / 2 images par batch + 1 batch d'une image)).

La fonction perte pour la détection des box est la L1(définie en annexe 1).



Le réseau converge bien en 80 epochs.

# Annexe 8 : performance du réseau de détection sur les données test

	image	wilted flower	flower_closed	flower_open	AP_small	P_mediuA	P_large	R_smal	t_mediu	R_larg
0	patch0_output_Plot7_11_Ca	amera1_1_2400_782_76	0,38	0,48	0,05	0,2		0,1	0,28	
1	patch0_output_Plot7_11_Ca	amera1_1_4000_1098_7	0	0,63		0	0,3		0	0,3
2	patch0_output_Plot7_16_Ca	amera1_2_2400_1091_7	0	0,35	0	0,31		0	0,33	
3	patch0_output_Plot7_16_Ca	amera1_2_800_1634_76	0,62	0,53	0,26	0,41		0,26	0,46	
4	patch0_output_Plot7_18_Ca	amera1_1_4000_1578_7	0,44	0,5	0,4	0,19		0,4	0,2	
5	patch0_output_Plot7_18_Ca	amera1_1_800_859_768	_768.png	0,47	0	0,23		0	0,23	
6	patch0_output_Plot7_21_Ca	amera2_1_2400_1482_7	0,49	0,49	0,27	0,29	0,3	0,31	0,34	0,31
7	patch0_output_Plot7_22_Ca	amera2_2_800_1480_76	0,62	0,69	0,23	0,66	0,6	0,23	0,68	0,6
8	patch0_output_Plot7_23_Ca	amera2_2_2665_952_76	0	0,19	0	0		0	0	
9	patch0_output_Plot7_24_Ca	amera1_2_533_1382_76	0,02	0,55			0,04			0,11
10	patch0_output_Plot7_27_Ca	amera1_1_4000_1579_7	0,53		0,15			0,18		
11	patch0_output_Plot7_27_Ca	amera1_1_800_1159_76	0,52	0,67	0,18	0,54		0,19	0,58	
12	patch0_output_Plot7_2_Car	mera1_3_2400_1142_76	0,51	0,24	0,14	0,33	0,7	0,17	0,35	0,7
13	patch0_output_Plot7_2_Car	mera1_3_800_1254_768	0,73		0,57	0,5		0,68	0,53	
14	patch0_output_Plot7_30_Ca	amera2_1_2400_1544_7	0,55	0,13	0,16	0,27		0,16	0,27	
15	patch0_output_Plot7_30_Ca	amera2_1_4000_1208_7	0,57		0	0,8		0	0,8	
16	patch0_output_Plot7_34_Ca	amera2_1_2400_935_76	0,9	0,48		0,7	0,13		0,7	0,12
17	patch0_output_Plot7_34_Ca	amera2_1_800_1030_76	0,76	0,74	0,58	0,46	0,8	0,65	0,48	0,8
18	patch0_output_Plot7_41_Ca	amera1_2_2400_932_76	0,64	0,44	0,22	0,34		0,38	0,37	
19	patch0_output_Plot7_41_Ca	amera1_2_800_785_768	0,65	0,41	0,26	0,53		0,28	0,54	
20	patch0_output_Plot7_42_Ca	amera1_2_2665_3204_7	0,67	0,85	0,4	0,69		0,4	0,71	
21	patch0_output_Plot7_6_Car	mera1_2_4000_1236_76	0	0,47	0,25	0		0,5	0	
22	patch0_output_Plot7_8_Car	mera1_2_800_866_768_	0,33	0,48	0,16	0,29	0	0,19	0,33	0
23	patch0_output_PlotGA_S_1	_015_Camera2_2_800_1	0,66		0,44			0,47		
24	patch0_output_PlotGA_S_1	_050_Camera1_2_2400_	0,43	0,29	0,12	0,55		0,15	0,56	
25	patch0_output_PlotGA_S_1	_051_Camera1_2_800_1	0,71	0,43	0,25	0,5		0,25	0,53	
26	patch0_output_PlotGA_S_1	_064_Camera1_3_2400_	0,78	0,44	0,22	0,39		0,26	0,4	
27	patch0_output_PlotGA_S_1	_064_Camera1_3_4000_	0,51	0,88	0,25	0,4		0,28	0,4	
28	mean		0,482222222	0,492916667	0,2224	0,3832	0,3588	0,2596	0,4028	0,37
29	std		0,258991396	0,182470983	0,158273	0,2124	0,287	0,1823	0,2138	0,28

# Annexe 9: précision de la mesure de circonférence en verger

Mesures réalis	ées le 22 juin en	G13 avec un mètre	ruban et un	pied à couliss	e						
				Diam	ètres en mm						
rbre (rang_posi	eur depuis le sol	Circonférence (cm	mètre 90° (fa	amètre 0° (co	mètre 45° (dia	amètre 135° (dia	rt type diamèt	onference - diam1	ence - moyenne	rmalized differer	Commentaire
1_12	2	25,5	79,23	81,3	80,27	81,51	1,05	6,09	1,86	0,07	e bleue de 4 à 10
1_12	4	25,6	78,6	80,36	80,97	79,51	1,03	9,07	5,11	0,20	e bleue de 4 à 10
1_12	6	25,7	78,56	79,47	81,76	78,38	1,55	10,20	7,11	0,28	e bleue de 4 à 10
1_12	8	26	77,04	80,19	81,46	78,87	1,89	17,97	10,59	0,41	e bleue de 4 à 10
1_12	10	26,3	78,81	81,42	82,81	79,63	1,80	15,41	9,58	0,36	e bleue de 4 à 10
1_12	12	28,1	ut charpenti	ut charpenti	out charpentiè	but charpentièr	es			tra	ce bleue de 4 à 10
1_12	14	29,7	ut charpenti	ut charpenti	out charpentiè	but charpentièr	es			tra	ce bleue de 4 à 10
1_22	2	20,3	62,62	64,8	63,65	64,31	0,94	6,27	2,43	0,12	rès rectiligne et ré
1_22	4	19,9	61,82	61,81	61,81	62,99	0,59	4,79	3,88	0,20	rès rectiligne et ré
1_22	6	19,5	60,32	60,19	60,34	61,05	0,39	5,50	5,01	0,26	rès rectiligne et ré
1_22	8	19,4	60,52	58,14	60,16	60,07	1,07	3,87	6,38	0,33	rès rectiligne et ré
1_22	10	19,5	61,66	58,51	59,36	60,73	1,40	1,29	6,30	0,32	rès rectiligne et ré
1_22	12	22	pas mesuré	pas mesuré	pas mesuré	pas mesuré	0,00			tronc	très rectiligne et ré
1_22	14	22,2	pas mesuré	pas mesuré	pas mesuré	pas mesuré	0,00			tronc	très rectiligne et ré
1_22	18	21,4	pas mesuré	pas mesuré	pas mesuré	pas mesuré	0,00			tronc	très rectiligne et ré
1_56	2	22,4	70,55	75,13	67,08	71,84	3,33	2,36	0,48	0,02	ice bleue de 4 à 80
1_56	4	21,5	65,27	68,69	64,19	67,59	2,07	9,95	6,29	0,29	ice bleue de 4 à 80
1_56	6	21,8	64,44	71,06	64,56	66,81	3,09	15,56	8,40	0,39	ice bleue de 4 à 80
1_56	8	21,9	64,22	71,18	63,62	66,65	3,43	17,25	10,34	0,47	ice bleue de 4 à 80
1_56	10	23,5	66,44	74,51	68,42	67,8	3,58	26,27	17,31	0,74	ice bleue de 4 à 80
2_69	2	36,2	coulisse tro	coulisse trop	coulisse trop	à coulisse trop e	étroit			trac	e bleue de 12 à 14
2_69	4	35,9	coulisse tro	coulisse trop	coulisse trop	à coulisse trop e	étroit			trac	e bleue de 12 à 14
2_69	6	34,9	coulisse tro	coulisse trop	coulisse trop	à coulisse trop e	étroit			trac	e bleue de 12 à 14
2_69	8	34,9	coulisse tro	coulisse trop	coulisse trop	à coulisse trop e	étroit			trac	e bleue de 12 à 14
2_69	10	35,1	coulisse tro	coulisse trop	coulisse trop	à coulisse trop e	étroit			trac	e bleue de 12 à 14
2_69	12	35,5	coulisse tro	coulisse trop	coulisse trop	à coulisse trop e	étroit			trac	e bleue de 12 à 14
2_69	14	36,6	coulisse tro	coulisse trop	coulisse trop	à coulisse trop e	étroit			trac	e bleue de 12 à 14
2_69	16	36,2	coulisse tro	coulisse trop	coulisse trop	à coulisse trop	étroit			trac	e bleue de 12 à 14

## Annexe 10: Précision de la notation de floribondité

### Sur Abricotier, 30 arbres

PRECISION		Note sur im	age	Nota an	Corrélation(r <sup>2</sup> )	
		Notateur 1	Notateur 1 Notateur 2 Notateur 3		verger	Comptage en verger fleur/m rameaux
	Notateur 1	1	0,45	0,66	0,45	0
Note sur image	Notateur 2		1	0,55	0,52	0
innage	Notateur 3			1	0,66	0
Note en verger					1	0
Corrélation(r²) Comptage en verger fleur/m rameaux						1

### Sur Pêcher, 101 arbres

PRECISION		Note sur im	age	Nata	Corrélation(r <sup>2</sup> )	
		Notateur 1	Notateur 2 Notateur 3		Note en verger	Comptage en verger fleur/m rameaux
	Notateur 1	1	0,52	0,56	0,49	0.23
Note sur	Notateur 2		1	0,57	0,49	0.29
initige	Notateur 3			1	0,45	0.26
Note en verger					1	0.41
Corrélation(r <sup>2</sup> )						1
Comptage en verger fleur/m rameaux						

# Annexe 11 : Synthèse de la bibliographie phénotypage digital

Au début de ce stage 15 jours ont été consacrés à l'étude bibliographique des méthodes de phénotypage des plantes par capteurs hyperspectraux, RGB ou LIDAR.

Type de données	Espèce	Vecteur	Echelle d'observation	Information recherchée	Process	ref
Hyperspectral	Pomme	Drone	Verger	Classification plante saine/malade	Classification pixel, cartographie PCA+SVM classification	(23)
Hyperspectral	Riz	Camera hyperspectrale	Une assiette de riz	Trouver la ferme d'origine du riz	CNN / svm	(24)
Hyperspectral	Betterave à sucre	Spectroradiomètre portable sans imagerie	Une plante	Détecter et identifier maladie	Classification, décision tree, ANN, SVM	(25)
Hyperspectral	Framboise			QTL mapping		(26)
Hyperspectral	Foret	Image satellite	Une forêt	Xylella fastidiosa	PCA=>dimension réduction, Feature extraction, pixel classification SVM	(27)
Hyperspectral	Citron	Drone	Quelques arbres	Détecter citrus canker (~spots sur fruits et feuilles)	Analyse des longueurs d'ondes significative de la maladie en labo puis application sur images hyperspectrales	(28)
Hyperspectral	Blé	Labo	Qqus épis	Détecter crown rot	Analyse réflectance/longueur d'onde	(29)
NIR+RGB	Mais	Camera	Qqus épis	Mesure de la chlorophylle	Analyse réflectance	(16)
RGB image	Soja	Camera	Qqus plans	Suivit de la croissance	Analyse couleur et texture	(17)
RGB image	Riz	Smartphone	Une feuille visée/plan	Estimation de la chlorophylle	Analyse d'image et deep	(30)
RGB image	Pomme	Camera couleur	1 arbre	Prédiction rendement : séparation fruit/ branche/feuille	Traitement image (modification couleur) + DNN	(31)
RGB image	Pomme	Drone	Verger	Estimation production, détection de fruit	CNN	(32)
RGB image	Fraise	Camera couleur	1 fraisier	Détection spot sur feuille	DeepL (CNN)	(33)
RGB image	Feuille random	Camera couleur	1 feuille	Détecter maladie (spot, trou, zone marron sur feuille verte)	Traitement d'image uniquement (morphologie + seuil)	(34)
RGB image	Feuille Random (12 espèces)	Camera couleur	1 feuille	Identifier maladie grâce à symptômes détectés	Traitement d'image (segmentation de la feuille, du symptôme) ML (pas deep) pour identifier maladie	(35)
RGB image	Pomme/ Feuille	Camera couleur	1 fruit/1feuille	Détection maladie	YOLO	(19) (20; 36)
RGB image	Vigne	Boite noire	Feuille	Détection mildiou ; Classification pixel : background, feuille saine, feuille malade	Segmentation+ ML stat	(37)
RGB image	Feuille	Scan	1 feuille	Détecter lésions	Analyse en labo	(38)
RGB image	Vigne	Camera couleur	1pied de vigne	Détecter symptômes maladie d'esca	deepL, SVM	(39)
RGB image	maïs	drone	Qques pied de maïs	Détecter insectes (trou dans feuille) But : détection rapide et précise	Classification des images infecté/saine	(40)
RGB image	Tomate	Drone ;(RGB + multispectral)	Parcelle	Analyse feuille pour mesure production et qualité		(41)
RGB image	Soja	Drone	Parcelle	Prédiction croissance génotypes	comptage pixel vert	(42)

RGB image	Pomme	Camera couleur	1 arbre	Détection fruit	Comparaison méthode : traitement d'image, Faster R-CNN, YOLO	(43; 44)
RGB image	Pêche	Camera couleur	Arbre ou partie de l'arbre	Segmentation du fruit	Définition d'un modèle linéaire des couleurs associés à la pêche	(45)
RGB image	Citron	Camera couleur	1 arbre	Détecter fruit	YOLO	(46)
RGB image	Riz	Drone	Parcelle	Phénotypage résistance sècheresse		(47)
RGB image	Blé	Camera couleur	Quelques épis	Prédiction génomique	Traitement d'image	(48)
RGB image	Blé	Camera couleur	Quelques épis	Resistance à la Fusariose de l'épi	DeepL, dual mask RCNN	(49)
RGB image	Pomme	Camera couleur, background panel + drone	Arbre + verger	Phénotypage	Pearson	(50)
RGB image	Pêche	Drone	Verger	Caractérisation de la cime des arbres, calcul de la cpa (crown projection area)	Traitement d'image, threshold + watershed segmentation	(51)
RGB image	Myrtille	Camera couleur	~1m² sol	Détection mauvaise herbe	CNN	(52)
RGB image	Maïs	Drone	Quelques épis	Détection de maladie spodoptera frugiperda par analyse des défauts des feuilles	Fsat R-CNN	(53)
RGB image	blé	Phone camera	1 epis	Détection maladie	Machine learning + analyse d'image	(54)
Multispectral	Cerise	Drone	Verger	Rendement + besoin en eau	Image process + Decision tree + ANN	(55)
Multispectral	Pastèque	Drone	Parcelle	Détecter maladie	RGB+NIR réflectance analyse	(56)
Multispectral	Pèche	Drone	Verger	Détecter dégâts des acariens (spider mites)	Identification des longueurs d'ondes significatives avec spectroradiomètre sur feuille échantillonnées et canopée puis transfert des résultats aux images multispectrales	(57)
Multispectral	Soja	Drone	Parcelle	Prédiction de la biomasse et du rendement		(58)
Multispectral	Pin méditer- -rannéen	Drone	Parcelle	Identification des génotype	Croisement information RGB/Multispectral/Thermique	(59)
LIDAR, multispectral Thermique	POMME	Drone	Parcelle	Architecture des arbres, consommation en eau	Croisement information lidar/Multispectral/Thermique	(60) (61)
Lidar	Foret		Foret	Surveillance de la forêt : biomasse, maladies, comptage	Lidar, détection, segmentation, fusion avec hyperspectral/multispectral	(60)
Radar	Conifère	Ground penetrating radar	Parcelle	Caractérisation racine ; phénotypage		(61)
Thermique	pomme	Caméra thermique	Feuille	Quantification+identificationapplescab	Baisse de temp dans feuille quand malade	(62)
Thermique	Peuplier	Drone	Parcelle	Resistance à la sécheresse	Image processing, segmentation, mapping	(63)
Image fluorescence	Pomme		Feuille			(62)
Image fluorescence	Tabac	PAM : pulse amplitude modulation	Feuille	Détection pre- symptome maladie		(64)
Image fluorescence			Feuille	Détecter maladie	Analyse d'image seuil	(65)
REVIEW	CNN pour phéno	otypage	· · · · · · · · · · · · · · · · · · ·		· · · · · · · · · · · · · · · · · · ·	(70)

REVIEW	Méthodes de phénotypage digital	(71)
REVIEW	Détection et classification des maladies des plantes par deep learning	(72)
REVIEW	Détection et classification / évaluation santé des plantes /contrôle mauvaise herbe et insecte Estimation production+ analyse culture	(73)
REVIEW	Méthodes de gestion des vergers avec UAV : les approches de détection et d'analyse	(75)
REVIEW	Technique de phénotypage fruitiers	(1)
REVIEW	Utilisation de l'hyperspectral pour l'agriculture et la foresterie	(3)
		(3)

# Bibliographie de l'annexe

- 1. Phenotypic techniques and applications in fruit trees a review, Huang, 2020.
- 2. Plant Disease Detection by imaging sensors\_parallels and speccific demands for precision agriculture and plant phenotyping, Mahlein, 2016.
- 3. Hyperspectral Imaging: A Review on UAV-Based Sensors, Data Processing and Applications for griculture and Forestry, Adao, 2017.
- 4. Application of Reflectance Indices for Remote Sensing of Plants and Revealing Actions of Stressors, Kior, 2021.
- 5. A review on plant high-throughput phenotyping traits using UAV-based sensors ,Xie,2019.

6. Quantitative and qualitative phenotyping of disease resistance of crops by hyperspectral sensors: seamless interlocking of phytopathology, sensors, and machine learning is needed, Mahlein, 2019.

7. High throughput phenotyping to accelerate crop breeding and monitoring of diseases in the field, Shakoor, 2017.

8. A review on the main challenges in automatic plant disease identification based on visible range images, barbedo, 2016.

9. Applications of UAV Thermal Imagery in Precision Agriculture: State of the Art and Future Research Outlook, Messina, 2020.

- 10. An efficient\_RGB-UAV-based\_platform\_for field almond tree phenotyping: 3-D architecture and flowering traits, Lopez, 2019.
- 11. Mapping Almond Orchard Canopy Volume Flowers Fruit, 2016, Underwood.
- 12. Peach Flower Monitoring Using Aerial Multispectral Imaging, Ryan Horton, 2017.

13. Pear Flower Cluster Quantification using RGB Drone Imagery, Vanbrabant, 2020.

14. Automatic apple tree blossom estimation from UAV RGB imagery, Comas, 2019.

15. Multispecies fruit flower detection using a refined semantic segmentation network, Dias, 2018.

16. Zhang\_2018\_Chlorophyll\_Content\_Detection\_of\_field\_maize\_using\_RGB\_NIR\_Camera.

17. Yuan\_2019\_Early\_rediction\_of\_soybean\_trats\_through\_colo\_and\_texture\_features\_of\_canopy\_RGB\_Imagery.

18

Dutta\_Gupta\_2019\_Intelligent\_image\_analysis\_for\_retrieval\_of\_leaf\_chlorophyll\_content\_of\_rice\_from\_digital\_images\_of\_smartphone\_un der natural light.

19. Detection of Apple lesion in orchards based on deep learning methods yolov3-dense, Tian, 2019.

20. A Deep Learning Enabled Multi-class Plant Disease Detection Model Based on computer Vision, Roy, 2021.

- 21. Recent advances in images processing techniques for automated leaf pest and disease recognition-A review, Ngugi, 2020.
- 22. PeachNet\_Peach\_Diseases\_Detection\_for\_Automatic\_Harvesting, Alosaimi, 2020.

23. Thesis\_apple\_proliferation\_multi\_hyperspectral, McLeod, 2021.

24. A residual network with attention module for hyperspectral information, Men, 2021.

25. Early detection and classification of plant diseases with Support Vector Machines based on hyperspectral reflectance,rumpf,2010.

26. Seeing the wood for the trees: hyperspectral imaging for high throughput QTL detection in raspberry, a perennial crop species, Williams, 2021.

27. Previsual symptoms of Xylella fastidiosa infection revealed in spectral plant-trait alterations, zarco-tejada,2018.

28. UAV-Based Remote Sensing Technique to Detect citrus canker Disease Utilizing hyperspectral imaging and machine learning, Jaafar Abdulridha, 2019.

29. The Promise of Hyperspectral Imaging for the Early Detection of crown Rot in wheat ,Xie,2021.

30. Dutta\_Gupta\_2019\_Intelligent\_image\_analysis\_for\_retrieval\_of\_leaf\_chlorophyll\_content\_of\_rice\_from\_digital\_images\_of\_smartphone\_un

der\_natural\_light.

31. Cheng\_2017\_yeild\_pred\_apple.

32. A Cloud-Based Environment for Generating Yield Estimation maps from apple orchards using uav imagery and deep learning technique, Apolo, 2020.

33. Strawberry Fungal Leaf Scorch Disease Identification in Real-Time Strawberry Field Using Deep Learning Architectures, Abbas, 2021.

34. An Automatic Method to Detect and Measure Leaf Disease Symptoms Using Digital Image Processing, Barbedo, 2014.

35. Identifying multiple plant diseases using digital image processing barbedo, 2016.

36. A fast accurate fine-grain object detection model based on YOLOv4 deep neural network, Roy, 2021.

37. A Lightweight Powdery Mildew Disease Evaluation Model for Its In-Field Detection with Portable Instrumentation, Gong, 2022.

38. A fast, nondestructive method for the detection of disease-related lesions and wounded leaves ,Zahid,2021.

39. Comparison of SIFT Encoded and Deep Learning Features for the Classification and Detection of Esca Disease in Bordeaux Vinevards, Rancon, 2019.

40. Hybrid convolution neural network model for a quicker detection of infested maize plants with fall armyworms using UAV-based images, Ishengoma, 2021.

41. High-throughput phenotyping of a large tomato collection under water deficit: Combining UAVs' remote sensing with conventional leaflevel physiologic and agronomic measurements, Fullana-Pericas, 2021.

42. Genomic\_prediction\_of\_green\_fraction\_dynamics in soybean using UAV observations, Toda.

43. Détection d objets en milieu naturel application à l arboriculture, Dore, 2017.

44. Fruit Detection and segmentation for apple harvesting Using Visual Sensor in Orchards, Kang, 2019.

45. Definition of Linear Color Models in the RGB Vector color space to detect red peaches in prchard images taken under natural illumination, Teixido, 2012

46. Image analysis as a potential tool for marker-assisted selection.Kim.2022.

47. Combining UAV-RGB high-throughput field phenotyping and genome-wide association study to reveal genetic variation of rice germplasms in dynamic response to drought stress, Jiang, 2021.

48. A simple, cost-effective high-throughput image analysis pipeline improves genomic prediction accuracy for days to maturity in wheat, Shabannejad, 2020.

49. Automatic Evaluation of Wheat Resistance to Fusarium Head Blight Using Dual Mask-RCNN Deep Learning Frameworks in Computer Vision, Su, 2021.

50. Non-invasive sensing techniques to phenotype multiple apple tree architectures ,Zhang,2021.

51. Characterization of peach tree crown by using hight-resolution images from an unmanned aerial vehicle, Mu, 2018.

52. Evaluation of cameras and image distance for CNN-based weed detection in wild blueberry, Hennessy, 2022.

53. A Novel Object Detection Model Based on Faster R-CNN for Spodoptera frugiperda According to Feeding Trace of Corn Leaves, Du, 2022.

54. Detecting Crown Rot Disease in Wheat in Controlled Environment Conditions Using Digital Color Imaging and Machine Learning, Xie, 2022.

55. Potential of UAS-Based Remote Sensing for Estimating Tree Water Status and Yield in Sweet Cherry Trees, Blanco, 2020.

56. An Improved Crop Scouting Technique Incorporating Unmanned Aerial Vehicle–Assisted Multispectral Crop Imaging into Conventional Scouting Practice for Gummy Stem Blight in Watermelon, Kalischuk, 2019.

57. Remote sensing of spider mite damage in California peach orchards ,Luedeling,2009.

58. Time-series Multi-spectral Imaging in Soybean for Improving Biomass and Genomic Prediction Accuracy, Sakurai, 2021.

59. Bridging the genotype-phenotype gap for a Mediterranean pine by semi-automatic crown identification and multispectral imagery, Santini, 2020.

60. Multi-scale hight-throughput phenotyping of apple architectural and functional traits in orchard reveals genotypic variability under contrasted watering regimes, Coupel-Ledru, 2019.

61. Tree architecture, light interception and water use related traits are controlled by different genomic regions in apple tree core collection, Coupel-Ledru, 2022.

62. Application of Remote Sensing Technologies for Assessing Planted Forests Damaged by Insect Pests and Fungal Pathogens: a Review, Stone-Mohammed, 2017.

63. Ground-Penetrating Radar as phenotyping tool for characterizing intraspecific variability in root traits of a widespread conifer, Lombardi, 2021.

64. Thermography versus chlorophyll fluorescence imaging for detection and quantification of apple scab, Belin, 2013.

65. UAV Based Thermal Imaging for high-throughput field phenotypig of black poplar response to Drought ,Ludovisi,2017.

66. Pre-Symptomatic Detection of Viral Infection in Tobacco Leaves Using PAM Fluorometry, Grishina, 2021.

67. High throughput quantitative phenotyping of plant resistance using chlorophyll fluorescence image analysis, Rousseau, 2013.

68. Convolutional Neural Networks for Image-Based High-Throughput Plant Phenotyping: A Review, Jiang, 2020.

69. remote\_sensing\_diseases,Oerke,2020.

70. Plant Desease and Classification by Deep Learning, Saleem, 2019.

71. Smart Agriculture Using UAV and deep learning a systematic review, Paul, 2021.

72. Orchard management with small unmanned aerial vehicles: a survey of sensing and analysis approaches, Zhang, 2021.

73. Review: High-throughput phenotyping to enhance the use of crop genetic resource, Rebetzke, 2018.

74. Agriculture and digital sustainability a digitization footprint, Marinello, 2019.

75. Huang\_2021\_artifical\_neural\_network\_loquat.

76. Huang\_2021\_artifical\_neural\_network\_loquat.

77. Ogawa\_2021\_remote-sensing\_QTL\_rice.

78. Plant disease Forecasting: Past Practices to emerging technologies, Bhati,2022.

79. Advances in Plant Disease Detection and Monitoring From Traditional Assays to In-Field Diagnostics, Buja, 2021.

80. Making Sense of Light: The Use of Optical Spectroscopy Techniques in Plant Sciences and Agriculture, Cavaco, 2022.

81. Early Yield Prediction Using Image Analysis of Apple Fruit and Tree Canopy Features with Neural Networks, Cheng, 2021.

82. Can we harness digital technologies and physiology to hasten genetic gain in United States maize breeding, Diepenbrock, 2021.

83. Plant Disease Sensing: Studying Plant-Pathogen Interactions at Scale, Gold, 2021.

84. Analysis on Digital Image Processing for Plant Health Monitoring, Granwehr, 2021.

85. Using artificial neural network in predicting the key fruit quality of loquat, Huang, 2021.

86. Interpretability in the field of plant disease detection: a review, Leal-Lara, 2021.

87. Remote-Sensing-Combined Haplotype Analysis Using Multi-Parental Advanced Generation Inter-Cross Lines Reveals Phenology QTLs for Canopy Height in Rice Ogawa.2021.

88. The use of high-throughput phenotyping in genomic selection context, Persa, 2021.

89. An Overview of the Special Issue on Plant Phenotyping for Disease Detection, Pineda, 2021.

90. HairNet: a deep learning model to score leaf hairiness, a key phenotype for cotton fibre yield, value and insect resistance, Rolland, 2022.

91. Digitalization of Clubroot Disease Index, a Long Overdue Task, Salih, 2021.

92. Integrating Genomic and Phenomic Breeding Selection Tools with Field Practices to Improve Seed Composition and Quality Traits in Soybean, Singer, 2021.

93. Deep Learning for Plant Stress Phenotyping: Trends and Future Perspectives, Singh, 2018.

94. Classification of Daily Crop Phenology in PhenoCams Using Deep Learning and Hidden Markov Models, Taylor, 2022.

95. Genomic prediction of green fraction dynamics in soybean using UAV observations ,Toda,2021.

96. Remote sensing for agricultural applications: A meta-review, Weiss, 2020.

97. Crop Phenomics and High-Throughput Phenotyping: Past Decades, Current Challenges, and Future Perspectives, Yang, 2020.

98. Modeling canopy photosynthesis and light interception partitioning among shoots in bi-axis and single-axis apple trees (Malus domestica Borkh), Yang, 2021.

99. A special issue on phytopathometry — visual assessment, remote sensing, and artificial intelligence in the twenty-first century, Bock, 2022.

## Diagramme de GANTT



# Résumé

Ce travail a été réalisé pendant un stage de six mois avec les unités de recherche GAFL et EMMAH d'INRAE et l'entreprise Hiphen dans le but d'évaluer le potentiel des images RGB et de la stéréovision en proxidétection pour mesurer des traits phénotypiques sur pêchers et abricotiers et ainsi faciliter le travail de phénotypage pour la sélection variétale.

Les méthodes proposées associent le deep learning, l'analyse d'image et la stéréovision pour suivre la vigueur et la floribondité des arbres et établir un classement des individus (génotypes) étudiés sur ces critères. La circonférence des troncs est estimée avec une erreur moyenne absolue de 9.5mm par rapport à la mesure au mètre ruban en verger. Elle donne une indication sur la vigueur des arbres. Deux indicateurs sont proposés pour suivre la floribondité : un premier donne le rapport entre le nombre de fleurs et de pixel bois dans l'image, il corrèle avec un coefficient de 0.47 aux nombres de fleurs par longueur de rameau mixte mesuré en verger. Le second propose une classification des arbres en quatre groupes selon la répartition des fleurs dans l'arbre. La précision de cette classification est de 0.48 par rapport à la classification visuelle faite en verger.

Si les premières analyses sont prometteuses, les méthodes manquent encore de précision et cette étude propose plusieurs pistes d'amélioration pour élaborer une méthodologie robuste à destination des utilisateurs finaux (expérimentateurs, sélectionneurs par exemple)

# Abstract

This work was conducted during a six-month internship with the GAFL and EMMAH research units of INRAE and the company Hiphen with the aim of evaluating the potential of RGB images and stereovision in proximity detection to measure phenotypic traits on peach and apricot trees and thus facilitate phenotyping work for varietal selection.

The proposed methods combine deep learning, image analysis and stereovision to assess the vigor and flower density of trees and establish a classification of the individuals (genotypes) studied on these criteria. The circumference of the trunks is estimated with a mean absolute error of 9.5mm compared to the measurement in the orchard. It gives an indication of the vigor of the trees. Two indicators are proposed to assess flower density: the first gives the ratio between the number of flowers and wood pixels in the image, it correlates with a coefficient of 0.47 to the number of flowers per length of bough measured in the orchard. The second proposes a classification of trees into four groups according to the distribution of flowers in the tree. The precision of this classification is 0.48 compared to the visual classification made in the orchard.

If the first analyzes are promising, the methods still lack precision and this study proposes several avenues for improvement to develop a robust methodology for end users (experimenters, breeders for example)