



HAL
open science

Phénaufol - Mise au point d'outils et techniques de PHENotypage pour détecter AUTomatiquement les maladies FOLiaires de la betterave.

François Joudelat, Sandrine Dupin, Bernard Benet, Frédéric Cointault,
Fabienne Maupas

► To cite this version:

François Joudelat, Sandrine Dupin, Bernard Benet, Frédéric Cointault, Fabienne Maupas. Phénaufol - Mise au point d'outils et techniques de PHENotypage pour détecter AUTomatiquement les maladies FOLiaires de la betterave.. Innovations Agronomiques, 2022, 85, pp.279-288. 10.17180/ciag-2022-vol85-art21 . hal-03772381

HAL Id: hal-03772381

<https://hal.inrae.fr/hal-03772381>

Submitted on 8 Sep 2022

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Distributed under a Creative Commons Attribution - NonCommercial - NoDerivatives 4.0
International License

Phénaufol - Mise au point d'outils et techniques de PHENotypage pour détecter AUTomatiquement les maladies FOLiaires de la betterave

Joudelat F.¹, Dupin S.¹, Benet B.², Cointault F.³, Maupas F.¹

¹ ITB, 45 rue de Naples, F-75008 Paris

² INRAE, TSCF, 9 Avenue Blaise Pascal, F-63170 Aubière

³ INRAE, UMR1347 Agroécologie, 17 rue Sully, F-21065 Dijon

Correspondance : f.joudelat@itbfr.org

Résumé

Le projet Phénaufol a consisté à développer une chaîne de phénotypage robotisée des parcelles expérimentales de betteraves sucrières et de quantification automatisée des symptômes de maladies foliaires. Une approche en go / no-go préliminaire a permis de sélectionner les capteurs les plus adaptés au phénotypage des symptômes de maladies foliaires. Diverses approches de traitement d'image (seuillage, texture, machine learning) ont été comparées dans le but de quantifier l'impact de chacune des principales maladies foliaires. En parallèle, une étude mathématique a été réalisée sur la plateforme robotisée choisie, afin de permettre une commande précise des mouvements. Plusieurs campagnes d'acquisitions ont été effectuées pour valider les itérations du système sur le terrain et d'acquérir des données sur le développement des maladies. Une preuve de concept sur la visualisation géographique a été réalisée. Enfin, un couplage vision / robotique a été implémenté sous la forme d'un tracking de manière à positionner la caméra au plus près des symptômes. Un certain nombre de leviers reste encore à lever avant de lancer un phénotypage à grande échelle (panel commercial de variétés, réseau national d'essais).

Mots-clés : robotique, phénotypage, betterave sucrière, maladies foliaires, imagerie

Abstract : Phénaufol: PHENotyping tools and methods development for AUTomated detection of sugar beet FOLiar diseases

The Phenaufol project consisted in the development of a robotic phenotyping process for sugar beet trial plots, and of algorithms for automated quantification of symptoms. A preliminary go/no-go approach allowed us to focus on the most suitable sensors for leaf diseases phenotyping. In order to measure the impact of each main foliar disease, several image analysis methods (thresholding, texture, machine learning) were compared. At the same time, a mathematical modeling of the chosen robotic rig was done for a precise motion execution. Several in-field phenotyping campaigns were conducted to validate the system improvements and to collect disease dynamics data. Geographic visualization was done as a proof of concept. Finally, a vision / robotics pairing was implemented with a tracking algorithm, to move the camera at the closest to the symptoms. Some blockages still need to be removed before running a wide-scale phenotyping campaign (many commercial varieties, national network of experimental sites).

Keywords: robotics, phenotyping, sugar beet, leaf diseases, imaging

Introduction

La culture de la betterave sucrière doit faire face à des épidémies de maladies foliaires qui pénalisent le rendement. En plus de compromettre la rentabilité économique, ces bioagresseurs font l'objet de traitements fongicides ayant de facto un impact environnemental. Ce projet s'inscrit ainsi dans la volonté de développement d'une lutte phytosanitaire plus durable.

Phénaufol facilitera la surveillance de la dynamique d'évolution, clé pour une bonne gestion des maladies foliaires. En effet, la filière a adopté l'utilisation de seuils de pourcentage de plantes malades afin de raisonner l'application de fongicides en diminuant leur usage et en maximisant leur efficacité. Ce projet, en automatisant l'acquisition d'images au champ et la quantification des maladies, permettra d'améliorer la qualité de ce suivi.

La sélection génétique représente également un levier pour protéger partiellement les cultures de ces bioagresseurs. Phénaufol ouvre la voie à des techniques de phénotypage semi-automatiques haut-débit en plein champ qui permettront d'évaluer la tolérance des variétés commercialisées.

Partenaires du projet : L'ITB a coordonné ce projet et épaulé les partenaires lors du transfert des résultats. L'INRAE, via son unité TSCF issue de l'IRSTEA, a permis le développement de la plateforme robotique. L'UMR Agroécologie Agrosup Dijon/INRAE/Université de Bourgogne Franche-Comté a travaillé sur les capteurs et les algorithmes de traitement des images.

1. Contexte

La betterave sucrière est soumise à différents bioagresseurs au cours de son cycle cultural qui s'étend des semis, fin-mars, à la récolte, d'octobre à décembre. Ce projet s'est focalisé sur les maladies foliaires fongiques apparaissant en fin d'été et impactant le plus le rendement, à savoir :

- La cercosporiose : *Cercospora beticola*
- La rouille : *Uromyces betae*
- L'oïdium : *Erysiphe betae*
- La ramulariose : *Ramularia betae*

Les objectifs affichés dans Phénaufol se déclinent selon trois grandes parties : (i) capteurs et analyse d'images ; (ii) plateforme robotique ; et (iii) mise en application. Les parties ci-dessous peuvent ainsi être lues selon ces axes.

2. Matériel et Méthodes

2.1 Capteurs

La première tâche du projet Phénaufol a consisté à identifier le type de capteur nécessaire et optimal pour permettre la détection et l'identification des symptômes de maladies foliaires.

Les premiers essais ont été réalisés avec un spectromètre FieldSpec® 3 ASD équipé d'une sonde adaptée à la mesure sur feuilles. Cet outil non-imageur permet une mesure fine (bande passante de 3 nm vers 700 nm, et de 10 nm vers 1400/2100 nm) de la réflectance des tissus dans une large gamme de longueur d'onde (de 350 à 2500 nm).

En parallèle, une caméra multispectrale Airphen a été utilisée au champ à l'aide d'objectifs adaptés à la prise de vue en champ proche. L'appareil était maintenu à une hauteur d'environ 1,80m à la verticale de la végétation et muni d'une petite mire de calibration. Les images brutes dans les 6 longueurs d'onde du capteur (450, 530, 570, 675, 730 et 850 nm) ont ensuite été traitées par la plateforme Cloverfield de Hiphen.

Pour la suite des travaux, des systèmes imageurs couleur plus classiques ont été utilisés : une caméra RGB Baumer, des réflex Sony, un Nikon D7000, et des capteurs de smartphone.

2.2 Plateformes robotiques

Ce projet est centré sur la mise au point et l'utilisation d'un seul robot : « Bettybot ». Toutefois, d'autres appareils ont ponctuellement été utilisés dans le but de recueillir des images d'entraînement et d'expérimenter certains algorithmes de déplacement.

Le robot « Jaguar » (Figure 1) est un dispositif mobile sur 4 roues, doté d'une première caméra inclinée vers l'avant et d'une seconde orientée verticalement vers le bas. Il permet le suivi et la numérisation de rangs. Le robot « Robufast » (Figure 1), quadrimoteur plus robuste, permet lui aussi de transporter une caméra couleur au-dessus des rangs de betteraves.



Figure 1 : Photographies du robot « Jaguar » (gauche) et du robot « Robufast » (droite) en pleine action

Le robot « Bettybot » (société Robotnik) est constitué d'un axe linéaire motorisé, sur lequel est accroché un bras manipulateur UR5 à 6 degrés de liberté, lui-même équipé d'une caméra Baumer RGB. Cette plateforme a été choisie pour le phénotypage en conditions réelles du fait de sa garde au sol plus élevée et de son volume de travail compatible avec les dimensions des micro-parcelles.

L'attelage complet est constitué d'un microtracteur Lamborghini permettant le déplacement dans l'essai (Figure 2). Un groupe électrogène positionné à l'avant, assure l'alimentation électrique des équipements. Un contrepoids à l'opposé de l'axe linéaire évite les retournements. L'armoire électrique contient les équipements informatiques : pilotes des moteurs électriques, hub réseau et ordinateur portable de contrôle.



Figure 2 : Equipement complet permettant les mesures au champ

L'ensemble de ces robots dispose d'un système ROS pour assurer leur pilotage. De plus, leurs clones numériques ont été configurés afin de pouvoir mettre au point les algorithmes de commande en laboratoire sans disposer du matériel physiquement.

2.3 Environnements informatiques

Les développements informatiques ont été réalisés sur des stations de travail aux caractéristiques hétéroclites. Il est cependant à noter que les interactions avec le robot sont faites via des ordinateurs ayant un système d'exploitation Ubuntu (Sobel, 2015) exploitant la plateforme ROS.

L'analyse d'images a principalement été réalisée grâce aux environnements Matlab et Python (Van Rossum *et al.*, 2009). Les réseaux de neurones utilisés ont été implémentés grâce à la bibliothèque Keras (Chollet, 2015) et optimisés avec Tensorflow-gpu (TensorFlow Developers, 2021).

2.4 Matériels végétaux

Les tests en laboratoire ont nécessité la culture de betterave en pot afin de disposer de matériel végétal à tout moment pour le besoin des expérimentations. La plateforme Serres - 4 PMI a notamment été mobilisée par l'équipe de l'UMR Agroécologie.

Les essais de l'ITB ou de ses partenaires (Tableau 1) ont, quant à eux, permis le phénotypage en conditions réelles, c'est-à-dire dans une parcelle agricole suivant un itinéraire cultural général classique, mais avec un découpage en micro-parcelles avec des variétés différentes.

Tableau 1 : Bilan des essais réalisés durant le projet

Lieu	Dates	Description	Localisation (latitude, longitude EPSG 4326)
Casteljaloux	2016	Test d'acquisition avec robot, hors projet	44.3, 0.1
Dijon – 4PMI	2017	Plateforme d'acquisition avec betteraves en pot inoculées	47.3, 5.1
Corbeilles	2017	Essai en parcelle agriculteur	48.1, 2.6
Viapres	2017	Essai en parcelle agriculteur	48.6, 4.0
Coucy-les-Eppes	28/05/2019 10/09/2019	Essais Bettybot	49.6, 3.8
Aubeterre	20/06/2019 05/07/2019	Essais Bettybot	48.4, 4.1

En serre, les betteraves ont été inoculées afin d'observer des symptômes de maladie. Des feuilles malades de l'année N ou N-1 (feuilles séchées) ont été broyées et mises en suspension. Cette dernière a ensuite été badigeonnée sur les plantes saines.

3. Résultats

3.1 Eléments de contexte

La période disponible pour réaliser des tests et des acquisitions sur le terrain a été raccourcie à plusieurs reprises. En 2019, une panne matérielle sur l'axe linéaire du robot a écourté la campagne de phénotypage. En 2020 aussi, l'été sec et l'importance des attaques virales n'ont pas permis le développement de maladies foliaires. Les symptômes tardifs d'automne ne pouvaient pas être liés avec certitude aux maladies recherchées (sénescence, stress hydrique, maladies de faiblesse, ...).

3.2 Phénotypage des maladies

Tout d'abord, la présence de symptômes de maladies s'est révélée incertaine tant au champ qu'au laboratoire. Au champ, la cercosporiose était plus fréquente que la rouille ou l'oïdium, tandis que la ramulariose n'est pas apparue. En serre, seules les inoculations de cercosporiose et d'oïdium ont conduit à une expression de la maladie.

Les spectres acquis au champ, et sur les plantes inoculées montrent de grosses différences pour les feuilles à des stades avancés de l'épidémie (Figure 3). Toutefois, l'utilisation d'un spectromètre non imageur est complexe et ne permet pas la quantification spatiale des symptômes. Ce système est donc à considérer uniquement comme une méthode d'appui. Ce travail confirme aussi la pertinence de l'utilisation de capteurs plus simples en termes de résolution spectrale.

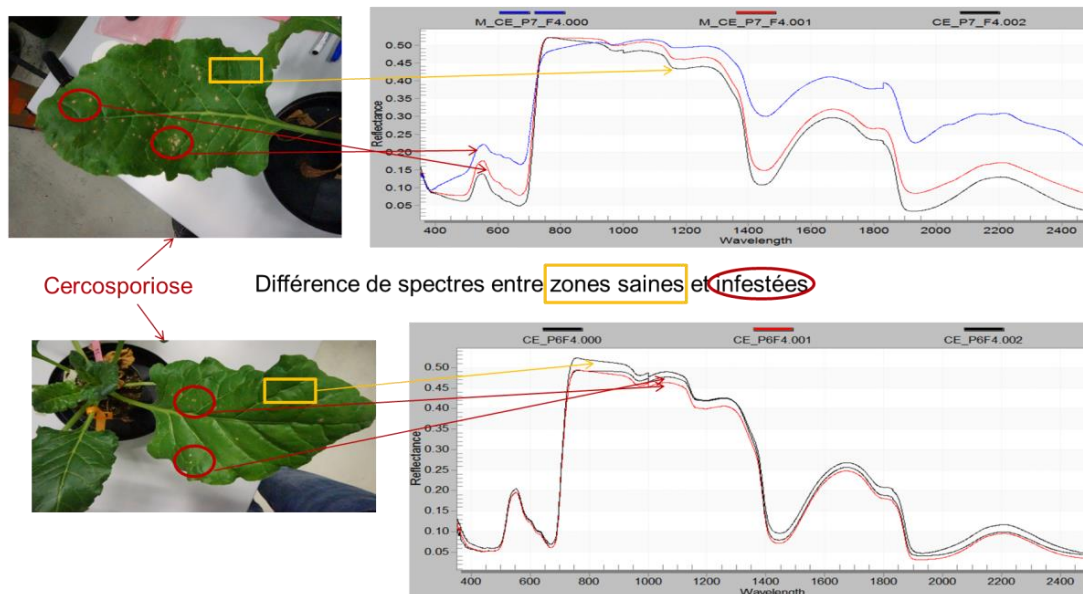


Figure 3 : Comparaison des spectres sains/malades

La caméra multispectrale Airphen s'est révélée également difficile à exploiter. De nombreux prétraitements sont nécessaires pour recombinaison des multiples longueurs d'ondes (Rabatel *et al.*, 2016) et corriger les effets des optiques. La plateforme Cloverfield fournissait ces résultats corrigés ; cependant une faible proportion des images brutes était exploitable du fait du faible recouvrement à courte distance. Ce problème combiné à la faible résolution des capteurs n'a pas permis d'exploiter ces données pour la détection et la quantification de maladies (Figure 4).



Figure 4 : Perte d'information par co-régistration

Les caméras couleur classiques ont cependant permis d'acquérir un nombre important d'images de symptômes. Leur résolution est compatible avec le seuil requis de 2 mm/pixel. Ce sont ces images qui ont majoritairement été analysées par la suite. Dans le cadre de Phénaufol, des indicateurs de la qualité des prises de vue ont été mis au point afin de ne traiter que les images pertinentes (Figure 5).




Figure 5 : Détection d'une image sous-exposée à partir de son histogramme

Une segmentation en 2 étapes a montré de bons résultats par la suite : la végétation est d'abord séparée du sol, puis les maladies sont identifiées et quantifiées. Les classifieurs « Support Vector Machines » (Cortes *et al.*, 1995) testés par l'IRSTEA montrent de bons résultats pour le suivi de rangs. L'UMR Agroécologie a quant à elle développé un seuillage sur l'excès de vert et la méthode des k-moyennes sur l'espace couleur Hue Saturation Value afin de séparer numériquement les pétioles du sol.

Après classification des zones végétales, la segmentation des zones malades et leur quantification sont enfin réalisées grâce à un filtrage dans l'espace $L^*a^*b^*$ qui exacerbe davantage les symptômes (Figure 6, Figure 7).




Figure 6 : Conversion et filtrage des images dans l'espace $L^*a^*b^*$: A) RGB Image, B) $L^*a^*b^*$, C) a^* band, D) cercosporiose blocs Cercosporiose

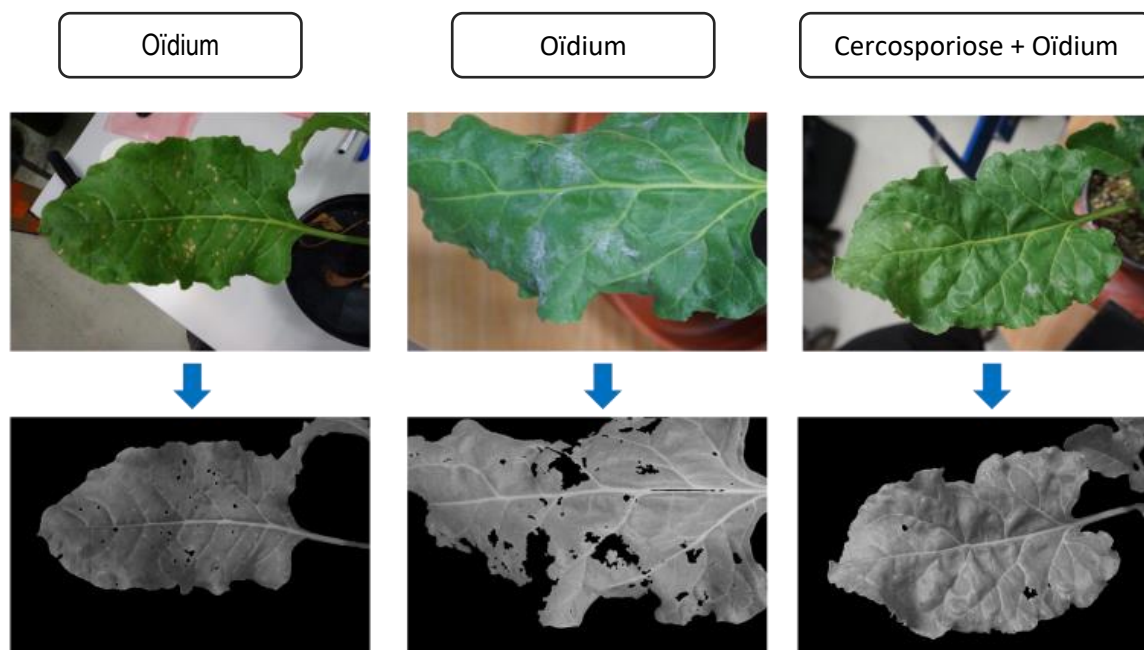


Figure 7 : Segmentation des maladies utilisant les filtres issus des analyses

En parallèle, les approches d'apprentissage profond avec des réseaux de neurones convolutifs (LeCun *et al.*, 2015) montrent des résultats plus mitigés (Tableau 3) à mettre en relation avec un faible nombre d'échantillons d'entraînement (70).

Tableau 3 : Performance des différents réseaux de neurones entraînés

Architecture	MDU	Unet	Enet	linkNet	FCN8	PSP	Inception	Inception Resnet v2	Mobile Net	ResNet50
Score macro F1 (%)	57	45	48	55	54	48	48	63	60	35

De manière opérationnelle, le temps d'exécution de ces techniques a été évalué sur l'ordinateur de pilotage du robot « Bettybot » ou sur des machines équivalentes. Une image de 1022 par 1022 pixels acquise par la caméra embarquée, y est traitée en 2 secondes environ.

L'exploitation fine des données de phénotypage est plus problématique car l'appariement d'un GPS RTK au robot n'a pas été possible. Néanmoins, le couplage Bluetooth d'un smartphone équipé d'un récepteur GPS classique est un succès.

Dans la même optique, des scripts cartographiques (Figure 8) sont réalisés en Python (Van Rossum *et al.*, 2009) afin de compiler géographiquement les sorties du robot et d'étudier la réponse des plantes à l'échelle de la micro-parcelle. L'export dans des formats courants est également possible afin d'analyser les données sous QGIS par exemple.

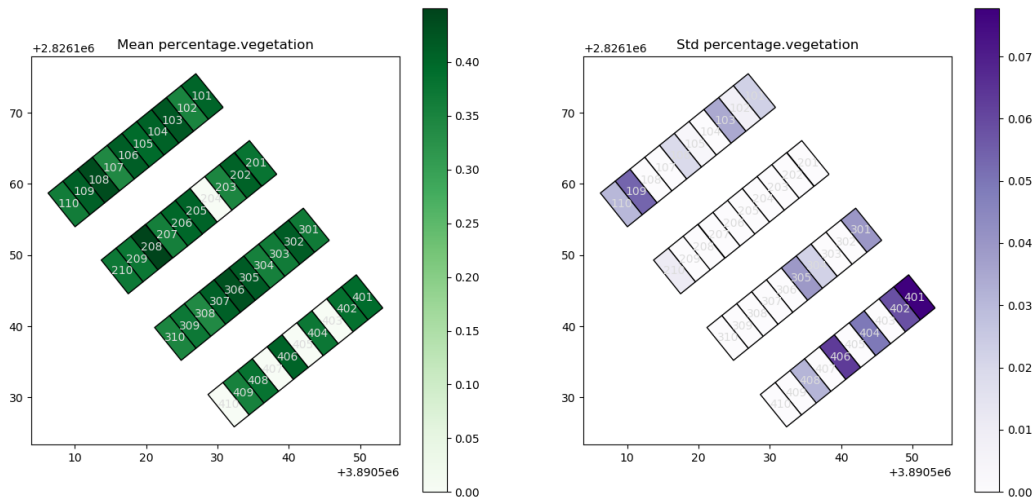


Figure 8 : Exemples de cartographies

3.3 Déplacements de la plateforme robotique

Les premiers algorithmes de déplacement ont été mis au point sur le robot « Jaguar ». Le flux vidéo de sa caméra antérieure est analysé en temps réel afin de commander le suivi des rangs de betterave (Figure 9). Les pixels correspondant à la végétation sont identifiés, puis leur position alimente une régression linéaire qui estime l'emplacement relatif des raies par rapport au modèle géométrique du robot (Figure 10). Enfin, la rotation des roues est ajustée pour corriger la trajectoire. Les résultats sont satisfaisants, car la deuxième caméra du robot, située à l'aplomb du rang, est correctement positionnée pour phénotyper les betteraves.




Figure 9 : Suivi des lignes de rang




Figure 10 : Correction de la trajectoire

Pour la plateforme « BettyBot », le pilotage plus complexe du système a été résolu par une modélisation mathématique de l'axe linéaire et de chacune des six articulations du bras.

L'analyse a démontré que le système était redondant : à une position donnée de la caméra correspond une infinité de positions pour le robot. Des algorithmes spécifiques ont donc été développés pour gérer les déplacements du robot sans se retrouver bloqué. Dans le détail, un coefficient λ reflète l'éloignement de la position à atteindre par rapport à l'espace accessible par les mouvements du bras seul. Les commandes sont alors pondérées par ce facteur λ , d'où une mobilisation accrue de l'axe linéaire pour déplacer la zone de travail du bras à la verticale de l'objectif.

Plusieurs stratégies ont été développées pour répondre à la problématique du positionnement optimal de la caméra par rapport à la végétation à phénotyper. La première, la plus adaptée lors d'une forte infestation de maladie, consiste à parcourir l'ensemble du rang et à multiplier les poses afin de capturer la plus grande surface possible. Une version de cet algorithme a été présentée au SIMA 2019 et a permis d'acquérir le plus d'images en conditions réelles à des fins de test. Pour exemple, le phénotypage d'une micro-parcelle est réalisé en environ 5 minutes.

Dans le cas d'une faible présence de symptômes, la deuxième stratégie de déplacement adoptée est d'identifier chaque plante puis de phénotyper une à une les feuilles. Dans ce sens, des scripts de traitement d'image ont également été développés. La combinaison de techniques classiques et de machine learning s'est révélée performante pour parvenir à identifier les centres des pieds et les feuilles associées (Figure 11). Enfin, une méthode dite de tracking a fait le lien entre la partie perceptive et la commande active du robot pour positionner le bras au plus près de la végétation. Les essais au champ ont validé la démarche.




Figure 11 : Feuilles détectées par deep learning A) B)

4. Discussion

4.1 Phénotypage

Les techniques classiques de phénotypage et le deep learning montrent des résultats complémentaires. Les seuillages ont de meilleurs résultats quant à la qualité de la détection mais semblent plus sujets aux variations de conditions de prise de vue. Un des objectifs futurs pourrait être de combiner les deux approches pour élargir le jeu d'entraînement d'un réseau de neurones. Les durées d'exécution, bien que proches du temps réel, sont un point à améliorer pour encourager l'intégration de ces méthodes dans davantage de cas réels. De plus, la présence de symptômes de maladies en laboratoire ou au champ est cruciale afin de disposer d'une grande diversité de prise de vue, de permettre aux algorithmes de mieux généraliser et de sélectionner les meilleures bandes spectrales. Enfin, sujet peu abordé, la vérité terrain, dictée par les experts en reconnaissance de bioagresseurs, est la ressource clé d'un projet tel que celui-ci et mériterait une plus grande prise en compte en amont afin d'optimiser sa valorisation.

4.2 Plateforme robotique

Lors de la construction du projet, le déplacement du robot « BettyBot » devait être automatisé. En raison des contraintes pratiques et financières, celui réalisé est attelé sur un microtracteur. Des adaptations au niveau des algorithmes de pilotage ont donc été nécessaires. Bien que fonctionnel, il reste sans doute encore des adaptations à fournir afin d'augmenter le débit de chantier et la facilité de prise en main pour une utilisation optimale en routine et à large échelle.

Conclusion

Le projet Phénaufol ouvre deux voies pour une culture plus durable de la betterave sucrière. Par l'utilisation de vecteurs robotisés, ce projet montre les enjeux et les apports de l'automatisation dans le cycle cultural. Aussi, la gestion intégrée des bioagresseurs tels que les maladies foliaires passera à l'avenir par une meilleure connaissance de la physiologie des différentes plantes, et donc par un phénotypage toujours plus fin. Ces deux thèmes seront approfondis à l'ITB, notamment avec les projets LITERAL et CERCOCAP.

L'objectif du projet LITERAL (LITE phenotyping system to Record, Analyze and Lay out) est de développer, mettre en œuvre et évaluer les performances d'un système de phénotypage léger et portable. Il utilisera un ensemble de capteurs imageurs, contrôlés par une interface simple. Les données seront automatiquement référencées et leur traitement sera assuré sur une plateforme cloud. Des algorithmes de transfert radiatif et de deep learning seront mis en œuvre pour transformer les images acquises en variables agronomiques d'intérêt. Une petite série de 12 systèmes LITERAL sera produite et prise en main par les partenaires du projet pour l'évaluer sur un ensemble d'espèces dont la betterave.

CERCOCAP (pilotage de la CERcosporiose de la betterave par COuplage entre modèle agroclimatique et CApteurs connectés) vise à accompagner les agriculteurs dans leur stratégie de gestion durable de la cercosporiose grâce au développement d'outils innovants basés sur la modélisation des processus épidémiologiques et le couplage avec des capteurs connectés.

Références bibliographiques

- Chollet F., 2015. Keras : The python deep learning library. GitHub. <https://github.com/fchollet/keras>
- Cortes C., Vapnik V., 1995. Support-vector networks. *Machine Learning* 20, 273–297.
- LeCun Y., Bengio Y., Hinton G., 2015. Deep learning. *Nature* 521, 436–444
- Rabatel G., Labbé S., 2016. Registration of visible and near infrared unmanned aerial vehicle images based on Fourier-Mellin transform. *Precision Agriculture* 17, 564–587
- Sobel M.G., 2015. A practical guide to Ubuntu Linux, 4th Edition. Pearson Education. ISBN: 9780133927313
- TensorFlow Developers, 2021. TensorFlow. Zenodo. doi:10.5281/ZENODO.4724125.
- Van Rossum G., Drake F.L., 2009. Python 3 - Reference Manual. CreateSpace. ISBN: 978-1-4414-1269-0.

Cet article est publié sous la licence Creative Commons (CC BY-NC-ND 3.0)



<https://creativecommons.org/licenses/by-nc-nd/3.0/fr/>

Pour la citation et la reproduction de cet article, mentionner obligatoirement le titre de l'article, le nom de tous les auteurs, la mention de sa publication dans la revue « Innovations Agronomiques », la date de sa publication, et son URL)