

TRAITEMENT DES DONNEES DE PHENOTYPAGE : DE L'ACQUISITION A L'INTERPRETATION

Benoît de SOLAN

ARVALIS – Institut du végétal, 3 rue Joseph et Marie Hackin, 75116 Paris

UMT CAPTE, 228 Route de l'Aérodrome, 84914 Avignon

b.desolan@arvalis.fr

RESUME

Le phénotypage en agriculture est traditionnellement assuré par des méthodes destructives et coûteuses en temps. Il connaît une réelle révolution grâce au développement de vecteurs et de capteurs de détection à distance, utilisables aujourd'hui dans les conditions de plein champ. En complément de l'offre technologique capteurs-vecteurs, un travail conséquent a été effectué ces dernières années pour mettre au point des méthodes de traitement des données ainsi acquises. Cet article a pour objet de présenter les principales méthodes d'analyse de données donnant accès à des traits utiles à l'acquisition de références en expérimentation : comptage de plantes, d'épis, caractérisation de l'architecture, quantification des maladies, pouvoir couvrant, contenu en chlorophylle, etc. Il met également en évidence les évolutions induites par l'adoption du numérique dans le domaine agricole : (i) la démocratisation des outils d'acquisition de données au champ par des capteurs embarqués sur des robots, drones ou systèmes portables ; (ii) les performances des algorithmes, notamment le *deep learning*, pour l'analyse de données complexes ; (iii) l'importance de la mutualisation de données d'origines diverses. Il montre que les promesses du phénotypage haut débit sont enfin prêtes à se concrétiser. La qualité et la quantité des variables ainsi générées ouvrent la voie à des analyses d'une profondeur inédite, au service de l'amélioration génétique mais aussi du développement de nouveaux moyens de protection des plantes ou de la mise au point de systèmes de cultures innovants.

Mots-clés : phénotypage haut-débit ; capteurs ; vision par ordinateur ; *deep learning* ; analyse 3D ; données multispectrales.

1 – INTRODUCTION

Le phénotypage en agriculture vise à caractériser l'état et le fonctionnement des cultures. Traditionnellement, ces observations sont effectuées visuellement ou par des méthodes destructives. Elles sont souvent coûteuses, d'où la faible quantité d'observations généralement disponibles. Le développement des capteurs change en profondeur cette situation, en offrant la possibilité d'acquérir des mesures non destructives, à faible coût et répétables. Suivant les applications, ils nécessitent des résolutions spatiales, temporelles et spectrales particulières. Depuis 10 ans environ, le phénotypage haut-débit a connu une attention particulière avec la perspective de mieux comprendre la fonction des gènes dont le séquençage est devenu une activité de routine. Furbank & Tester (2011), précisent ainsi l'objectif de la phénomique : établir le lien entre l'information génétique, le fonctionnement de la plante et les traits variétaux en contexte agricole. Une communauté s'est progressivement structurée au travers de projets et réseaux nationaux (PHENOME en France), européens (EPPN et Emphasis) et internationaux (IPPN). Différents systèmes d'acquisition, combinant un vecteur plus ou moins

automatisé, un ensemble de capteurs de mesure ainsi qu'un ordinateur embarqué pour contrôler leur fonctionnement et enregistrer leurs données, ont ainsi été développés et mis en œuvre sur les plateformes d'essais. Les données acquises sont ensuite analysées pour obtenir des caractéristiques physiques ou biochimiques de la culture au moment de la mesure. L'analyse de l'évolution au cours du temps de ces caractéristiques donne accès à des variables de fonctionnement.

Dans cet article, nous nous concentrons sur le phénotypage au champ, dans des essais constitués de petites parcelles de quelques m². Les applications principales sont le processus de sélection variétale, l'évaluation de variétés inscrites, l'évaluation de produits de protection des cultures et le développement d'outils d'aide à la décision. Dans ce contexte, nous décrivons les grands types des méthodes utilisées pour analyser les données générées par ces systèmes et les transformer en traits d'intérêt : analyse d'images, traitement de données 3D et de données multispectrales. Parmi les traits accessibles, on en distingue deux grandes catégories : les variables intégratives qui évoluent de manière continue, à un pas de temps journalier, comme l'indice foliaire ou la biomasse ; les variables de flux, évoluant à un pas de temps rapide (minute, seconde), comme la fluorescence passive ou la température de surface. Pour ces dernières, une mesure est plus difficilement interprétable car fortement dépendante des conditions de température, de vent, de rayonnement, etc. au moment précis de celle-ci. Elles ne sont pas abordées dans cet article.

2 - TRAITEMENT D'IMAGE ET VISION PAR ORDINATEUR

Le traitement d'images désigne l'ensemble des opérations réalisées sur les images numériques, qui transforment une image en une autre image. La vision par ordinateur désigne la compréhension d'une scène à partir d'une image. Ce dernier domaine s'est fortement développé grâce à l'intelligence artificielle. L'intelligence artificielle apparaît dans les années 1950, dès l'invention des ordinateurs. Elle permet, aux moyens de programmes (ou algorithmes), d'automatiser des tâches intellectuelles normalement réalisées par des humains. Sa mise en œuvre passe par l'écriture d'un ensemble de règles simples et logiques qui formalisent un savoir expert. La *machine learning*, est une forme d'intelligence artificielle. Dans ce cas, l'algorithme est entraîné, plutôt que programmé de manière explicite. Les règles sont le résultat d'un processus d'apprentissage au cours duquel on fournit au système des données d'entrées (par exemple, des images) et les résultats attendus (par exemple, un objet identifié). Ces règles ainsi apprises peuvent ensuite être appliquées à de nouveaux jeux de données.

Le *deep learning* est une forme particulière de *machine learning*. Son originalité tient au niveau de complexité des règles pouvant être générées. Une image, par exemple, va traverser un ensemble de couches de traitement successives qui agissent comme des filtres pour mettre en évidence des formes simples, à différentes échelles. Ces formes vont ensuite être combinées pour identifier des objets complexes. La reconnaissance automatique des chiffres a été une des premières applications opérationnelles de ces méthodes. En effet, le petit nombre de types d'objets (0 à 9) rend le problème assez simple à résoudre avec un nombre restreint de formes (lignes, courbes, extrémités...). Mais la démarche est la même pour des objets plus complexes comme des épis de blé, moyennant un modèle d'analyse plus profond. Le *deep learning* est aujourd'hui la technique de référence pour de nombreuses tâches d'analyse d'images, de sons, de textes ou de toute information numérique.

Plusieurs applications de la vision par ordinateur sont possibles. La classification d'images permet d'assigner une catégorie à une image selon son contenu, par exemple une plage ou un champ de blé. La détection et la localisation d'objets dans une image va plus loin en permettant de déceler et d'identifier plusieurs objets distincts présents dans une même image. Chaque objet est alors localisé par une boîte englobante. La segmentation sémantique consiste à affecter chaque pixel de l'image à

une catégorie : feuille, épi, sol, etc. Enfin, la segmentation d'instance identifie chaque objet distinctement, comme pour la détection, et le segmente selon son contour précis. Nous allons maintenant illustrer ces différents usages dans le domaine du phénotypage au travers d'exemples.

2.1 - La détection d'objet : exemple du comptage d'épis de blé

L'estimation de la densité d'épis de blé est emblématique des limites du phénotypage traditionnel, qui consiste à compter visuellement tous les épis sur un mètre carré au champ - une mesure longue, fastidieuse et assez peu précise du fait de l'échantillonnage restreint. C'est pourquoi l'automatisation du comptage par analyse d'images a fait l'objet de nombreux travaux depuis une quinzaine d'années. Cependant, l'objet « épi » est extrêmement divers, fonction du génotype et du stade du blé, ainsi que sa disposition complexe dans l'espace, avec des occlusions et des intersections.




Figure 1. Exemples d'images dans lesquelles les épis sont détectés automatiquement (ARVALIS, 2021)

Cela peut être résolu par la constitution de jeux de données annotés de grande taille, et très diversifiés. C'est pourquoi une approche collaborative et participative a été adoptée (David *et al.*, 2021). Elle a permis la constitution rapide d'un jeu de données très diversifié contenant plus de 6.000 images et 300.000 épis annotés. Ce jeu de données est mis à disposition librement. Sur cette base, un data challenge a été organisé (<https://www.aicrowd.com/challenges/global-wheat-challenge-2021>), et le modèle de détection le plus performant a été implémenté. Il a ensuite été appliqué à un large jeu d'images acquises par les différents systèmes de phénotypage d'Arvalis (Figure 1). Le passage de la détection dans l'image à une estimation de densité nécessite, de plus, une mesure de la distance du capteur à la culture.

Une large comparaison a été réalisée en confrontant les résultats obtenus par analyse d'images par *deep learning* avec ceux réalisés par comptages visuels au champ en 2021 sur 252 microparcelles. L'écart absolu moyen entre la densité estimée visuellement et celle calculée à partir des images est de 55 épis/m² en comparant les résultats par parcelle, sachant que les zones échantillonnées diffèrent. Les comparaisons à l'échelle de la modalité (2 à 3 répétitions selon les essais) présentent un écart moyen de 35 épis/m², soit du même ordre de grandeur que l'incertitude associée

au comptage manuel, ce qui valide cette approche. En 2022, celle-ci est mise en œuvre sur tous les sites de phénotypage haut débit d'Arvalis afin d'automatiser ce comptage.

2.2 - La segmentation sémantique : estimation de la fraction de couverture verte et de la fraction de sénescence

La segmentation sémantique est une autre méthode intéressante pour estimer des informations quantitatives à partir d'images acquises au champ. Elle est très similaire à la perception visuelle en ce qu'elle permet d'analyser des formes, des couleurs pour identifier des surfaces de différentes catégories. Ainsi, une photographie verticale d'un m² de blé peut être segmentée en sol nu, végétation. La végétation peut être décomposée en différents types d'organes (feuilles, tiges, inflorescences). Et chaque type d'organe peut être partiellement vert ou sénéscent (Figure 2). En comptabilisant les pixels de chaque classe, on peut quantifier les fractions des différentes classes d'intérêt. La puissance de la segmentation par *deep learning* tient à la prise en compte d'informations multi-échelles : ces données sont générées par la succession de couches de convolutions qui sont appliquées en amont du processus de classification.¹

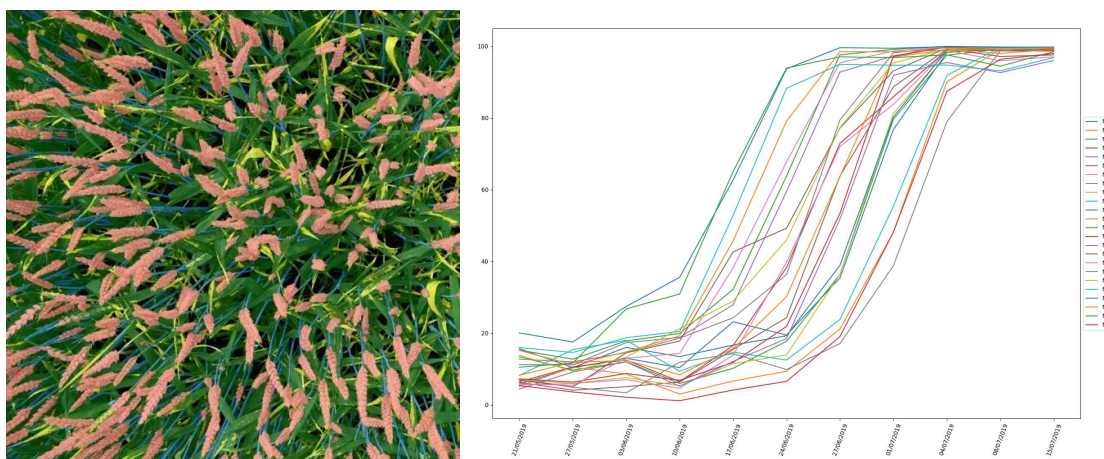


Figure 2. Segmentation sémantique d'une parcelle de blé pour le suivi de la sénescence foliaire et comparaison des cinétiques de sénescence sur un ensemble de parcelles suivies au cours du temps (ARVALIS, 2021)

Pour développer des applications de ces techniques, ARVALIS et INRAE ont constitué un large jeu d'images de végétation annotées (Madec *et al.*, 2019). Il sera enrichi en 2022, avec plus de 4.000 images qui seront mises à disposition librement. Sur cette base, un modèle de segmentation utilisant une architecture U-Net a été entraîné pour classer chaque pixel en "végétation sur pied" ou "sol". Un second modèle a été entraîné pour affecter chaque pixel de végétation à une classe "vert" ou "sénéscent". Sur cette base, plusieurs applications sont développées. La précision de la méthode, évaluée sur un jeu de données de validation indépendant de celui d'entraînement, est de 93 %.

La fraction de couverture verte, ou pouvoir couvrant, est un premier trait d'intérêt. Il est mesuré dans les réseaux d'essais variétaux car cette caractéristique est intéressante pour la compétition de la culture vis-à-vis des adventices. Le pourcentage de maladies est une autre variable fréquemment estimée visuellement dans les parcelles par les expérimentateurs. Les essais conduits en

¹ Une couche de convolution est le résultat du produit entre l'image d'origine et un filtre, c'est-à-dire une fenêtre glissante représentant une forme simple (ligne, courbe, ...) que l'on souhaite détecter dans cette image.

2021 montrent une bonne concordance entre les classements obtenus par notations visuelles et par segmentation d'images et des cinétiques de pertes de surfaces vertes très cohérentes (Figure 2), avec des R^2 supérieurs à 0.8.

D'autres variables peuvent être calculées à partir de ces segmentations, comme l'indice foliaire vert et la fraction de rayonnement intercepté par la culture. Les développements actuels portent sur la segmentation différenciée des espèces végétales présentes. Cela est important en présence d'adventices, mais aussi dans les cultures en mélange. Ces approches seront particulièrement intéressantes pour accompagner le développement de pratiques agroécologiques.

3 - ANALYSE DES DONNEES 3D

Les méthodes précédentes analysent des données en deux dimensions, longueur et largeur. L'ajout de la dimension de hauteur par rapport au sol est intéressant pour caractériser plus finement l'architecture de la culture et notamment la disposition des organes dans l'espace. Les capteurs donnant directement accès à cette troisième dimension sont notamment les LiDAR et les caméras *Time of Flight*. Ils mesurent le temps de retour de rayons lumineux émis par une source contrôlée et en déduisent une distance. La photogrammétrie, elle, se base sur des images 2D classiques prises avec plusieurs points de vue, comme pour la stéréoscopie ou les techniques de *shape from motion*. Ces différentes solutions permettent la génération de nuages de points 3D, qui sont à la base de différents types d'analyses.

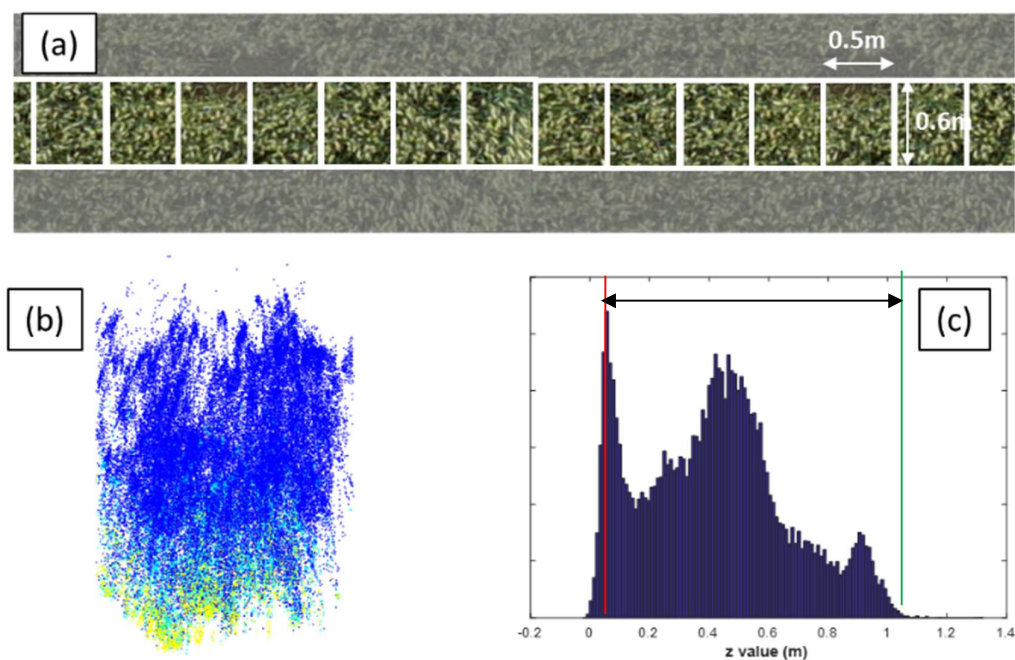


Figure 3. (a) La parcelle est découpée en zones élémentaires de 0.6 m x 0.5 m ; (b) Le nuage 3D LiDAR est extrait pour chacune des zones ; (c) La distribution des hauteurs z pour la zone considérée. Les points de végétation sont situés à des hauteurs supérieures au trait rouge. La hauteur maximale correspond au trait vert. La hauteur calculée de la végétation est la différence entre ces deux valeurs (Madec *et al.*, 2017).

La hauteur maximale de la culture est la variable la plus simple à extraire (Figure 3). Elle renseigne sur le développement général de la culture et, indirectement, sur la phénologie de la culture (Kronenberg *et al.*, 2017), ou sur le risque de verse. Son calcul est possible à partir de l'analyse de nuages de points 3D obtenus par photogrammétrie dans le cas du drone, ou par LiDAR (Madec *et al.*, 2017).

La reconstruction du profil d'interception d'un rang moyen ou d'une microparcelle décrit la densité de végétation en fonction de la hauteur par rapport au sol et de la position dans le rang. Elle décrit la manière dont la culture développe sa surface foliaire. Un ensemble de caractéristiques architecturales fines peuvent être dérivées, comme la hauteur relative pour laquelle la moitié du LAI est atteint (Figure 4).

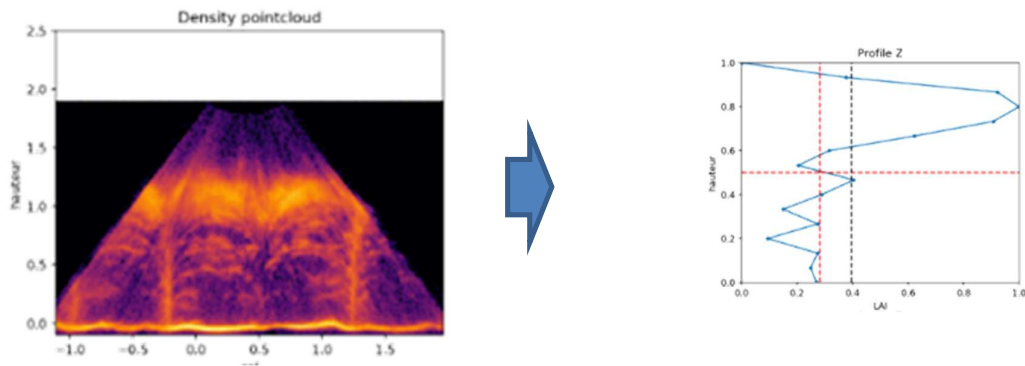


Figure 4. Transect de densité de végétation d'une parcelle de maïs (Phenofield, 2018) et profil moyen d'indice foliaire en fonction de la hauteur relative.

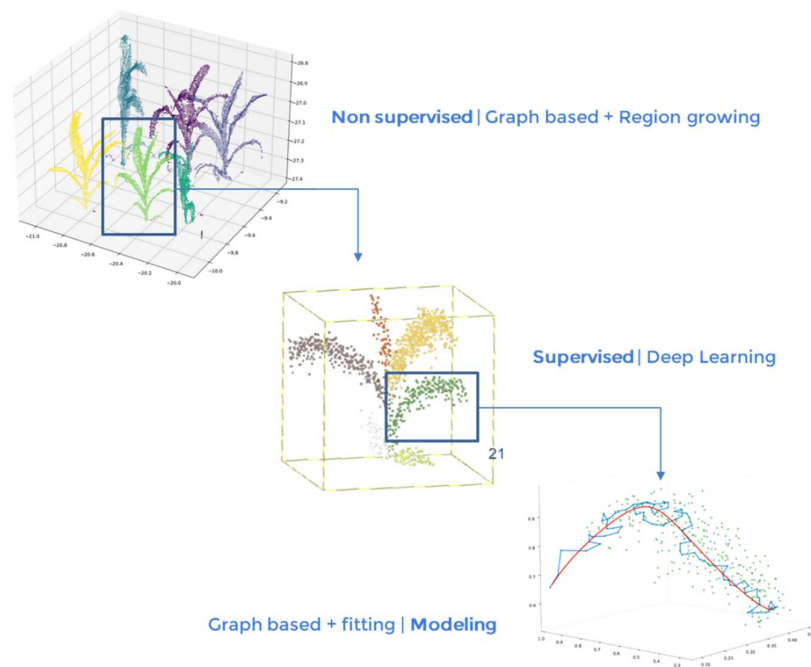


Figure 5. Exemple d'analyse d'un nuage de points 3D, de la scène complète à la feuille individuelle (adapté d'après Li *et al.*, 2022).

L'analyse de l'architecture à l'échelle de l'organe apporte un niveau de détail supplémentaire. Dans ce cas, on segmente le nuage de points 3D. Des modèles de *deep learning* sont spécialisés pour ce type d'analyse. Là encore, l'identification d'objets particuliers (feuilles, épis...) nécessite un entraînement spécifique. Cela reste complexe à réaliser pour les nuages de points, mais des modèles pré-entraînés sont disponibles (Li *et al.*, 2022) et constituent une bonne base de travail. Cela est particulièrement pertinent pour les espèces avec des organes de grande taille, comme le maïs ou le tournesol (Figure 5).

4 - ANALYSE DE DONNEES MULTISPECTRALES

La réflectance est la proportion de la lumière incidente qui est réfléchiée par l'objet cible, dans une gamme de longueurs d'ondes donnée. Elle est liée à sa composition biochimique, car les molécules présentes dans la plante interagissent avec la lumière, qui peut être absorbée, réfléchiée ou transmise, et modifient son spectre. La réflectance d'un objet en fonction de la longueur d'onde considérée apporte une nouvelle dimension à sa caractérisation.

Corrélation entre Indice de Végétation et mesures de LCC et CCC de référence
(Gréoux 2020, Phénomobile, mode actif)

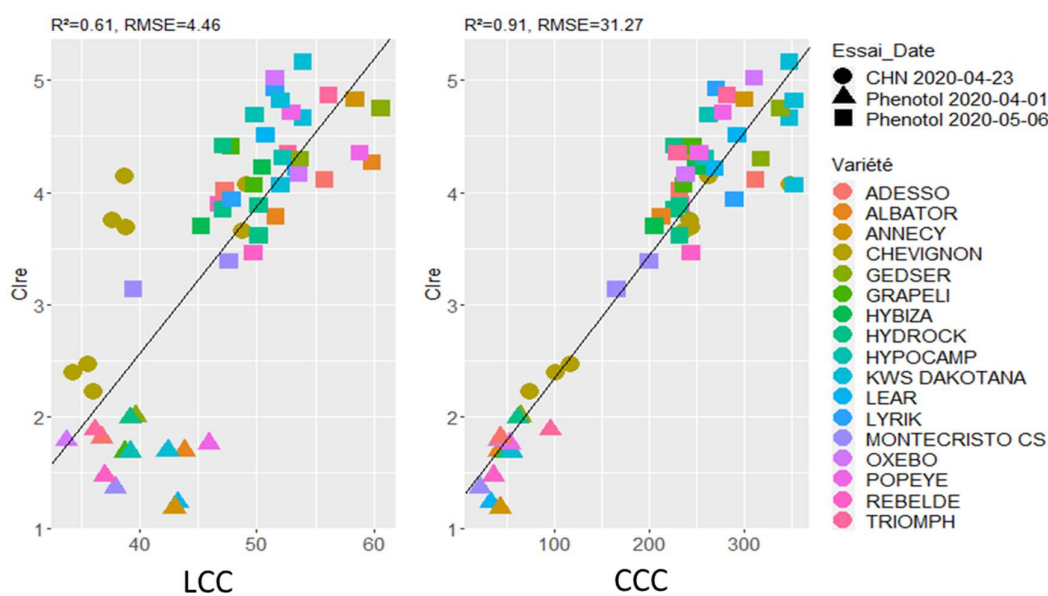


Figure 6. Relations d'étalonnage entre un indice spectral, le LCC (*Leaf Chlorophyll Content*, à gauche) et le CCC (*Canopy Chlorophyll Content*, à droite). On constate que la relation est linéaire et que la RMSE (*Residual Mean Square Error*) est de l'ordre de 10% (ARVALIS, 2020).

Parmi les molécules importantes, la chlorophylle présente un spectre d'absorption très caractéristique, avec une absorption élevée dans le rouge, plus faible dans le vert et nulle dans le proche infrarouge. Ainsi, une culture bien développée, donc avec un contenu élevé en chlorophylle, présentera une réflectance très faible dans le rouge (de l'ordre de 5 %) et très élevée dans le proche infrarouge (de l'ordre de 50 %). Cette molécule est par ailleurs impliquée dans la photosynthèse et corrélée à la teneur en azote de la culture. Pour toutes ces raisons, l'estimation de la teneur en chlorophylle à l'échelle de la feuille (LCC, *Leaf Chlorophyll Content*) et de la culture (CCC, *Canopy Chlorophyll Content*) a fait l'objet de nombreux travaux (e.g. Peng *et al.*, 2011).

Les systèmes de mesures actifs, c'est-à-dire intégrant une source lumineuse contrôlée, permettent d'établir des relations d'étalonnage simples entre réflectances mesurées et contenu en chlorophylle. Certaines combinaisons de longueurs d'ondes, des indices spectraux comme le *CI red edge* (Gitelson *et al.*, 2005), sont linéairement corrélés à cette grandeur. Cela est particulièrement net pour le CCC (Figure 6).

En condition de mesures passives (satellite, drone), étant donné la grande diversité des conditions d'éclairement et de composition en différents objets de propriétés optiques variables dans la culture, il est difficile d'établir des étalonnages empiriques robustes entre variables d'intérêt et réflectances. On utilise alors des modèles bio-physiques plus complexes comme PROSAIL (Jacquemoud *et al.*, 2009) permettant d'estimer directement l'indice foliaire et la teneur en chlorophylle. De tels modèles prennent en compte de manière explicite ces facteurs de variations et offrent une meilleure robustesse vis-à-vis des variations d'éclairement ou d'angle de mesure (Baret & Buis, 2008).

5 - CONCLUSION ET PERSPECTIVES

Il existe aujourd'hui une grande diversité d'outils et de méthodes pour le phénotypage au champ. Loin de rentrer en concurrence, ils constituent une offre technologique complémentaire. En effet, le niveau de précision des données de phénotypage, donc le choix du système de mesure associé, dépend largement de la phase de sélection dans laquelle elle s'inscrit. En phase amont d'un programme de sélection, la population étudiée est très importante (plusieurs dizaines de milliers de microparcelles), et la diversité génétique, donc phénotypique, est très large : un système à très haut débit avec une précision de mesure moindre, tel que le drone, permettra une identification pertinente des génotypes les plus performants. Dans les dernières phases de sélection, les écarts entre génotypes testés sont plus faibles et les populations moins importantes, leur comparaison nécessite donc des méthodes plus précises, comme celles permises par des systèmes au sol.

La qualité du traitement est grandement conditionnée par la qualité des données acquises par le système d'acquisition. Un consensus sur les méthodes les plus prometteuses se dégage (Pound *et al.*, 2016). La caractérisation fine en 3D des cultures, les techniques de vision artificielle par *deep learning* s'imposent comme incontournables. Le développement de chaînes complètes allant de l'acquisition des mesures sur le terrain jusqu'à la mise à disposition des données pour les utilisateurs finaux est en cours. Cela nécessite de gérer les volumes importants de données produites, de les référencer avec des ontologies communes. L'automatisation du filtrage des données aberrantes ou douteuses est un sujet encore peu traité mais c'est un préalable indispensable, du fait du volume important de données générées, à une analyse plus poussée des comportements variétaux. La qualité et la quantité des variables ainsi générées ouvrent la voie à des analyses d'une profondeur inédite, au service de l'amélioration génétique mais aussi du développement de nouveaux moyens de protection des plantes, ou encore de la mise au point de systèmes de cultures innovants.

Journée Scientifique ASF du 3 février 2022
« *Quoi de neuf sur le phénotypage en amélioration des plantes ?* »

REFERENCES

- Baret, F., & Buis, S. (2008). Estimating canopy characteristics from remote sensing observations: Review of methods and associated problems. *Advances in Land Remote Sensing: System, Modeling, Inversion and Application*, 173-201.
- David E., Serouart M., ..., de Solan B., Baret F., Stavness I., Guo W. (2021). Global Wheat Head Detection 2021: An Improved Dataset for Benchmarking Wheat Head Detection Methods", *Plant Phenomics*, vol. 2021, Article ID 9846158, 9 pages, 2021.
- Furbank, R. T., & Tester, M. (2011). Phenomics - technologies to relieve the phenotyping bottleneck. *Trends in Plant Science*, 16(12), 635-644. doi:10.1016/j.tplants.2011.09.005
- Gitelson, A. A., Viña, A., Ciganda, V., Rundquist, D. C., and Arkebauer, T. J. (2005), Remote estimation of canopy chlorophyll content in crops, *Geophys. Res. Lett.*, 32, L08403, doi:10.1029/2005GL022688.
- Jacquemoud, S., Verhoef, W., Baret, F., Bacour, C., Zarco-Tejada, P. J., Asner, G. P., . . . Ustin, S. L. (2009). PROSPECT plus SAIL models: A review of use for vegetation characterization. *Remote Sensing of Environment*, 113, S56-S66. doi:10.1016/j.rse.2008.01.026
- Kronenberg, L., Yu, K., Walter, A. et al., Monitoring the dynamics of wheat stem elongation: genotypes differ at critical stages. *Euphytica* 213, 157 (2017). <https://doi.org/10.1007/s10681-017-1940-2>
- Li, Y., Wen W., Miao T., Wu S., Yu Z., Wang X., Guo X., Zhao C., 2022. Automatic organ-level point cloud segmentation of maize shoots by integrating high-throughput data acquisition and deep learning. *Computers and Electronics in Agriculture*, Vol. 193, 2022. <https://doi.org/10.1016/j.compag.2022.106702>.
- Madec, S., F. Baret, B. de Solan, S. Thomas, D. Dutartre, S. Jezequel, M. Hemmerlé, G. Colombeau, A. Comar (2017) High-Throughput Phenotyping of Plant Height: Comparing Unmanned Aerial Vehicles and Ground LiDAR Estimates. *Frontiers in Plant Science*, 8 (2017), 10.3389/fpls.2017.02002
- Madec, S., Xiuliang J., Baret, F., de Solan B. (2017), Ear density estimation in wheat crops from high resolution RGB imagery using deep learning technique. *Phenotyping side event. ICCV 2017, Venice*.
- Madec, S., Kamran Irfan, Etienne David, Kaaviya Velumani, Gaetan Daubige, et al., (2019). The P2S2 segmentation dataset: annotated in-field multi-crop RGB images acquired under various conditions. *7th International Workshop on Image Analysis Methods in the Plant Sciences (IAMPS)*, Jul 2019, Lyon, France.
- Peng, Y., Gitelson, A. A., Keydan, G., Rundquist, D. C., & Moses, W. (2011). Remote estimation of gross primary production in maize and support for a new paradigm based on total crop chlorophyll content. *Remote Sensing of Environment*, 115(4), 978-989. doi:10.1016/j.rse.2010.12.001
- Pound, M. P., Burgess, A. J., Wilson, M. H., Atkinson, J. A., Griffiths, M., Jackson, A. S., French, A. P. (2016). Deep Machine Learning provides state-of-the-art performance in image-based plant phenotyping. bioRxiv. doi:10.1101/053033