OBSERVATION DES CARACTÈRES RACINAIRES AU CHAMP : APPORT DE L'APPRENTISSAGE AUTOMATIQUE

François POSTIC

CIRAD - UMR AMAP - *TA A51/PS2*
34398 Montpellier cedex 5
francois.postic@cirad.fr

RÉSUMÉ

La faisabilité d'études *in situ* à grande échelle utilisant des images de systèmes racinaires produites par des minirhizotrons - tubes transparents insérés dans le sol - nécessite une détection entièrement automatisée et précise des racines présentes sur les images acquises. Cet article présente une méthode de classification à l'échelle du pixel, appliquant des descripteurs basés sur des filtres d'image standards, optimisée sur un jeu d'entraînement composé d'images minirhizotrons

La surface racinaire prédite par cette procédure de classification est fortement corrélée avec la surface racinaire annotée (R^2 = 0,91) sur le jeu de test d'images de racines de blé (T*riticum aestivum* L.), et plus faiblement corrélée sur les jeux d'images d'orge (*Hordeum vulgare* L.) et de maïs (*Zea mays* L.) (respectivement R^2 = 0,74 et R^2 = 0,80). Les prévisions les plus précises ont été trouvées avec un classificateur « forêt aléatoire » utilisant des descripteurs basés sur les canaux de couleur RVB (Rouge-Vert-Bleu) normalisés et des filtres spatiaux isotropes. Cette méthode fournit une détection fiable des racines *in situ* et constitue une étape essentielle dans la caractérisation de la géométrie et de la structuration des systèmes racinaires au champ.

Mots-clés : segmentation, apprentissage automatisé, surface racinaire, minirhizotron.

1 - INTRODUCTION

Le changement climatique et les incertitudes sur les ressources minérales destinées à la production d'engrais (Reijnders, 2014) incitent à focaliser les programmes de sélection sur l'adaptation aux stress abiotiques (sécheresse et faible fertilité du sol). Ainsi, les futures stratégies de sélection des cultures pourraient axer la sélection des plantes sur des caractères racinaires d'intérêt (Lynch, 2007). Les minirhizotrons font partie des techniques utilisées au champ (Munoz-Romero *et al.*, 2010 ; Li *et al.*, 2011) dans le cadre d'études agronomiques et représentent un bon compromis entre précision et temps d'acquisition. Néanmoins, en l'absence de méthode de traitement d'image automatique, le déploiement à grande échelle de tels systèmes ne peut pas être envisagé.

La détection et la segmentation des racines sur les images issues de minirhizotrons s'avèrent complexes à cause du faible contraste et de l'hétérogénéité de l'arrière plan. Les solutions testées dans des études antérieures reposaient sur des méthodes standard de traitement d'image, conduisant à l'élaboration de filtres complexes, spécialisés à un type de scène. Dans ce contexte, des techniques d'apprentissage automatique (Machine Learning) et de classification ont été introduites pour traiter la complexité des résultats issus de ces procédures de traitement d'image, par exemple en classant les objets détectés d'après leurs paramètres géométriques (Zeng *et al.*, 2010). Une application plus directe de la classification est possible, en utilisant les valeurs de chaque pixel en guise de paramètre de classification.

Dans cette étude, nous proposons (i) une nouvelle méthode de segmentation d'image basée sur une classification à l'échelle des pixels, (ii) nous identifions les filtres et les classificateurs les plus performants, et (iii) nous évaluons la précision des mesures obtenues automatiquement par comparaison aux notations visuelles.

2 – PRINCIPE CLASSIFICATION PIXEL A PIXEL

La classification par Machine Learning décrit un large groupe d'algorithmes (Kotsiantis *et al.*, 2006). Le but de ces algorithmes est de générer une fonction de décision, utilisant les valeurs des échantillons (ou descripteurs) pour prédire l'appartenance à une classe. Cette fonction de décision varie en fonction de l'algorithme utilisé pour la classification : par exemple, la classification des échantillons effectuée par les *régressions logistiques* est basée sur une courbe sigmoïde, tandis que les *arbres de décision* utilisent une séquence de conditions logiques. Les paramètres de cette fonction de décision sont ajustés sur un jeu de données, dit « jeu d'entraînement ».

Une image peut être décrite comme un jeu de données, où chaque pixel est un échantillon et dont la dimension dépend du type de l'image. Dans le cas d'une image en niveaux de gris, les échantillons sont des vecteurs à valeur unique, tandis que dans le cas d'une image couleur (RVB), ce sont des vecteurs en trois dimensions représentant les trois canaux de couleur. Par conséquent, les composantes de couleur d'un pixel d'une image RVB peuvent être utilisées en tant que descripteurs. De plus, toute transformation qui conserve les dimensions de l'image (c'est-à-dire le nombre de pixels) peut fournir des descripteurs supplémentaires. Ainsi, une classification basée sur les pixels peut être établie en entraînant des classificateurs sur un jeu de données comprenant des images originales, leurs transformations à travers des filtres simples et leurs vérité-terrain, c'est-à-dire des images avec des pixels étiquetés (images noir et blanc, pour une classification binaire).

3 – JEU DE DONNÉES, ALGORITHMES ET DESCRIPTEURS D'IMAGES MIS EN ŒUVRE

Tableau 1. Descripteurs utilisés et classement relatif selon leur « Stability score ». (Meinshausen et Bühlmann, 2010).

Descripteur d'image	Stability score moyen
Composante Verte Normalisée	1.00
Laplacien Normalisée	1.00
Ecart Type	1.00
Composante Saturation Normalisée	0.81
Filtre de Prewitt	0.75
Filtre de Sobel	0.69
Composante Saturation	0.64
Filtre de Sobel Normalisé	0.57
Composante Bleu Normalisée	0.57
Composante Luminosité Normalisée	0.56
Filtre Minimum	0.52
Composante Teinte Normalisée	0.52

Le jeu d'entraînement est composé d'images de racines de blé acquises en 2015 et le jeu de test comprend les images de blé, d'orge et de maïs collectées en 2017. Sur ces images minirhizotron, les racines ont été notées manuellement à l'aide de Smartroot (Lobet *et al.*, 2011), puis les notations ont été converties en images binaires (les vérités-terrain) où le sol et les racines sont représentés respectivement par les pixels noirs et les pixels blancs.

Les descripteurs d'images utilisés sont basés sur les techniques de traitement d'image les plus courantes et ont été sélectionnés d'après leur capacité à segmenter correctement les images du jeu d'entraînement (Tableau 1). Ces filtres comprennent des conversions simples de d'espace colorimétrique (par exemple, division des canaux rouge vert et bleu, conversion en niveaux de gris ou dans l'espace colorimétrique HSV) ou de filtres simples (directionnels ou isotropes) tels que les filtres de Sobel, de Prewitt ou les filtres Laplaciens.

Les 8 classificateurs suivants ont été testés : un perceptron, un arbre de décision, un modèle bayesien naïf, une régression logistique, un SVM (Support Vector Machine) linéaire, une combinaison de régressions logistiques (optimisées avec AdaBoost), une combinaison d'arbres de décision (optimisés avec AdaBoost) et une forêt aléatoire (forêt d'arbres de décision). L'algorithme a été écrit en Python 3, avec les librairies OpenCv (traitement image) et scikit-learn(Machine Learning).

4 – QUALITÉ DES PRÉDICTIONS

La « forêt aléatoire » s'avère être le classificateur le plus performant, comme le montre la précision des prédictions sur le jeu d'entraînement (Figure 1a), ainsi que la prédiction de surface racinaire sur l'ensemble des images de blé (R^2 = 0,91, Figure 2a). À titre de comparaison, le classificateur régression logistique obtient des résultats bien moins fiables, illustrés par le nombre élevé de faux négatifs (Figure 1c). La classification réduit le temps consacré à la détection des racines à quelques dizaines de secondes, alors qu'un annotateur humain y passerait près d'une heure. Cependant, la fiabilité de la détection est moindre sur des images de racines d'espèces végétales absentes du jeu d'entraînement (Figures 2b et 2c).

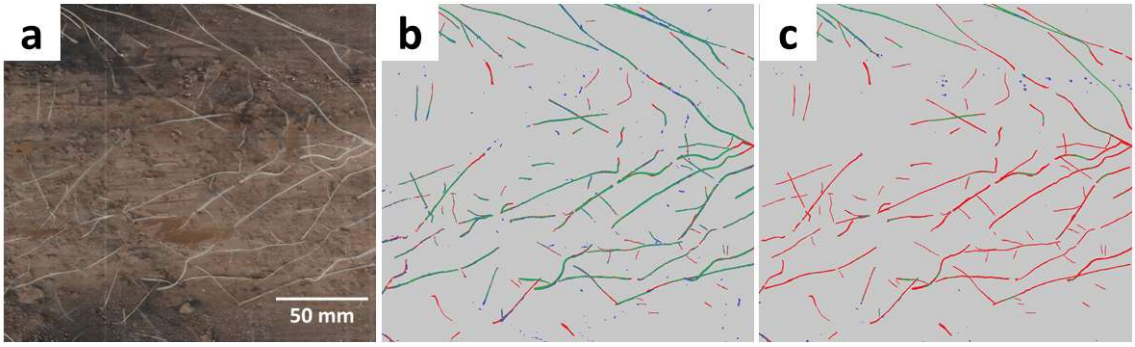

Figure 1. Illustration de la classification obtenue sur le jeu de données de test par la "forêt aléatoire" et la "régression logistique". La colonne de gauche (a) montre une image originale de minirhizotron de l'ensemble de test blé. La colonne centrale (b) montre les résultats de classification obtenus par la "forêt aléatoire", et la colonne de droite (c) montre les résultats de la "régression logistique". Les pixels verts, gris, bleus et rouges représentent, respectivement, les vrais positifs, les vrais négatifs, les faux positifs et les faux négatifs.

Ces diminutions de précision entre espèces peuvent provenir d'une sur-spécialisation du classificateur (sur-entraîné sur les racines de blé) introduite au stade de la sélection des descripteurs, en particulier pour la taille du noyau des filtres directionnels, adaptés au diamètre moyen des racines des plants de blé.

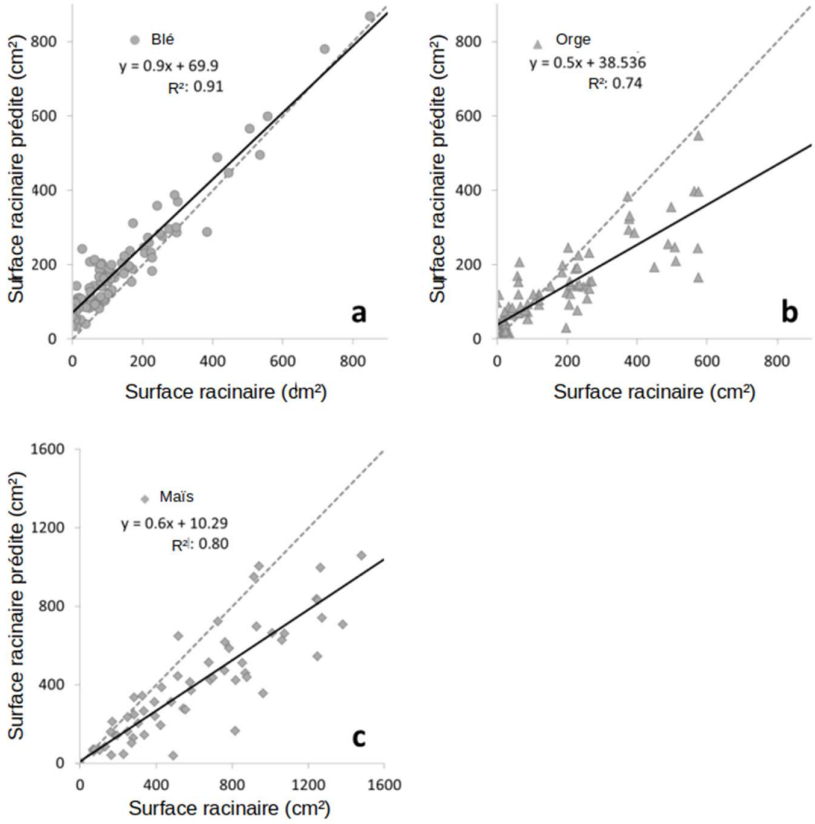

Figure 2. Corrélation entre la surface racinaire prédite par le classificateur « forêt aléatoire » et la surface racinaire relevée manuellement, pour les ensembles de test blé (a), orge (b) et maïs (c). Chaque point représente une image, la ligne pointillée représente la relation 1:1. La surface racine (cm2) est calculée en fonction de la surface en pixels des images originales.

Cela suggère qu'un seuil sur le diamètre des racines est induit par l'algorithme, ce qui implique une classification erronée des racines les plus épaisses, (notamment pour les racines de maïs). Au contraire, la couleur des racines semble être un caractère stable de détection, car celle-ci ne varie pas d'une espèce à l'autre, mais dépend davantage de l'activité métabolique (Comas *et al.*, 2000).

5 – CONCLUSION ET PERSPECTIVES

Notre objectif était d'obtenir un classificateur de la surface racinaire en utilisant des transformations d'image simples, tout en utilisant peu de savoir *a priori* sur les caractéristiques dimensionnelles de la racine. Ces images segmentées sont le point de départ de multiples mesures, les plus simples – et parmi les plus importantes – reposent sur la mesure de longueurs et de diamètres. Une fois ces variables extraites des images et recalées selon la profondeur d'acquisition, il est possible de produire des profils d'enracinement. La performance de l'algorithme présenté ici doit être testée face aux algorithmes de Deep Learning (ces derniers ne nécessitent pas de générer des descripteurs).

Néanmoins, cet algorithme peut tourner sur un ordinateur de bureau classique, sans l'aide de composants spécifiques (cartes graphiques), à l'opposé des algorithmes de Deep Learning.

Journée Scientifique ASF du 7 février 2019
" Le système radiculaire et la rhizosphère en amélioration des plantes "

BIBLIOGRAPHIE

Comas LH, Eissenstat DM, Lakso AN. - 2000 - Assessing root death and root system dynamics in a study of grape canopy pruning. *New Phytol.* 147, 171–178.

Kotsiantis SB, Zaharakis ID, Pintelas PE. - 2006 - Machine Learning: A Review of Classification and Combining Techniques. *Artif Intell Rev*. 26, 159–190.

Li C, Sun J, Li F, Zhou X, Li Z, Qiang X, et al. - 2011 - Response of root morphology and distribution in maize to alternate furrow irrigation. *Agric Water Manag*. 98, 1789–1798.

Lobet G, Pagès L, Draye X. - 2011 - A Novel Image-Analysis Toolbox Enabling Quantitative Analysis of Root System Architecture. *Plant Physiol*. 157, 29–39.

Lynch, J.P. - 2007 - Roots of the second green revolution. *Australian Journal of Botany* 55, 493-512.

Meinshausen N. , Bühlmann P. - 2010 - Stability selection. Journal of the Royal Statistical Society: Series B 72, 417-473.

Munoz-Romero V, Benítez-Vega J, López-Bellido L, López-Bellido RJ. - 2010 - Monitoring wheat root development in a rainfed vertisol: Tillage effect. *Eur J Agron*. 33, 182–187.

Reijnders L. - 2014 - Phosphorus resources, their depletion and conservation, a review. *Resour Conserv Recycl*. 93, 32–49.

Zeng G, Birchfield ST, Wells CE. - 2010 - Rapid automated detection of roots in minirhizotron images. *Mach Vis Appl.* 21, 309–17.