

Végéphy – 24e CONFÉRENCE DU COLUMA
JOURNÉES INTERNATIONALES SUR LA LUTTE CONTRE LES MAUVAISES HERBES
ORLÉANS – 3, 4 et 5 DÉCEMBRE 2019

RECONNAISSANCE DIGITALE DES ADVENTICES AVEC PROXIMAIS® ITECH EN UTILISANT LE DEEP LEARNING POUR AIDER A RAISONNER LA STRATEGIE DE DESHERBAGE.

T. VARRAILLON⁽¹⁾, F. JUMEL⁽¹⁾, D. BRUXELLE & V. GODET⁽¹⁾

⁽¹⁾ Syngenta Agro, SAS, 1 avenue des prés, France, thierry.varraillon@syngenta.com

RÉSUMÉ

Reconnaître les adventices qui concurrencent la culture de maïs en place est la première étape d'une pratique de désherbage efficace. En 2017, Syngenta a complété son outil pour raisonner le programme de désherbage maïs (Proximaïs® iTech) avec une nouvelle fonctionnalité permettant une aide à l'identification des adventices à partir de photographies. L'apprentissage emprunte aux technologies d'intelligence artificielle d'analyse d'images. Le processus de reconnaissance automatique de l'espèce végétale a été testé sur plus de 19 125 images pour différentes espèces dicotylédones et graminées. Des résultats encourageants ont été obtenus sur maïs pour 32 adventices dont 5 graminées à différents stades de développement.

Mots-clés : digital, adventices, deep learning, OAD.

ABSTRACT

DIGITAL WEEDS RECOGNITION WITH PROXIMAIS® ITECH USING DEEP LEARNING TO MANAGE THE STRATEGY OF WEED CONTROL.

Recognizing weeds that compete with the existing corn crop is the first step in effective weed control. In 2017, Syngenta has completed its tool to reason the weed control program: Proximaïs® iTech with a new feature to help identify weeds from digital pictures. Learning using artificial intelligence technologies of image analysis to develop a process of automatic recognition of the plant species has been tested on more than 19 125 images of different dicotyledonous and monocotyledonous species. Encouraging results were obtained on maize for 32 weeds including 5 weed grasses at different stages of development.

Keywords: digital, weeds, deep learning, DSS.

INTRODUCTION

Le deep learning, ou apprentissage profond, est une branche du machine learning utilisé en intelligence artificielle qui vise à développer des méthodes automatiques d'apprentissage à partir de données. Il est exploré depuis quelque temps en agriculture pour répondre aux questions de prévisions posées par le vivant (production animale, végétale et aide à la décision pour la gestion des exploitations). Les cas d'utilisation du deep learning les plus couramment appréhendés sont liés à la vision (objets connectés, robotique et machinisme agricole). Dans le cadre de la reconnaissance de plantes à partir d'images, il s'agit pour Syngenta de reconnaître une adventice et de l'identifier afin d'adapter le choix du produit(s) de désherbage. En fonction de la complexité des flores rencontrées dans les maïs et de l'importance du développement de l'infestation, les stratégies doivent être adaptées en nombre de passages et en positionnement en fonction du stade de développement des adventices. L'objectif étant d'appliquer le produit (ou l'association) à la bonne dose en fonction du stade des mauvaises herbes.

Le deep learning est très performant sur des tâches de classification d'images. Il utilise des réseaux de neurones convolutionnels profonds inspirés par le fonctionnement du cortex visuel (Lecun, 2016). Cependant, afin que ces modèles puissent apprendre correctement la relation entre un ensemble d'images et leurs noms, il est nécessaire de disposer de suffisamment de clichés par adventice.

Dans cette perspective, depuis 2013, les équipes de recherche et développement de Syngenta ont complété les notations des essais de désherbage par plus de 19 000 clichés photographiques dans les zones de comptage d'inter-rangs des cultures de maïs.

MATERIEL ET MÉTHODE

Sites expérimentaux, prises de vue et classification des plantes:

Entre 2013 et 2018, dans les parcelles d'essais de désherbage maïs, des placettes de comptages sont repérées (Fig. 1A). Des photographies de celles-ci ($\approx 0,75 \text{ m}^2$ au sol) sont réalisées à 1 mètre de haut à différents stades de développement du maïs, de la levée jusqu'au stade 7-8 feuilles (Fig. 1B). Différents appareils photographiques numériques RGB sont utilisés avec des résolutions variant de 5 à 20 mégapixels.

L'écartement moyen entre rangs de semis est de 75 cm en moyenne, représentant chaque fois 2 rangs par photographie. Sur ces clichés les plantes sont isolées avec le logiciel ImageJ® développé par le National Institute of Health, USA (<https://imagej.nih.gov>) (Fig. 1C), identifiées suivant son code EPPO (Mamarot *et al*, 2014) et un stade de croissance de 0 à 5 suivant l'échelle principale des stades BBCH (Lancashire *et al*, 1991) leur est attribué (Tab. I).

Figures 1: Scènes photographiées, A : Placette de comptage B : Principe de prise de vue C : Classification des plantes. (Scenes photographed, A : Counting area B : Shooting protocol C : Plant classification)





Tableau I : Echelle des stades de développement des adventices et cultures. (Scale of development stages of weeds and crops).


Stades principaux		Description phénologique
0	Flore peu développée (facile à désherber)	Stade cotylédons à 1ère feuille peu développée (DICOT)
		Feuille imparfaite sortie à 1ère feuille peu étalée (GRAM)
1		Développement des premières feuilles, stade peu développé (2-4 Feuilles) (DICOT)
		Développement des premières feuilles, stade peu développé (GRAM)
2		Plusieurs feuilles sont développées (DICOT)
		Début / Mi-tallage (GRAM)
3	Flore très développée (difficile à désherber)	Expansion de la plante, montaison (DICOT)
		Fin tallage (GRAM)
4		Stade limite d'apparition de l'inflorescence ou des premiers bourgeons (DICOT & GRAM)
		5



Panic pied-de-coq stade 0



Renouée-liseron stade 1



Morelle Noire stade 2



Chénopode blanc stade 3



Mercuriale stade 4

Description de la base d'entraînement :


Une base de 19 125 photos constituée de flores identifiées par nos experts dans les parcelles maïs (ZEAMX) en France entre 2013 et 2018 a ainsi pu être construite. Elle regroupe 15 666 photographies pour 92 DICOT et 3 459 photographies pour 28 GRAM et 2 261 photographies pour ZEAMX. Les 5 premières adventices: mercuriale annuelle (MERAN), morelle noire (SOLNI), panic pied-de-cq (ECHCG), renouée liseron (POLCO) et chénopode blanc (CHEAL) représentent près de 50% de notre base d'apprentissage (Fig. 2A).

32 adventices dont les effectifs sont supérieurs à 100 images représentent 91% de notre base d'apprentissage (Fig. 2A). 5 adventices sont des GRAM : panic pied-de-coq ECHCG, pâturin annuel (POAAN), digitaire sanguine (DIGSA), ray-grass anglais (LOLPE) et sétaire verte (SETVI). Les 27 autres sont des DICOT dont 2 vivaces : lychnis dioïque (MELAL) et la prêle des champs (EQUAR).

Les 88 autres adventices dont les effectifs sont inférieurs à 100 représentent 9% du total seulement.

Les stades sont principalement situés autour du stade 1, développement des premières feuilles. 85 % des cas sont situés entre la levée (stade 0) et la formation de pousses secondaires (stade 2) (Fig. 2B). Cette plage de stade est bien la période optimale d'intervention des stratégies de désherbage (Tab. I) et du conseil que l'on vise à soutenir avec ce type d'outil.

Figures 2: Répartition des photographies A : par adventices * effectifs > 100 images B : par stades. (Distribution of pictures A: by weeds * > 100 pictures B: by stages)




Méthologie générale de classification et de sa validation :

Les réseaux de neurones utilisés sont des réseaux convolutifs (Convolutional Neural Networks, ConvNets ou CNN), inspirés des processus biologiques du cortex visuel des animaux, qui permettent de transformer un problème global de reconnaissance en une succession d'étapes plus faciles à résoudre.

Ainsi, l'architecture des CNN comprend une alternance de couches de traitement (couches de convolution, d'activation et de simplification ou pooling) qui permettent d'extraire des caractéristiques. Plus on progresse vers les couches profondes, plus on obtient des combinaisons complexes, c'est-à-dire de plus en plus abstraites. La convolution consiste à faire glisser des filtres sur les images pour faire ressortir de façon marquée certaines caractéristiques (Toulon, 2018). Un tel réseau prend directement en entrée les pixels d'une image et propage ces informations couche par couche jusqu'à la couche de sortie dont la taille correspond au nombre de classes de la tâche de prédiction considérée. Le numéro du neurone de la couche de sortie dont la valeur est la plus élevée correspond au nom de l'adventice prédite par le réseau (Fig. 3).

Figure 3 : Architecture simplifiée d'un réseau de neurones convolutif CNN. (Convolutional Neural Networks)




D'après : Deep Learning et Agriculture – Une étude de la Chaire AgroTIC – Novembre 2018

Pour estimer la qualité de la prévision, il est nécessaire d'utiliser un ensemble de données distinct dit de test, afin de quantifier à quel point les prédictions du modèle sont cohérentes avec la réalité. Ainsi nous avons séparé les images de chaque classe en un ensemble d'apprentissage (80 % des images) et en un ensemble de test (20 % des images).

Application Proximaïs iTech :

Un accès à ce modèle CNN entraîné à partir de notre base d'images de référence a été ajouté (icône appareil photo 📷 Fig. 4) à notre application web disponible sur smartphone: Proximaïs® iTech. Cette application est spécialement conçue pour guider l'utilisateur dans le choix des solutions de désherbage à la parcelle. L'utilisateur peut désormais, en plus d'une clé de détermination classique, s'appuyer sur cet outil de reconnaissance digitale pour constituer sa flore présente et accéder aux stratégies et aux solutions de désherbage les plus pertinents (Fig. 4A). Une photo au champ de l'adventice est déposée dans l'application (Fig. 4B), puis quelques secondes plus tard un score de ressemblance d'adventices (3 au maximum) est renvoyé à l'utilisateur (Fig. 4C).

Figures 4 : Proximaïs® iTech, A : écran d'accueil B : écran prise de vue C : écran de résultats. (Proximaïs® iTech web application, A : home screen B : shooting screen C : results screen.)



RESULTATS

Le modèle CNN est entraîné de façon indépendante sur les stades d'un côté et le nom des adventices de l'autre, car pour le moment la couverture des données n'est pas suffisante lorsqu'on croise les deux.

Performance des estimations des stades de développement :

Dans les résultats nous regroupons les stades en 2 classes (Tab. I): flores peu développées : [stade 0 à 2] et très développées [> stade 3]. Le tableau II présente les pourcentages de bonne détection de ces 2 classes. La précision globale de l'estimation est de 89% de bonnes prédictions.

Tableau II : Pourcentage de bonnes détections du stade de développement sur l'échantillon test. (Percentage of good development stage detections on the test sample)

		Détection	
		Flore peu développée	Flore très développée
Observation	Flore peu développée	80 *	10
	Flore très développée	1	9 *


* Bonnes prédictions.

Performance des déterminations des noms des adventices :

Afin de mesurer la performance de l'apprentissage, nous comparons le pourcentage de bonnes détections obtenus sur l'échantillon test par rapport à la taille de l'échantillon (nombre de clichés) d'apprentissage pour chacune des 130 adventices à disposition.

Que se soit sur DICOT ou GRAM, plus le nombre d'images d'apprentissage est grand plus le taux de succès est grand et les écarts-type de prévisions sont petits (Fig. 5). Pour une taille d'échantillon d'apprentissage de 100 images, les pourcentages de bonnes prévisions sont supérieures à 50% avec en moyenne $83 \pm 12\%$ contre $49 \pm 46\%$ pour une taille d'échantillon inférieure à 100.

Figure 5 : Pourcentage de bonnes détections de l'adventice sur l'échantillon test par rapport au nombre d'images disponibles par adventice. (Percentage of good detections on the test sample compared to the number of images available by weed)



DISCUSSION

Le potentiel du deep learning et autres domaines de l'intelligence artificielle en plein développement actuellement semble énorme. Le fait de donner la capacité d'apprendre à la machine, par elle-même, quelle que soit la situation et sans que l'on ait formellement à écrire toutes les règles permet de proposer rapidement des applications.

L'identification des plantes est souvent délicate car les critères sur lesquels se fonde la détermination sont quelquefois difficiles à observer (découpe et structure foliaire, ligule, oreillettes, pilosité, couleur ...). Nous avons voulu valider dans ce travail, au travers de la reconnaissance des plantes, que ces nouvelles technologies associées à notre photothèque qualifiée par nos experts pouvaient aider nos clients dans leurs tours de plaine et les sécuriser dans leur conseil desherbage.

L'analyse d'images peut aider à la reconnaissance des structures visibles et proposer une ressemblance par rapport à une base d'entraînement et compléter les clés de détermination classique. Bien que ces techniques proposent rarement une vision détaillée de la structure en trois dimensions de la plante, qu'elles s'intéressent très peu à l'appareil souterrain et ne prennent pas en compte les critères d'odeur ou de saveur qui pourraient éviter les confusions toujours possibles, les résultats obtenus sont surprenants ! Le taux de succès d'identifications sur monocotylédones est inattendu car bien que les ressemblances soient grandes pour les graminées le réseau de neurones entraîné distingue à plus de 50% les adventices comme panic pied-de-coq (ECHCG), pâturin annuel (POAAN), digitale sanguine (DIGSA), ray-grass anglais (LOLPE) et sétaire verte (SETVI) qui lui sont présentées. Le gradient de forme et de découpe des feuilles en fonction des stades juvéniles et des stades adultes semble être pris en compte par le réseau de neurones sur les monocotylédones. En effet, dans plus de la moitié des situations : mercuriale annuelle (MERAN), morelle noire (SOLNI), renouée liseron (POLCO), chénopode blanc (CHEAL), véronique de Perse (VERPE), séneçon vulgaire (SENVU), stellaire intermédiaire (STEME), renouée persicaire (POLPE), amarante réfléchie (AMARE), renouée des oiseaux (POLAV), lychnis dioïque (MELAL), matricaire camomille (MATCH), gaillet gratteron (ALAP), repousse de colza (BRSNN), laituron rude (SONAS), coquelicot (PAPRH), géranium disséqué (GERDI), pensée des champs (VIOAR), chénopode hybride (CHEHY), fumeterre officinal (FUMOF), linaria élatine (KICEL), mouron des champs (ANGAR), lamier pourpre (LAMPU), abutilon de Théophraste (ABUTH), datura stramoine (DATST), prêle des champs (EQUAR), ravenelle (RAPRA) sont détectées.

L'approche « boîte noire » de ce type d'approche, rend difficile l'établissement de causalité dans l'interprétation et l'explication des résultats. Prenez vous en « selfie » et l'algorithme vous donnera la ressemblance avec l'une des 92 adventices la plus proche, sans possibilité de comprendre facilement pourquoi !

La limite (mais aussi la force) de cette technique statistique réside dans le nombre et la diversité d'images d'entraînement dont on dispose. Nous avons montré qu'un minimum de 100 images en moyenne par adventice et par stade semblerait être idéal pour permettre un apprentissage correct dans notre cas. En dessous de cet effectif les résultats sont moins robustes et nous avons choisi de ne pas les proposer dans Proximaïs® iTech. Mais malgré de gros efforts de recherche pour couvrir 32 adventices parmi plus de 500 identifiées en France métropolitaine nous nous demandons si le seuil de 100 photographies convient vraiment suivant les caractéristiques des adventices. Nous avons remarqué que dans le cas de certaines adventices ayant des caractéristiques très spécifiques (Fig. 6) comme le pourpier maraicher (POROL) un nombre de 76 clichés donne 100% de taux de reconnaissance (Fig. 5). A l'inverse pour des espèces avec des caractéristiques moins marquées comme le lychnis dioïque (MELAL) nous observons un taux de 55% de reconnaissance seulement pour un nombre d'images d'entraînement de 276 (Fig. 5 et 6).

Figures 6: Caractéristiques morphologiques des plantules et environnement de l'image A : *Lychnis dioïque* (MELAL) sur sol argileux motteux avec des résidus de graminées et des feuilles, B : Pourpier maraîcher (POROL) sur sol sableux à graviers. (Morphological characteristics of seedlings and image environment A : *Silene latifolia subsp. alba* on clay soil with grasses and leaves , B : *Portulaca oleracea* on sandy soil with gravel)



Nous nous interrogeons également sur la manière dont est prise en compte la variabilité de l'environnement et de la qualité de l'image de la plante (texture du sol, résidus de cultures, dégâts d'insectes ou de maladies, ensoleillement, ombres ...) par le réseau de neurones (Fig. 6). Il est à ce jour difficile d'y répondre et une étude plus fine mériterait d'être conduite afin d'optimiser les filtres sur les images avant le processus de reconnaissance.

Enfin, l'application Proximaïs® iTech permet de détecter isolément une plante, ce qui apporte de l'innovation dans le conseil. Des progrès sont attendus en la matière car pour conseiller un programme de désherbage, il faudra être capable de détecter plusieurs individus (fréquences et intensités) avec des inter-rangs faibles, voire sur le rang et des superpositions possibles entre les plantes (Varraillon *et al*, 2016).

CONCLUSION

L'identification d'une plante, habituellement effectuée par les experts, se base sur l'observation de ses organes et en majeure partie sur des critères visuels. Ceci permet d'envisager d'utiliser le deep learning pour élaborer un processus de reconnaissance automatique de l'espèce végétale à partir de la donnée d'une image.

Cette nouvelle approche nous a permis, grâce à l'accumulation de plus de 19 000 clichés pris sur nos sites d'expérimentation et un travail minutieux d'identification de chacune des adventices, d'ajouter une nouvelle fonctionnalité à notre service Proximaïs® iTech. Elle apporte une aide pour conseiller un programme herbicide en fonction des flores présentes.

Ainsi 32 adventices dont 5 graminées à différents stades de développement sont détectées avec 83% de succès en moyenne. Le taux de succès étant proportionnel au nombre d'images du jeu d'apprentissage, ces travaux nous encouragent à poursuivre nos efforts dans le futur sur l'acquisition d'autres photos pour les 88 espèces d'adventices du maïs plus rares pour lesquelles nous disposons encore de trop faibles quantités d'images pour proposer des estimations au dessus de 50% de succès.

L'objectif de notre service est de reconnaître tôt les adventices pour utiliser le bon produit ou la bonne association au juste stade afin d'être le plus efficace possible et limiter précocement la concurrence de ces adventices identifiées sur la culture du maïs.

REMERCIEMENTS

Nous souhaitons remercier particulièrement nos collègues, expérimentateurs et ingénieurs conseil, de Syngenta S.A.S France pour l'acquisition des clichés photographiques et la mise à disposition de celles-ci.

BIBLIOGRAPHIE

Lancashire et al., 1991, Echelle BBCH améliorée 2ème édition, 1997 - Compendium pour l'identification des stades phénologiques des espèces mono- et dicotylédones cultivées.

Lecun Y., 2016 - L'apprentissage profond (Cours en ligne). <https://www.college-de-france.fr/site/yann-lecun/course-2015-2016>.

Mamarot J. & Rodriguez A., 2014 - ACTA, Mauvaises herbes des cultures. 569p.

Toulon N., 2018 - Deep learning et agriculture, Une étude de la Chaire AgroTIC - Novembre 2018. 49p.

Varraillon T., Pierre J.B. & Jumel F. 2016 - Application smartphone de traitement d'images en proximité pour distinguer automatiquement le salissement de l'inter-rang et le recouvrement des céréales – AFPP – 23ème conférence du COLUMA Journées internationales sur la lutte contre les mauvaises herbes Dijon – 6, 7 et 8 décembre 2016.