

DISCRIMINATION AUTOMATIQUE DES ESPÈCES PAR IMAGERIE ET INTELLIGENCE ARTIFICIELLE

APPLICATION AU CAS DE L'AMBROISIE A FEUILLES D'ARMOISE

A. THÉBAULT ⁽¹⁾, S. PIERRON ⁽²⁾, A. ACHARD ⁽¹⁾

⁽¹⁾ Carbon Bee AgTech, Rovaltain - Parc du 45° parallèle, 11 rue Olivier de Serres, 26300
Châteauneuf-sur-Isère

⁽²⁾ Corteva Agriscience, Paris, France

RÉSUMÉ

Des solutions innovantes permettent aujourd'hui de discriminer différents groupes de plantes (ex : graminées vs. dicotylédones) ou, plus largement, les adventices de la culture d'intérêt. L'identification précise des espèces demeure toutefois largement empirique, menant à de nombreuses incertitudes. Les algorithmes d'intelligence artificielle sont de puissants outils de discrimination d'objets. Dans ce cadre, Carbon Bee AgTech propose une offre innovante de détection d'espèces par imagerie grâce à une technologie reposant sur l'utilisation d'un capteur hyperspectral, adapté à une utilisation sur le terrain, associé à des algorithmes d'intelligence artificielle. Une étude a été menée sur trois saisons dans le but d'estimer la capacité de cette solution à discriminer l'ambrosie à feuilles d'armoise des autres adventices dans divers contextes agricoles. Les données ont été acquises sur le terrain via le capteur hyperspectral puis annotées. L'intelligence artificielle développée par Carbon Bee a permis d'élaborer une base de connaissances basée sur plus de 700 images d'ambrosie annotées. Globalement, la base de connaissances permet de détecter plus de 90% des pieds d'ambrosie. Les résultats de détection varient en fonction du stade de développement de la plante et du contexte, avec un meilleur taux de détection en contexte maïs et tournesol qu'en orge de printemps. Les résultats doivent être confirmés en 2019 et élargis à une plus grande variété de contextes, notamment les milieux fermés.

Mots clés : intelligence artificielle, imagerie agronomique, hyperspectral, désherbage, ambrosie

SUMMARY

Nowadays, innovative solutions allow to discriminate different groups of plants based on their phenological traits (e.g. grasses vs. broadleaf) or, more widely, weeds in crops. However, the precise identification of species is still based on human expertise, leading to some uncertainties or mistakes. Artificial intelligence algorithms are powerful tools to detect objects. In this context, Carbon Bee AgTech proposes an innovative solution of species discrimination based on the coupling of in-field hyperspectral imagery and artificial intelligence algorithms. A three-year study has been done to test the ability of this solution to specifically discriminate the common ragweed in different agricultural contexts. Data were acquired in the field via the hyperspectral sensor and annotated. Carbon Bee's artificial intelligence allowed to build a relevant knowledge base based on more than 700 annotated pictures. Overall, the knowledge base presents promising results with more than 90% detection of ragweed plants. Performances vary between ragweed's development stage and contexts, with better results in maize and sunflower than barley. These results need to be consolidated in 2019 and widen to more contexts, including high vegetation density areas.

Keywords: artificial intelligence, agronomic imagery, hyperspectral, weeding, ragweed

INTRODUCTION

Les objectifs du plan Ecophyto (réduction de l'utilisation des produits phytosanitaires de 25% d'ici 2020 et 50% à l'horizon 2025) impliquent une mutation profonde des systèmes de production et le développement de solutions innovantes, moins impactantes pour l'environnement et la santé (Cerf *et al*, 2017; Butault *et al* 2010). Au cours des dernières décennies, de nombreux outils visant à optimiser la croissance des plantes et la consommation d'intrants ont été développés. Le développement des nouvelles technologies telles que les capteurs, drones et autres objets connectés permet une meilleure connaissance des systèmes agricoles. La facilité d'acquisition d'information objective sur l'état des parcelles via ces nouvelles technologies permet une meilleure gestion des interventions au sein de l'itinéraire technique, en apportant les produits adaptés, aux bonnes doses et au moment opportun (Taylor et Whelan 2005; Weis *et al*, 2008; Esfahani and Asadiye, 2009). La réduction des intrants dans les systèmes agricoles nécessite, a minima, une surveillance précise sur le terrain et une application localisée. Dans ce cadre, de nombreux efforts de recherche se focalisent sur le diagnostic de la parcelle et notamment la détection des adventices (Slaughter *et al*, 2008; Weis *et al*, 2008; Christensen *et al*, 2009; Berge *et al*, 2012; López-Granados *et al*, 2016; Barrero and Perdomo, 2018 ; Kunz *et al*, 2018). La détection la plus précoce possible permet une gestion tactique des applications herbicides alors qu'une détection tardive permet une gestion stratégique visant à envisager une gestion intégrée dans la rotation et à optimiser les traitements de l'année suivante (Koger *et al*, 2003; López-Granados, 2011).

Le développement des capteurs, drones et autres objets connectés a permis d'élaborer diverses solutions de détection d'espèces en proxy- et télédétection (Gebbers, 2014). Alors que la télédétection permet d'avoir une information de l'ordre du décimètre, voire centimètre, la proxy-détection permet des traitements de données à l'échelle millimétrique. Aujourd'hui, seule la proxy-détection permet une action simultanée à la détection, permettant l'optimisation de l'itinéraire technique (López-Granados, 2011). Parallèlement, le développement des technologies de l'information et des outils informatiques permet aujourd'hui de traiter de grandes quantités d'information en un temps limité. Dans ce cadre, l'exploitation de l'imagerie par intelligence artificielle s'annonce très prometteuse pour la détection d'objets d'intérêt dans un milieu complexe (Christensen *et al*, 2009). Dans ce contexte, la société Carbon Bee AgTech s'appuie sur un couplage d'imagerie et d'intelligence artificielle pour discriminer des espèces basées sur leurs caractéristiques de couleur, texture et structure notamment. Associée à un équipement adapté (rampe de pulvérisation à coupe de tronçons, pulvérisation buse à buse, robot bineur, ...), la détection automatisée d'adventices permettrait d'optimiser les itinéraires techniques. Cette détection automatisée présente également un intérêt dans le contexte expérimental de tests d'efficacité herbicides en permettant une notation automatique et objective de la présence et des taux de couverture des adventices.

L'ambrosie à feuilles d'armoise (*Ambrosia artemisiifolia*) est une plante exotique envahissante provenant d'Amérique du Nord et dont l'aire de propagation s'accroît rapidement en France et en Europe. Le caractère allergène de ses pollens amène d'importants problèmes de santé publique. Les coûts de santé provoqués par l'Ambrosie se sont élevés à plus de 40 millions d'euros en 2016 (Observatoire régional de la santé Auvergne-Rhône-Alpes, 2017). L'ambrosie se développe notamment dans les espaces laissés nus ou non entretenus des zones agricoles et non agricoles (Arvalis, 2012). Dans la Drôme, région particulièrement touchée par l'ambrosie, 80% des surfaces infestées sont des parcelles agricoles. Les chaumes et le tournesol représentent la grande majorité des surfaces agricoles touchées (50% et 20% respectivement, Ministère des solidarités et de la santé, 2018). Dans ces parcelles agricoles, l'ambrosie peut être traitée via le plan de traitement de l'exploitant, notamment par la pulvérisation localisée. Dans les milieux non agricoles, elle se développe notamment dans les milieux ouverts et peut devenir prépondérante en l'absence de compétition. Dans une optique de prévention et traitement, il est indispensable de pouvoir également détecter l'espèce dans de tels milieux, a minima avant floraison.

Dans ce cadre, une étude a été mise en place en 2017 et reconduite en 2018 et 2019 en association avec Dow-Corteva Agrisciences et Qualiphyt afin d'estimer la capacité d'une solution de

couplage d'imagerie et intelligence artificielle à détecter l'ambrosie à feuilles d'armoise à différents stades et dans différent milieux. L'ambrosie à feuilles d'armoise sera désignée par le terme « ambrosie » dans toute la suite de l'étude. Cette étude porte sur la capacité de la solution Carbon Bee à détecter l'ambrosie dans différents contextes agricoles aux passages usuels de traitements herbicides. Une seconde partie abordera la capacité de la solution à estimer le taux de recouvrement de l'ambrosie avec une précision satisfaisante en contexte expérimental dans le cas d'étude d'efficacité de traitement herbicides.

MATERIEL ET METHODES

L'étude porte sur 4 parcelles de la région Rhône-Alpes, correspondant à 5 contextes agricoles : blé d'hiver, orge de printemps, maïs, et tournesol. Deux à quatre acquisitions d'images ont été effectuées sur chacune des parcelles entre 2017 et 2018 (Tab. I). Les dates de passage ont été choisies en accord avec des dates de désherbage. La parcelle d'Orge de printemps été suivie conjointement en 2018 avec la société Qualiphyt afin d'avoir des notations de présence d'ambrosie par des experts. Les images ont été acquises avec le capteur AQiT-Sensor de Carbon Bee, permettant d'acquérir simultanément trois images balayant le spectre de 300 à 1000 nm, avec une définition de 5 millions de pixels par image (Fig. 1).

Figure 1 : Le capteur AQiT-Sensor développé par Carbon Bee
(AQiT-Sensor developed by Carbon Bee)



Tableau I : Détail des prises de données
(Details of data acquisition)


	Blé d'hiver	Maïs	Tournesol	Orge de printemps
Passage 1	16/06/2017	13/04/2018	09/05/2018	07/05/2018
Passage 2	22/06/2017	27/04/2018	29/05/2018	16/05/2018
Passage 3	17/07/2017	04/05/2018		19/06/2018
Passage 4		18/05/2018		28/06/2018

Acquisition de données

Sur chacune des parcelles et lors de chaque prise de vue, deux types d'acquisition de données sont réalisées avec le capteur AQiT-Sensor. Une première prise de vue manuelle est effectuée à 50 cm au-dessus de la végétation permettant d'avoir des images en haute définition (Fig. 2a). Cette prise de vue permet d'avoir une visualisation d'une surface au sol de l'ordre de 0.25m². La seconde prise de vue est effectuée en positionnant le capteur sur un vecteur expérimental à 1.50 m au-dessus du sol afin de simuler une acquisition de données effectuée par un capteur embarqué sur un engin agricole (Fig. 2b), permettant de visualiser une surface au sol de l'ordre de 2.5m². Aucun éclairage n'est ajouté.

Figure 2 : exemple de prise de données à 50 cm (a) et 1.50 m (b) en contexte Orge de printemps (acquisition du 17/05/2018)

(example of data acquisition at 50 cm (a) and 1.50m (b) in spring barley (data from 17/05/2018))



Construction du jeu de données d'apprentissage

Les données acquises sont ensuite annotées par un expert agronomique, i.e. tous les pieds d'ambrosie présents sur les clichés sont colorés (Fig. 2). Cette phase d'annotation permet d'apprendre à l'intelligence artificielle à reconnaître la cible recherchée, i.e. l'ambrosie. La construction du jeu de données d'apprentissage est faite de manière à intégrer le plus de contextes possibles, afin d'assurer la robustesse de l'algorithme. Au total, 781 images ont été annotées, présentant des ambrosies dans des contextes variés en termes d'environnements, de stades de développement et d'ensoleillement notamment (Tab. II). Les données acquises en 2017 sur blé d'hiver présentant une sur-exposition rendant difficile la détection et donc l'annotation d'ambrosie, ont été écartées pour le reste de l'étude

Figure 2 : exemple d'annotation d'ambrosie dans différents contextes : (a) orge de printemps (b) tournesol et (c) maïs

(example of picture annotation of common ragweed in different environments: (a) spring barley (b) sunflower and (c) maize)



Tableau II : Détail des annotations sur les différents contextes agricoles
(Annotation details in studied areas)

	Nombre de clichés annotés	Nombre de stades
Blé d'hiver	5	1
Maïs	523	4
Tournesol	178	2
Orge de printemps	75	4

Entraînement de l'intelligence artificielle


Un réseau de neurones se définit par sa « structure » (comportement et modalité d'interconnexion des neurones) et sa « configuration » (la pondération des différentes interconnexions, (Fig. 3). « Deep Learning » est le terme générique pour les structures « profondes », c'est-à-dire comportant plusieurs couches de neurones interconnectés. Ces couches servent à élaborer des degrés d'abstraction, chacune possédant un niveau de recul supplémentaire sur les données réelles. Pour cette étude, un réseau de neurones convolutifs est utilisé, du même type que SegNet (Badrinarayanan *et al*, 2017). Ce réseau reprend les caractéristiques usuelles des réseaux de neurones, notamment une fonction de coût basée sur la moyenne balancée du carré des écarts, l'utilisation de l'algorithme ADAM

pour la back-propagation, la sélection de modèle basé sur le coefficient de corrélation de Matthews (MCC) et enfin la séparation du jeu de données en un jeu d'entraînement et de test (70/30 % des données respectivement). L'entraînement de l'intelligence artificielle (IA) correspond à paramétrer le réseau de neurones convolutifs afin qu'il détecte correctement l'objet d'étude. Plusieurs itérations sont nécessaires pour définir les paramètres optimaux en termes de nombre de couches de convolution et de structure des données d'entrée. Les différents paramètres testés sont le type de données d'entrée (nature, taille), le nombre de couches de convolution et le paramètre de binarisation des probabilités de reconnaissance.

Sélection de modèle

Le modèle sélectionné pour cette étude présente de très bons résultats de détection à l'échelle du pixel. Le réseau de neurones détecte 84% des pixels d'ambrosie sur le jeu de données test et présente un taux d'erreur de 16%. Le paramètre de seuil de détection permet de binariser la détection de l'intelligence artificielle (Fig. 3). La valeur de ce paramètre de seuil dépend de l'usage qu'il serait fait de la détection et de l'acceptation de l'utilisateur final en termes d'erreur de détection. Dans le cadre de cette étude, il a été fixé à 98% pour la détection et 95% dans le cadre de l'analyse de la surface couverte par l'ambrosie.

Figure 3 : exemple de sortie graphique obtenue pendant la phase d'apprentissage
(example of neural network output for expert analysis)



Evaluation des performances

L'évaluation des performances de l'IA a été estimée en termes de (1) détection de pieds d'ambrosies en vue d'une pulvérisation localisée et (2) d'estimation du taux de recouvrement, en lien avec les essais de tests d'efficacité d'herbicides. Les performances de l'IA à détecter les pieds d'ambrosie en milieu agricole ont été estimées visuellement par un expert. Dans un premier temps, 75 images prises à 50 cm, non utilisées dans la construction de l'IA, ont été choisies aléatoirement dans chacun des quatre contextes et analysées visuellement par un expert afin de calculer le taux de détection de l'ambrosie (i.e. le pourcentage de pieds d'ambrosie détectés par l'IA dans l'image) et le taux de confusion de l'IA correspondant au pourcentage de plantes détectées par l'IA comme étant de l'ambrosie, mais ne l'étant pas selon l'expert. Dans un second temps, une analyse de la détection à 150 cm, avec indication, pour chaque zone, de la présence ou absence d'ambrosie, quelque soit le nombre de pieds a été effectuée. A cette fin, les images prises à 150 cm de hauteur ont été découpées en 9 vignettes de 864*864 pixels. Pour chaque contexte, 100 vignettes choisies aléatoirement ont été analysées. Les résultats sont présentés sous la forme d'un tableau de contingence.

Dans le cadre de l'étude d'efficacité herbicide, un essai ayant pour objectif de comparer l'efficacité de quatre modalités de traitements herbicides sur l'ambrosie a été mis en place en contexte

Orge de Printemps par la société Qualiphyt. La parcelle a été découpée en 18 placettes de 25m², réparties sur trois blocs, chaque bloc étant composé de 6 placettes correspondant aux 4 traitements herbicides et 2 placettes non traitées (témoin), organisées aléatoirement. Des notations expertes ont été effectuées à trois reprises sur les placettes afin de mesurer l'efficacité des traitements herbicides en comparant les taux de recouvrement d'ambrosies dans les placettes de traitement aux taux de recouvrement dans les parcelles témoins (i.e. parcelles non traitées). Parallèlement, les taux d'efficacité de traitement estimés par l'IA ont également été estimés en comparant le recouvrement d'ambrosie issus de la détection automatique par l'IA dans les parcelles traitées et les parcelles témoins. Les performances de l'IA ont été estimées quantitativement en comparant les taux d'efficacité d'herbicide estimés par les experts sur les placettes aux taux estimés par l'IA. Une analyse de variance, suivie d'un test de Tukey a permis de comparer les effets des traitements estimés par (1) les notations expertes et (2) les notations automatiques de l'IA. Les analyses statistiques ont été réalisées avec R (R Development Core Team 2018).

RESULTATS

Détection des ambrosies en contexte agricole

Le taux de détection de l'ambrosie toutes cultures confondues est de 90.1 %. La détection est meilleure dans une culture de maïs et tournesol (94.0% et 93.0% respectivement) que dans l'orge de printemps (80.4%). En maïs et orge de printemps, le taux de détection de l'ambrosie augmente avec le stade de la culture et par conséquent le développement des ambrosies (Tab. III).

Tableau III : Taux de détection de l'ambrosie dans les contextes agricoles
(detection rate of common ragweed in different crops)

Culture	Stade BBCH culture	Stade ambrosie	Nombre total d'ambrosies	Taux de détection (%)	Taux de confusion (%)
Maïs	BBCH 12	2 feuilles	15	66.7	48.7
	BBCH 13	4 feuilles	58	98.3	47.9
	BBCH 15	6 feuilles	27	100.0	1.9
Tournesol	BBCH 17	8 feuilles	988	97.8	12.1
	BBCH 38	> 8 feuilles	282	76.2	14.8
Orge de printemps	BBCH 30	2 feuilles	111	56.8	5.2
	BBCH 45	4 feuilles	125	78.4	8.2
	BBCH 75	Proche floraison	118	94.1	30.2
	BBCH 87	Proche floraison	69	98.6	9.5

Bien que le taux de détection d'ambrosie soit plus faible en orge de printemps qu'en maïs et tournesol, la base de connaissance se révèle plus discriminante puisque moins de 10% des plantes détectées par l'IA comme de l'ambrosie sont d'autres adventices (Tab. III). En contexte maïs, ce taux d'erreur s'élève à 50% dans les stades précoces (ambrosies au stade 2-4 feuilles) mais est inférieur à 2% au stade le plus tardif. Le taux de confusion en tournesol est de l'ordre de 15%, quelque que soit le stade de développement de la culture étudié (Tab. III).

Sur prise de données à 1.5 m, les taux de détection sont supérieurs à 95% en maïs et tournesol et à 85% en orge de printemps (Tab. IV). Quels que soient la culture et le stade, l'absence de confusion sur les zones ne présentant pas d'ambrosie atteste de la solidité de la discrimination par rapport aux autres adventices.

Tableau IV : Taux de détection de l'ambrosie à l'échelle de la zone d'action de la buse de pulvérisation
(detection rate of common ragweed at boom spray scale)

Description des zones (0.20m ²)	Taux de détection (%) par l'IA
Maïs	
Absente (73 zones)	0


Présente (27 zones)	96.3%
Tournesol	
Absente (10 zones)	0
Présente (90 zones)	100%
Orge de printemps	
Absente (52 zones)	0
Présente (48 zones)	85.4%

Estimation des taux d'efficacité des herbicides

Les taux d'efficacité estimés par l'IA sont relativement proches des estimations expertes (Fig. 4). Lorsque les efficacités entre modalités sont contrastées, les résultats de l'IA et des experts sont comparables (Fig. 4a). En revanche, du fait de la plus faible variabilité des notations expertes entre les répétitions de traitements sur les forts taux d'efficacité, les effets modalités apparaissent plus nettement sur les notations expertes. En effet, alors que les notations expertes montrent une efficacité herbicide significativement plus forte sur les modalités 3 et 4 par comparaison aux modalités 2 et 5, les calculs d'efficacité par l'intelligence artificielle ne montrent aucune différence significative entre les modalités (Fig. 4b et Fig. 4c). La reconnaissance de l'ambrosie par l'IA ne permet donc pas d'appréhender avec autant de précision qu'un œil expert des différences fines de recouvrement.

Figure 4 : comparaison entre les efficacités des traitements herbicides mesurés par les experts (jaune) et l'IA (gris). Les lettres représentent les différences significatives (test de Tukey) d'efficacité entre traitements, respectivement selon les notations expertes (majuscules) ou la notation automatique par l'IA (minuscule)

(comparison between herbicides treatment efficiency as measured by experts (yellow) and AI (grey). Letters represent significant differences between treatments according to Tukey tests, following respectively expert notation (uppercase) and IA automatic notation (lowercase))



Détection de l'ambrosie dans d'autres contextes

La base de connaissances élaborée sur les cultures de maïs, tournesol, orge de printemps et dans une moindre mesure blé a été testée dans différents contextes agricoles tels que les rangs enherbés de vigne, une jachère agricole et du sorgho. La détection s'est révélée prometteuse en culture sarclée comme le sorgho. Cette base de connaissances nécessitera plus d'annotations en milieux fermés tels que la jachère ou les rangs de vigne pour une utilisation opérationnelle.

DISCUSSION ET CONCLUSION

Cette étude avait pour objectif d'estimer la capacité d'une solution de couplage d'imagerie agronomique et d'intelligence artificielle à détecter l'ambrosie dans divers contextes agricoles. Les résultats sont principalement basés sur les données acquises en 2018 dans trois contextes agricoles différents, i.e. le maïs, le tournesol et l'orge de printemps. L'efficacité de la solution porte sur deux aspects majeurs que sont le fonctionnement d'une même base de connaissance dans différents contextes et la capacité de la détection à discriminer l'ambrosie des autres adventices. En effet, le développement des capteurs et la diminution de leur coût voit aujourd'hui éclore sur le marché agricole des solutions de détection automatisées d'adventices (WeedSeeker® (Trimble Agriculture, Sunnyvale, CA, USA), Weed-it® (Rometron, CJ Steenderen, Netherlands)). Ces solutions se basent sur la détection de la chlorophylle, ce qui limite leur application à certaines périodes de l'itinéraire technique. Par ailleurs, la majorité des travaux présentés à ce jour ne discriminent pas les adventices (Louargant, 2016 ; Wang *et al*, 2019). L'absence de discrimination peut tout à fait s'avérer acceptable pour certaines adventices, mais dans le cas de l'ambrosie qui nécessite un contrôle particulier avec notamment des obligations réglementaires, la détection spécifique est indispensable.

Les traitements herbicides sont plus efficaces sur les stades jeunes des ambrosies (inférieur à 6 feuilles, Frédon, 2018). En maïs, les taux de détection supérieurs à 98% aux stades 4 à 6 feuilles de l'ambrosie montrent une efficacité opérationnelle de la solution, notamment en rattrapage post-levée. En orge de printemps, les taux de détection plus faibles, probablement liés à un inter-rang plus faible et un taux de recouvrement de la culture plus élevé, sur les jeunes ambrosies (50 à 80% de détection), ne permettent pas, à ce jour, un contrôle herbicide par la solution. Toutefois, les taux de détection supérieurs à 95% associés à un taux de confusion inférieur à 10% avant floraison permettraient de contrôler l'ambrosie à des stades plus tardifs tels que lors du déchaumage par exemple. En tournesol, les images ont été acquises trop tardivement pour évaluer la capacité de détection de la solution à des stades précoces (avant 6 feuilles). Néanmoins, les forts taux de détection au stade 8 feuilles associés à un faible taux de confusion laissent présager une détection prometteuse aux stades plus jeunes. Des prises de données plus précoces en cultures de tournesol en 2019 devraient permettre d'affiner ce résultat. Les excellents taux de détection sur images acquises à 1.50m dans les trois contextes et quels que soient les stades des cultures démontrent l'intérêt opérationnel d'une telle solution dans un contexte de désherbage chimique localisé avec capteur embarqué sur rampe de pulvérisation. L'absence totale d'erreur de détection sur les zones ne présentant pas d'ambrosie montre la capacité de la solution, couplée à de la pulvérisation buse à buse, à optimiser significativement les applications herbicides dans les parcelles. Cette étude constitue, à notre connaissance, la première ébauche de solution de discrimination d'une espèce adaptée à divers contextes agricoles.

Les algorithmes d'intelligence artificielle et notamment les réseaux de neurones convolutifs sont reconnus comme des outils performants pour la classification d'espèces intégrant la possibilité de détection en temps réel (Bosilj *et al*, 2018) . Toutefois, ces méthodes sont souvent décriées pour leur forte demande en données d'apprentissage, notamment pour arriver à une robustesse des détections en contextes variés (Lottes *et al*, 2018 ; Slaughter *et al*, 2008). Dans le cadre de cette étude, la base de connaissances a été élaborée à partir de moins de 1000 images. L'atout majeur de la méthodologie est l'ajout d'un nouveau contexte à moindre coût. En effet, l'ajout d'uniquement 75 images annotées en

orge de printemps permet d'atteindre des taux de détection supérieurs à 90% sur les stades tardifs. Par ailleurs, la base de connaissances présente l'avantage de travailler sur tous les stades de l'ambrosie. Enfin, la détection a montré de la robustesse sous éclairage variable puisque les images ont été acquises entre mars et juillet 2018, sous diverses conditions météorologiques.

Dans cette étude, le couplage de l'imagerie agronomique et de l'intelligence artificielle pour la discrimination d'espèces a permis d'élaborer une base de connaissances ambrosie opérationnelle dans différents contextes et à différents stades des cultures et de l'adventice. Les performances obtenues sur les vignettes à 1.50 m du sol montrent l'adéquation de cette solution avec un positionnement des capteurs sur une rampe de désherbage pour une détection en temps réel. Dans le cadre de la détection d'ambrosie, ces résultats, bien que prometteurs, nécessitent une amélioration. Pour cela, l'accent sera mis sur la saison 2019 pour aborder des stades plus précoces de tournesol et travailler dans les milieux plus fermés telles que les jachères agricoles, les bords de routes, de parcelles et les talus.

REMERCIEMENTS

Carbon Bee AgTech remercie chaleureusement Arthur Jeanselme et Simon Dennonain pour la prise de données ainsi que Audrey Anglade, Laura Grégoire et Perrine Achard pour les annotations et les comptages. Nous remercions également Colin Chaballier pour son approche marché et Anthony Gélibert, Clément Douarre et Gérald Germain (Carbon Bee) pour leurs conseils et les développements sur l'intelligence artificielle. Les auteurs remercient Mélanie Gressard, Guillaume Giroudon et Guillaume Veré (Qualiphyt) pour leur expertise et leur collaboration dans ce projet.

BIBLIOGRAPHIE

- Arvalis, 2012. Intervenir dès l'interculture pour gérer l'ambrosie à feuilles d'armoise. Disponible en ligne : <https://www.arvalis-infos.fr/intervenir-des-l-interculture-pour-gerer-l-ambrosie-a-feuilles-d-armoise-@/view-16214-arvarticle.html>
- Badrinarayanan V., Kendall A., Cipolla R., 2017. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Trans Pattern Anal Mach Intell* 39, 2481–2495. <https://doi.org/10.1109/TPAMI.2016.2644615>
- Barrero O., Perdomo S.A., 2018. RGB and multispectral UAV image fusion for Gramineae weed detection in rice fields. *Precision Agriculture* 19, 809–822. <https://doi.org/10.1007/s11119-017-9558-x>
- Berge T.W., Goldberg S., Kaspersen K., Netland J., 2012. Towards machine vision based site-specific weed management in cereals. *Computers and Electronics in Agriculture* 81, 79–86. <https://doi.org/10.1016/j.compag.2011.11.004>
- Butault J.-P., Dedryver C.-A., Gary C., Guichard L., Jacquet F., Meynard J.-M., Nicot P., et al. 2010. Ecophyto R&D. Quelles voies pour réduire l'usage des pesticides?, Synthèse du rapport d'expertise, 90. Paris: INRA. Disponible en ligne : <https://www6.paris.inra.fr/depe/Projets/Ecophyto-R-D>.
- Bosilj P., Aptoula E., Duckett T., Cielniak G., 2018. Transfer learning between crop types for semantic segmentation of crops versus weeds in precision agriculture. *Journal of Field Robotics* 0, 1–13. <https://doi.org/10.1002/rob.21869>
- Cerf M., Bail L., Lussion J.-M., Omon B., 2017. Contrasting intermediation practices in various advisory service networks in the case of the French Ecophyto plan. *The Journal of Agricultural Education and Extension* 23, 231–244. <https://doi.org/10.1080/1389224X.2017.1320641>
- Christensen S., Sogaard H.-T., Kudsk P., Nørremark M., Lund I., Nadimi E.S., Jørgensen R., 2009. Site-specific weed control technologies. *Weed Research* 49, 233–241. <https://doi.org/10.1111/j.1365-3180.2009.00696.x>

- Esfahani L.P., Asadiye Z.S., 2009. The Role of Information and Communication Technology in Agriculture. In: 2009 *First International Conference on Information Science and Engineering*. Presented at the 2009 First International Conference on Information Science and Engineering, pp. 3528–3531. <https://doi.org/10.1109/ICISE.2009.1282>
- Frédon 2018. Comment lutter contre l'ambrosie. Article disponible en ligne (http://www.fredon-bourgogne.com/docs/ambrosie/2018_comment_lutter_contre_l'ambrosie.pdf)
- Gebbers R., 2014. Current Crop and Soil Sensors for Precision Agriculture. In : Congresso Brasileiro de Agricultura de Precisão, Sao Pedro, Brazil.
- Koger C.H., Shaw D.R., Watson C.E., Reddy K.N., 2003. Detecting Late-Season Weed Infestations in Soybean (*Glycine max*). *Weed Technology* 17, 696–704. <https://doi.org/10.1614/WT02-122>
- Kunz C., Weber J.F., Peteinatos G.G., Sökefeld*, M., Gerhards*, R., 2018. Camera steered mechanical weed control in sugar beet, maize and soybean. *Precision Agriculture* 19, 708–720. <https://doi.org/10.1007/s11119-017-9551-4>
- López-Granados F., 2011. Weed detection for site-specific weed management: mapping and real-time approaches. *Weed Research* 51, 1–11. <https://doi.org/10.1111/j.1365-3180.2010.00829.x>
- López-Granados F., Torres-Sánchez J., De Castro A.-I., Serrano-Pérez A., Mesas-Carrascosa F.-J., Peña J.-M., 2016. Object-based early monitoring of a grass weed in a grass crop using high resolution UAV imagery. *Agron. Sustain. Dev.* 36, 67. <https://doi.org/10.1007/s13593-016-0405-7>
- Lottes P., Behley J., Milioto A., Stachniss C., 2018. Fully Convolutional Networks With Sequential Information for Robust Crop and Weed Detection in Precision Farming. *IEEE Robotics and Automation Letters* 3, 2870–2877. https://doi.org/10.1007/978-3-319-48036-7_9
- Louargant M., 2016. Proxidétection des adventices par imagerie aérienne : vers un service de gestion par drone (Thèse de doctorat). Université de Bourgogne, Dijon, France. 238pp.
- Ministere des solidarités et de la santé, 2018. Disponible en ligne : <https://solidarites-sante.gouv.fr/sante-et-environnement/risques-microbiologiques-physiques-et-chimiques/especes-nuisibles-et-parasites/ambrosie-info/ambrosie-info/cartographie>
- National Research Council 1997. Precision Agriculture in the 21st Century: Geospatial and Information Technologies in Crop Management. Washington, DC: The National Academies Press. <https://doi.org/10.17226/5491>.
- Observatoire régional de la santé Auvergne-Rhône-Alpes, 2017. L'impact sanitaire de l'ambrosie en Auvergne-Rhône-Alpes : analyse des données médico-économique. Disponible en ligne : http://wd043.lerelaisinternet.com/pdf/Impact_sanitaire_ambrosie_ARA_2017.pdf
- Taylor J., et Whelan B. (2005). "A General Introduction to Precision Agriculture." *Grains Research & Development Corporation*. Disponible en ligne: http://www.agriprecisione.it/wp-content/uploads/2010/11/general_introduction_to_precision_agriculture.pdf
- Slaughter D.C., Giles D.K., Downey D., 2008. Autonomous robotic weed control systems: A review. *Computers and electronics in agriculture* 61 (1), 63-78.
- Wang A., Zhang W., Wei X., 2019. A review on weed detection using ground-based machine vision and image processing techniques. *Computers and Electronics in Agriculture* 158, 226–240. <https://doi.org/10.1016/j.compag.2019.02.005>
- Weis M., Gutjahr C., Rueda Ayala V., Gerhards R., Ritter C., Schölderl, F., 2008. Precision farming for weed management: techniques. *Gesunde Pflanzen* 60, 171–181. <https://doi.org/10.1007/s10343-008-0195-1>