

L'IA au service de l'agriculture : au cœur de l'expérience Agro'Deep

Philippe Borianne^a, Frédéric Théveny^b, Benoît Bertrand^c, Luc Villain^d, Émile Faye^e, Julien Sarron^f, Gaele Viennois^g, Frédéric Borne^h, Marc Jaegerⁱ

^a CIRAD, UMR AMAP, F34398 Montpellier, France.
AMAP, Univ Montpellier, CIRAD, CNRS, INRAE, IRD, Montpellier, France.
E-mail : philippe.borianne@cirad.fr

^b CIRAD, UMR AMAP, F34398 Montpellier, France.
AMAP, Univ Montpellier, CIRAD, CNRS, INRAE, IRD, Montpellier, France.
E-mail : frederic.theveny@cirad.fr

^c CIRAD, UMR DIADE, F34394 Montpellier, France.
DIADE, Univ Montpellier, CIRAD, IRD, Montpellier, France.
E-mail : benoit.bertrand@cirad.fr

^d CIRAD, UMR DIADE, F34394 Montpellier, France.
DIADE, Univ Montpellier, CIRAD, IRD, Montpellier, France.
E-mail : luc.villain@cirad.fr

^e CIRAD, UPR HortSys, F34390 Montpellier, France.
HortSys, Univ Montpellier, CIRAD, Montpellier, France.
E-mail : emile.faye@cirad.fr

^f CIRAD, UPR HortSys, F34390 Montpellier, France.
HortSys, Univ Montpellier, CIRAD, Montpellier, France.
E-mail : julien.sarron@cirad.fr

^g CNRS, AMAP, Univ Montpellier, CIRAD, INRAE, IRD, Montpellier, France.
E-mail : gaele.viennois@cirad.fr

^h CIRAD, UMR AMAP, F34398 Montpellier, France.
AMAP, Univ Montpellier, CIRAD, CNRS, INRAE, IRD, Montpellier, France.
E-mail : frederic.borne@cirad.fr

ⁱ CIRAD, UMR AMAP, F34398 Montpellier, France.
AMAP, Univ Montpellier, CIRAD, CNRS, INRAE, IRD, Montpellier, France.
E-mail : marc.jaeger@cirad.fr

RÉSUMÉ. — Force est de constater que, depuis une décennie, les réseaux de neurones pénètrent massivement le domaine de l'analyse d'image en agriculture de précision. Cet article présente les aspects conceptuels, techniques et pratiques de la plateforme numérique Agro'Deep, expressément développée pour le Calcul Applicatif (Applicative Computing) en agriculture numérique. Agro'Deep est centrée sur le traitement distant de données visuelles par réseaux de neurones profonds et propose des services de détection, de dénombrement et de caractérisation d'organes de plantes (fleurs, feuilles, fruits, arbres, etc.). Elle fournit à ses utilisateur.trice.s un cadre technique et un accompagnement méthodologique afin de développer, entraîner, adapter, valider et déployer des réseaux neuronaux de détection, de localisation et/ou de reconnaissance d'organes multiples, et met à leur disposition des réseaux neuronaux spécialisés pour des domaines spécifiques. Agro'Deep est une plateforme Web dédiée à des utilisateur.trice.s non spécialistes reposant sur un modèle économique équitable et participatif. Un accompagnement technique et/ou méthodologique par les ingénieur.e.s de la plateforme est possible à travers des collaborations scientifiques. Trois cas d'étude sont présentés à ce titre : l'utilisation des confusions du réseau de neurones pour une détection plus pertinente de cerises de caféiers, l'introduction d'une fonction d'identification par hystérésis pour une meilleure détection variétale des mangues dans des images couleur, et l'apport des images de synthèse pour entraîner un réseau de neurones à détecter des palmiers dans des images de couverts forestiers.

MOTS-CLÉS. — plateforme numérique, réseaux de neurones, agriculture de précision, Applicative Computing.

1. INTRODUCTION

1.1. CONTEXTE

Le développement durable d'une agriculture productive et soucieuse de la préservation de l'environnement et de l'intégration des aspects socio-économiques est étroitement lié à notre capacité collective à définir des modèles d'estimation de rendements multi-échelles, pertinents et réalistes tenant compte aussi bien des facteurs endogènes (diversité des espèces cultivées et de leurs cultivars) que des facteurs exogènes (environnement, bioagresseurs, pratiques agricoles, etc.). Établir et valider de tels modèles nécessite le plus souvent l'accès à des données fines collectées à grande échelle. Si l'utilisation de capteurs de collecte d'information s'est largement démocratisée ces dernières années avec notamment l'introduction de l'imagerie pour le suivi des cultures, le traitement des données acquises est souvent problématique. Mais en 2010, l'augmentation significative des capacités de calcul des ordinateurs remet l'Intelligence Artificielle (IA) au centre des pratiques les plus innovantes de l'agriculture de précision [6], notamment pour la détection des maladies, l'estimation de la qualité des cultures céréalières ou le phénotypage [66][36]. Ainsi, les réseaux de neurones pénètrent massivement le domaine de l'analyse d'image (détection et reconnaissance d'objets, extraction d'information) appliquée à l'agriculture tant pour le suivi des cultures [38] que pour l'estimation des rendements [38] et relèguent les méthodes plus conventionnelles de segmentation ou de classification au second plan. Mais l'appropriation et la mise en œuvre de ces méthodes restent compliquées [4] pour ne pas dire inaccessibles à de nombreuses communautés de recherche et de développement qui n'ont ni les moyens ni le temps d'investiguer ce domaine encore confidentiel de l'IA.

1.2. DE LA COMPRÉHENSION MÉTHODOLOGIQUE DES RÉSEAUX DE NEURONES À LEUR MISE EN ŒUVRE

Les réseaux de neurones, en tant que systèmes capables d'apprendre, s'appuient avant tout sur le principe de l'induction, c'est-à-dire de l'apprentissage par l'expérience. Le caractère générique de leur décision est fonction du nombre et de la représentativité des cas d'apprentissages fournis. Leur utilisation nécessite donc la collecte et l'annotation de données, souvent en nombre relativement important. Mais au-delà de cet aspect, la première difficulté à surmonter est leur déploiement même sur un ordinateur : la tâche est souvent plus complexe qu'il n'y paraît. En effet, les réseaux sont souvent développés dans des environnements spécifiques pris entre contraintes matérielles et logicielles parfois antinomiques qu'il est difficile de reproduire et de stabiliser. Dans tous les cas, ces déploiements nécessitent des compétences tant en système d'exploitation qu'en programmation.

L'intérêt majeur d'une plateforme est d'affranchir ses utilisateurs de ces désagréments techniques.

1.3. LES PLATEFORMES

Le Cloud Computing [3], *informatique en nuage en français*, est un terme général désignant l'accès à des services informatiques par internet. De nombreuses plateformes de Cloud Computing ont ainsi vu le jour ces dernières années. Elles offrent différents services allant de la mise à disposition d'espace de stockage à l'accès à des ressources dédiées au calcul intensif [22] permettant par exemple de déployer et d'instancier des réseaux de neurones. Les plus connues et importantes en termes de dimensionnement sont probablement les plateformes américaines Google Cloud [10][31] ou Microsoft Azure [35] et la plateforme chinoise Alibaba Cloud [91][47]. À l'échelle nationale, la plateforme française OVH cloud [11] et le Genci - *Grand Équipement National de Calcul Intensif* - proposent des solutions assez compétitives.

L'offre de calcul intensif est complétée par les plateformes de Calcul Haute Performance (High performance computing ou HPC) [26] qui consiste à associer de plusieurs milliers à plusieurs millions de processeurs pour construire des architectures de calcul en parallèle et diminuer les temps de calcul. Il s'agit là le plus souvent de solutions universitaires développées avec le soutien des régions ; par exemple,

la plateforme MESO@LR [55] a reçu le soutien de la Région Occitanie-Pyrénées-Méditerranée dans le cadre du projet CPER 2015/2020 (*Contrat de Plan État-Région*). Bien que proposant un accompagnement technique plus personnalisé, ces solutions s'adressent préférentiellement à des utilisateur.trice.s autonomes en programmation informatique.

A cela s'ajoutent des plateformes d'envergure plus petites dédiées et réservées à des communautés thématiques spécifiques. Par exemple, la plateforme MBB (*Montpellier Bio-informatique et Biodiversité*)[52] est un service commun de "Calcul scientifique" de l'Université de Montpellier reposant sur la mutualisation de ressources informatiques dédiées au calcul et à la bioinformatique. Elle propose non seulement un accès à des machines de calculs intensifs mais également une aide aux utilisateur.trice.s désireux d'y transposer leurs propres codes informatiques.

Mais ces plateformes restent inaccessibles pour des utilisateur.trice.s sans bagage informatique, confronté.e.s au besoin de *Calcul Applicatif*, c'est-à-dire à l'adaptation ou l'utilisation d'un environnement ou d'une méthode spécifique de calcul pour un cas applicatif particulier.

2. IMAGES ET RÉSEAUX DE NEURONES

L'image est devenue depuis une vingtaine d'années un support d'études majeur en agriculture de précision [83][44], et les réseaux de neurones profonds des méthodes d'analyse incontournables et efficaces [38].

2.1. LES RÉSEAUX DE NEURONES CONVOLUTIFS

En apprentissage automatique, un réseau de neurones convolutifs est un type de réseau de neurones artificiels acycliques dans lequel le motif de connexion entre les neurones est inspiré par le cortex visuel des animaux. Le concept des réseaux de neurones artificiels, présenté en 1943 par le neurophysicien Warren McCulloch et le mathématicien Walter Pitts [54], repose sur l'idée selon laquelle l'activation de neurones est l'unité de base de l'activité cérébrale. Le Perceptron, le premier réseau dédié à des tâches de reconnaissance de patterns complexes, est présenté en 1957 [79]. Faute de puissance de calcul, ces approches sont mises en sommeil et réapparaissent en force en 2010, boostées par l'essor technologique des calculateurs sous la pression des jeux vidéo. Pour faire simple, les réseaux neuronaux convolutifs consistent en un empilage multicouche de perceptrons, dont le but est de prétraiter simultanément de petites quantités d'informations, et sont de ce fait particulièrement adaptés au traitement de contenus d'images et de vidéos [65].

2.2. DÉTECTION, CLASSIFICATION ET IDENTIFICATION

Dans ce cadre spécifique, une plateforme de calcul applicatif doit fournir un cadre technique simple d'utilisation pour aborder des questions scientifiques en lien avec la **détection**, la **classification** et l'**identification** d'objets [43][16]. La détection concerne la localisation de l'instance d'un objet dans l'image ; la classification porte sur la caractérisation de la catégorie de l'objet détecté, par exemple une pomme versus une pêche ; l'identification concerne plutôt la nature de l'objet détecté (et implicitement ou explicitement classé), par exemple la variété ou le stade de maturité d'un fruit. Classification et identification sont souvent confondus, mais il est important de garder à l'esprit les différences entre ces notions pour bien formaliser les questions de recherche, trouver les solutions méthodologiques les plus adaptées et repousser leurs limites.

2.3. ENTRAÎNEMENT, PRÉDICTION ET VALIDATION

Il s'agit là des trois actions clés de manipulation des réseaux de neurones.

ENTRAÎNEMENT. — L'entraînement consiste à spécialiser un réseau à une tâche spécifique, par exemple *détecter des fruits* ou *identifier des variétés de fruits*, à partir d'exemples annotés illustrant ce qu'il est censé faire 6.2.

PRÉDICTION. — La prédiction est le résultat de l'application d'un réseau entraîné sur un jeu de données, par exemple *la détection d'arbres dans des images aériennes* 6.11.

VALIDATION. — La validation est l'estimation de la capacité du réseau à remplir sa tâche et de sa stabilité : elle est obtenue en mesurant l'écart entre les annotations expertes et les prédictions du réseau sur des jeux de données annotés représentatifs de l'hétérogénéité rencontrée dans la réalité. De ce fait, la plateforme doit donner accès à des outils d'analyse reposant sur des indicateurs familiers facilement interprétables par les utilisateurs : seront donc privilégiés les indicateurs usuellement en biostatistique (*FI-score* ou *F-mesure*, *précision*, *rappel*, *mAP*, *matrice de confusion*) [23] [27] [50]. Mais si nécessaire, la validation peut prendre la forme d'un accompagnement des ingénieurs de recherche Agro'Deep qui, dans le cadre de collaborations scientifiques, fourniront des expertises ciblées, tant sur la constitution des jeux de données annotées que sur l'interprétation croisée des valeurs des différents indicateurs.

2.4. LES PROCESSUS INHÉRENTS AUX RÉSEAUX : TUILAGE - DÉTUILAGE

La plateforme doit intégrer de manière transparente les processus spécifiques inhérents à la manipulation des méthodes et des données. Typiquement, le tuilage de l'image, c'est-à-dire la partition de l'image en tuiles pouvant être traitées par les réseaux neuronaux, est explicitement nécessaire pour la détection de "petits" objets dans de "grandes" images. Sans tuilage, les petits objets "disparaissent" lors des transformations géométriques appliquées aux données par le réseau. Si la recomposition de l'image est simplement réalisée en juxtaposant les tuiles, l'agrégation des objets détectés est plus complexe, surtout pour les objets arbitrairement "coupés" en plusieurs parties par le tuilage. Lorsqu'ils sont suffisamment significatifs, c'est-à-dire assez proches des exemples donnés dans le jeu de données d'entraînement, ces différentes parties sont respectivement détectées, et l'objet est potentiellement compté plusieurs fois 2.1. Lorsqu'elles ne sont pas suffisamment significatives, aucune partie de l'objet n'est détectée. Les multiples détections d'un même objet apparaissant dans plusieurs tuiles doivent être fusionnées pour ajuster au mieux le comptage et la forme des boîtes prédictives caractérisant l'objet détecté. Ce problème classique doit donc être abordé et traité en toute transparence par la plateforme et non pas reporté sur l'utilisateur.trice.

3. AGRO'DEEP : UNE PLATEFORME NUMÉRIQUE DE CALCUL APPLICATIF POUR L'AGRICULTURE

3.1. DESCRIPTION

Agro'Deep [1] est une plateforme de traitement distant de données visuelles par réseaux de neurones profonds proposant des services de détection, de dénombrement et de caractérisation d'organes de plantes pour l'agriculture numérique, en particulier l'agroécologie, l'agronomie, l'agroforesterie, et l'agrobusiness. Elle fournit aux équipes de recherche thématique un cadre technique et un accompagnement méthodologique afin de développer, entraîner, adapter, valider et déployer des réseaux neuronaux de détection, de localisation et/ou de reconnaissance multiple d'organes spécifiques (fleurs, feuilles, fruits, arbres, etc.), et met à disposition de différentes communautés d'utilisateur.trice.s des réseaux neuronaux spécialisés pour des domaines spécifiques. Elle s'adresse avant tout aux unités de recherche publiques ou privées désireuses d'adapter ou de développer des méthodes d'identification de données visuelles basées sur des approches de Deep Learning dans le cadre de leurs questionnements scientifiques en s'appuyant sur des compétences et des ressources techniques externes. Elle concerne également les unités de production ou les sociétés privées confrontées au dénombrement ou à la caractérisation en masse et souhaitant évaluer

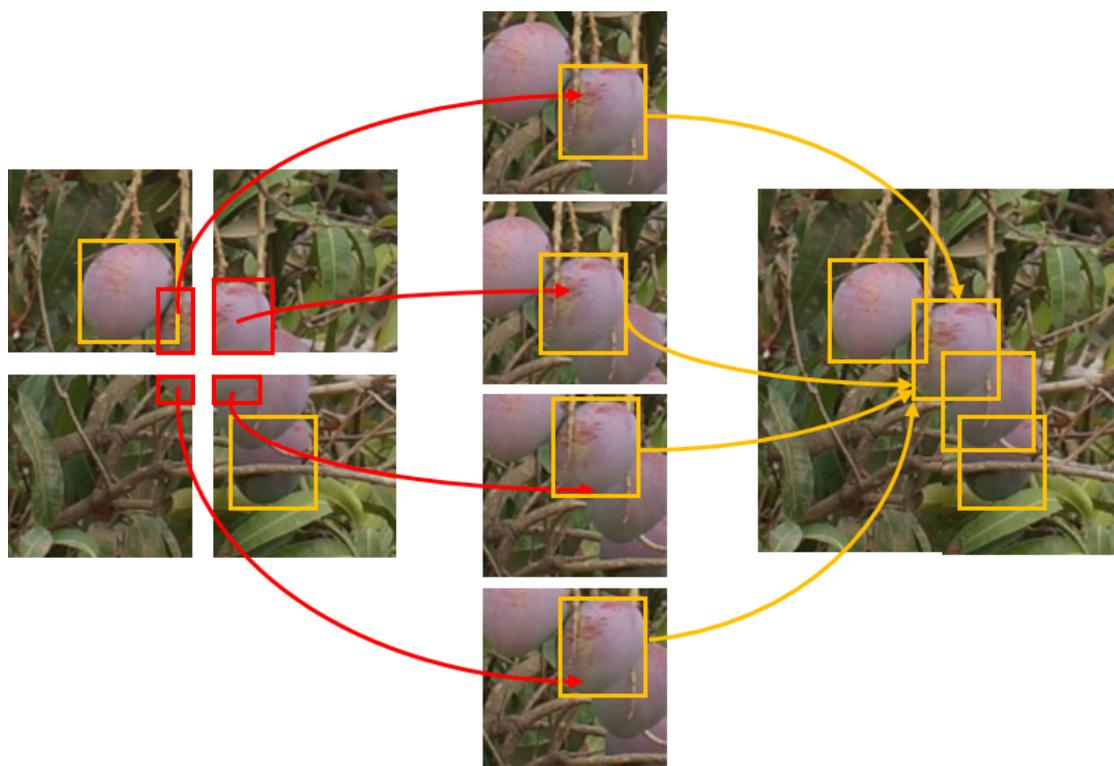


FIGURE 2.1. Tuilage et détection. A gauche : l'image est divisée en tuiles dans lesquelles le réseau détecte les objets ; les objets potentiellement coupés par le tuilage présentent des boîtes englobantes incidentes à au moins l'un des côtés d'une tuile. Au centre : des tuiles complémentaires autour de ces boîtes sont construites à partir de l'image native pour permettre au réseau de traiter correctement les occlusions d'objets. A droite, la fusion des boîtes significativement superposées réalisée à l'aide de l'indice Intersection sur Union permet de supprimer les doublons.

des méthodes ou s'affranchir des contraintes et des expertises techniques propres à la gestion de données et à l'usage du Deep Learning.

3.2. LES NOTIONS CLÉS

Agro'Deep [1] se focalise sur la mise à disposition d'outils d'identification visuelle sans aucun pré-requis thématique ; cette plateforme s'articule autour de concepts faciles à prendre en main définissant notamment les rôles et les services proposés tout en fournissant aux utilisateur.trice.s les outils simples de gestion de leurs activités respectives autour de ces services.

3.2.1. Analyse de données visuelles

Ces notions manipulées lors d'analyse de données concernent tout ce qui touche au cœur d'Agro'Deep [1], c'est-à-dire exécuter un calcul sur des données visuelles à l'aide de réseaux de neurones.

- *Processus de calcul (PdC)* : ce terme *général* désigne la chaîne de traitements appliqués aux données visuelles pour en extraire l'information pertinente. Le point majeur de ce processus est bien évidemment un réseau de neurones entraîné. Lui sont associées toutes les actions à réaliser

avant et après son application, qu'elles portent sur les données ou sur les résultats produits. Le réseau est l'outil central utilisé pour l'analyse de données ou l'objet de l'étude dans le cadre de la mise au point d'un traitement spécifique.

- *Calcul* : c'est l'instanciation d'un PdC à des fins de prédiction ou de mise au point. Il s'applique sur un jeu de données, éventuellement complété de paramètres, et retourne des résultats.
- *Jeu de données* : c'est l'ensemble des données (images, annotations, etc.) sur lequel s'appliquera un calcul. Un jeu de données est créé dans un dépôt de données sur l'espace de stockage Agro'Deep [1] et devient sous certaines conditions utilisables par des calculs.
- *Résultat* : ce terme définit le produit d'un calcul appliqué à un jeu de données, que ce soit dans le cadre de prédictions, d'entraînements ou de validations des réseaux mis en œuvre. Il peut prendre différentes formes selon les cas : visuels de contrôle, fichiers binaires de configuration de réseaux, fichiers texte caractérisant les prédictions ou la segmentation d'objets, indicateurs de validation, etc.
- *Ordonnanceur* : c'est le mécanisme clé qui s'occupe d'allouer les ressources pour instancier les calculs en fournissant le jeu de données demandé et de gérer l'espace de stockage des résultats. Il a en charge l'exploitation optimale des ressources de l'infrastructure c'est-à-dire l'ensemble des équipements mobilisés par la plateforme Agro'Deep [1] (*serveur(s) et calculateur(s)*).

3.2.2. Gestion de projets

Pour réaliser des calculs en garantissant confidentialité et sécurité des données et résultats, Agro'Deep [1] propose un modèle de gestion des interactions entre utilisateur.trice.s et un mode de fonctionnement reposant sur des concepts simples.

PROJET. — Il constitue la capsule thématique et temporelle définissant le cadre dans lequel Agro'Deep [1] est utilisé pour répondre aux problématiques de l'utilisateur.trice. Il regroupe l'ensemble des outils, données et acteurs associés à un objectif spécifique, soit de *production*, soit de *recherche*, sur un domaine applicatif spécifique (*café, cerises, mangues, etc.*).

- Un projet de *production* consiste à appliquer un ensemble de réseaux spécialisés et validés mis à disposition de la communauté des utilisateur.trice.s de la plateforme. Chacun de ces réseaux est décrit dans un document accessible en ligne. *Ces réseaux sont partagés au sein de la communauté Agro'Deep [1] à la seule initiative des responsables des projets de recherche dans lesquels ils ont été développés.*
- Un projet de *recherche* consiste à fournir un cadre permettant de spécialiser des réseaux de neurones types pour répondre à un objectif spécifique (par exemple, la détection des litchis).

UTILISATEUR.TRICE. — Personne physique inscrite sur la plateforme Agro'Deep [1]. Un.e utilisateur.trice peut, en fonction des droits dont il.elle dispose, créer des jeux de données, lancer ou finaliser des calculs, consulter ou récupérer des résultats, créer et administrer un ou plusieurs projets, communiquer sur ses projets à destination de la communauté d'utilisateur.trice.s d'Agro'Deep [1].

RÔLES ET DROITS. — Un.e utilisateur.trice ne peut interagir avec un projet qu'en fonction des droits qui lui sont accordés par les administrateur.trice.s de ce projet. Ces droits sont conditionnés par le rôle qu'il.elle joue au sein d'un projet. Un.e utilisateur.trice est l'administrateur.trice du projet qu'il.elle crée. Il.elle peut alors, par exemple, inviter un.e autre utilisateur.trice et lui attribuer un rôle de membre sans droit d'administration de ce projet.

3.2.3. Cadre contractuel et financier

L'utilisation d'Agro'Deep [1] est encadrée par une démarche contractuelle classique qui permet en outre de cadrer la contribution financière à l'usage de la plateforme. On retrouve ainsi les notions habituelles de ce genre de service.

CRÉDITS. — Unité représentant l'utilisation de l'infrastructure de calcul, tant en termes de ressources matérielles (espace disque, processeurs CPU et GPU [58]) qu'humaines (maintenance, appui technique ou support). Les crédits permettent la gestion de ces ressources, la facturation équitable et la ventilation des coûts de maintenance de l'infrastructure en fonction de l'usage de celle-ci.

CONTRAT. — Cadre juridique de la collaboration entre l'utilisateur.trice et les exploitant.e.s d'Agro'Deep [1]. C'est via le contrat que sont délimités le périmètre, la durée et la contribution financière de la collaboration ainsi que les services fournis et attendus par les différentes parties autour d'Agro'Deep [1]. Ils se déclinent en deux grandes catégories :

- Le contrat de *production* permet l'achat simple, rapide et forfaitaire de crédits d'utilisation de la plateforme et inclut un support technique minimum concernant l'utilisation d'Agro'Deep [1]. Immédiatement disponible via une interface de commande en ligne, il est à destination de l'exploitant de résultats de prédiction issues d'un réseau entraîné via un projet de production.
- Le contrat de *collaboration* est personnalisé et peut par exemple inclure des prestations d'accompagnement scientifique et technique autour de la mise au point d'un réseau sur une thématique précise. Nécessitant une prise de contact et une négociation avec les services de valorisation du CIRAD, il est à destination des utilisateur.trice.s désirant mettre au point un traitement non encore disponible sur Agro'Deep [1].

3.3. LES SERVICES CLÉS

Agro'Deep [1] doit permettre la mise au point et l'exploitation de traitements de données visuelles de manière simple et ouverte aux utilisateur.trice.s des résultats de ces traitements. La plateforme doit en outre offrir des mécanismes affranchissant, autant que faire se peut, l'utilisateur.trice des problèmes d'ordre techniques informatiques se présentant généralement lors de la mise en œuvre de ces travaux. Pour ce faire, Agro'Deep [1] fournit une interface ergonomique permettant d'effectuer les principales actions liées à cette mise en œuvre, en prenant en charge les aspects techniques ne relevant pas directement de l'exploitation et mise au point d'un réseau de neurones.

CALCUL. — Agro'Deep [1] facilite l'exploitation de traitements de données visuelles via

- la mise à disposition un ensemble de réseaux entraînés sur des thématiques agronomiques, mis au point soit par l'équipe d'exploitation, soit par des utilisateur.trice.s désireux.euses de partager tout ou partie de leurs réseaux au sein d'Agro'Deep [1] ;
- un environnement Web qui permet d'exécuter sans prérequis technique différents traitements de données sur la thématique ciblée par l'utilisateur.trice. Il suffit de déposer les données, choisir un PdC parmi ceux disponibles, lancer le calcul et consulter les résultats une fois le calcul terminé.

SPÉCIALISATION D'UN CALCUL. — Agro'Deep [1] offre les outils nécessaires à la mise au point d'un traitement de données visuelles pour une problématique donnée :

- l'interface web propose des outils de gestion d'entraînement, de validation et de mise en production d'un traitement articulé autour d'un réseau de neurones entraîné et validé. Les outils de

gestion de données, de réglage des réseaux en développement, de consultation des métriques de validation et de visualisation des résultats sont disponibles tout en permettant l'export vers des outils tiers.

- un accompagnement utilisateur.trice sur les problématiques concernant le développement de réseau de neurones, l'interprétations des résultats et métriques de validation. La personnalisation et le déploiement du réseau hors Agro'Deep [1] est proposé via les contrats de collaboration.

COMMUNICATION INTERNE. — Enfin, Agro'Deep [1] permet aux utilisateur.trice.s de communiquer sur leurs travaux au sein de la communauté Agro'Deep [1] en

- intégrant les outils de communication permettant à tout gestionnaire de projet de publier une description détaillée de son projet et, s'il le souhaite, des bulletins d'informations réguliers ;
- permettant à tout gestionnaire de projet le souhaitant de partager un ou plusieurs de ses PdC. Il peut ainsi mettre à disposition de la communauté Agro'Deep [1] certains réseaux de neurones spécialisés.

4. AGRO'DEEP : L'APPLICATION

4.1. IHM

Cette sous-section présente sommairement les cycles fonctionnels des services clés afin d'illustrer la simplicité d'utilisation de la plateforme Agro'Deep [1]. Les interfaces Homme-machine (IHM) sont à ce stade relativement rudimentaires mais permettent toutefois à l'utilisateur.trice de gérer *naturellement* données, calculs et résultats.

4.1.1. Service de calcul

Comme illustré en figure 4.1, le **service de calcul** repose sur un *enchaînement d'étapes* permettant d'appliquer un **calcul** sur l'un des **jeux de données** d'un **projet** particulier et de récupérer les **résultats** produits.

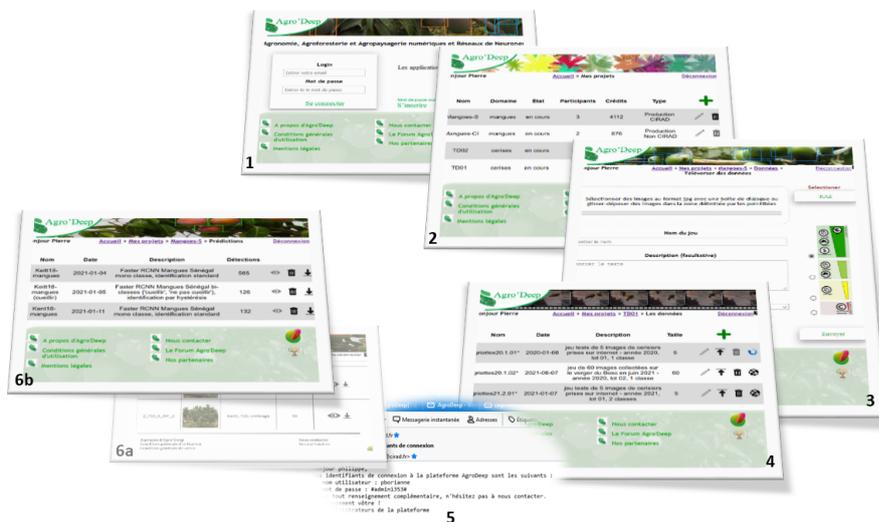


FIGURE 4.1. Service de calcul type

L'enchaînement type de ce service est le suivant :

- (1) L'utilisateur.trice se connecte à son espace privé.
- (2) L'utilisateur.trice accède, à travers son portefeuille de projets, à un projet en cours et crédité, c'est-à-dire un projet pour lequel un ou plusieurs contrats sont en cours et des crédits d'utilisation disponibles.
- (3) L'utilisateur.trice « téléverse » dans le projet, *et par conséquent sur le serveur Agro'Deep* [1], un jeu de données depuis son propre ordinateur.
- (4) L'utilisateur.trice demande un calcul sur ce nouveau jeu de données à partir de son gestionnaire de données, en choisissant le réseau idoine parmi ceux à sa disposition. *Le calcul est exécuté par l'ordonnanceur dès que les ressources matérielles sont disponibles.*
- (5) La plateforme Agro'Deep [1] prévient l'utilisateur.trice par mail dès que le calcul est terminé et les résultats accessibles.
- (6) L'utilisateur.trice consulte les résultats en ligne et peut, si il.elle le souhaite, télécharger les résultats sur son propre ordinateur.

4.1.2. Service de communication interne

La communication au sein de la plateforme Agro'Deep [1] est aujourd'hui primordiale. Dans cette première version, un espace de visibilité des projets est disponible; *des espaces "Nouveautés" et "Fil de discussion" sont actuellement en réflexion pour la future version de la plateforme.* La figure 4.1 illustre les étapes permettant à un.une **gestionnaire de projet de communiquer au sein de la communauté Agro'Deep** [1].

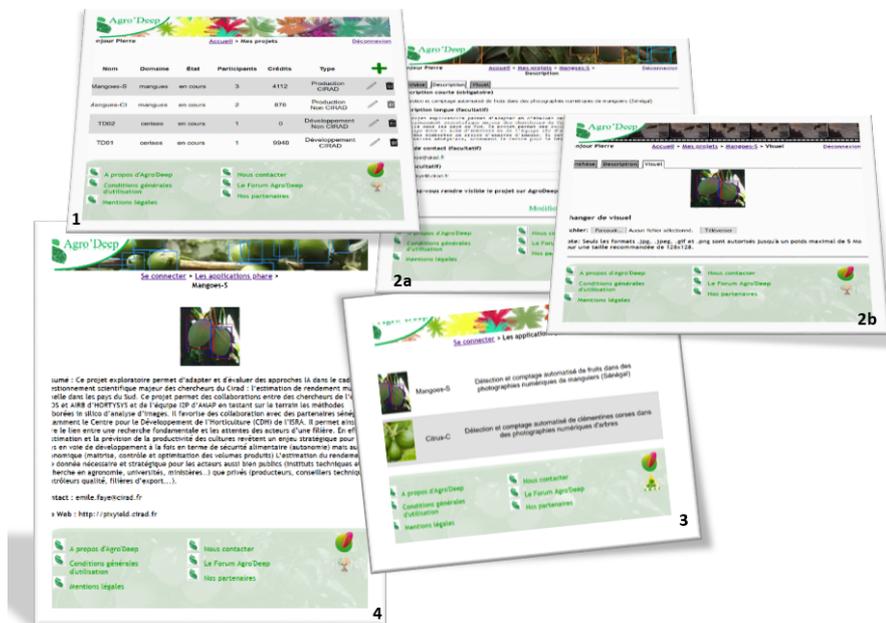


FIGURE 4.2. Service de communication

- (1) L'utilisateur.trice accède, à travers son **portefeuille de projets**, à la page d'accueil d'un projet qu'il.elle gère.

- (2) Les différents onglets relatifs aux **Informations** du projet permettent de fournir un descriptif sommaire, un ou plusieurs visuels, une adresse de contact et, le cas échéant, un lien vers un site web détaillant le projet.
- (3) Dès que le projet est rendu *visible* par son.ssa gestionnaire, il apparaît dans la liste des **applications phares** de la plateforme.
- (4) Tout.e utilisateur.trice de la plateforme peut accéder au descriptif sommaire de tout projet phare.

4.2. ARCHITECTURE

L'architecture, illustrée par la figure 4.3, est conventionnelle et se compose de trois grandes parties :

- une IHM permettant d'exécuter les tâches de paramétrage relatives au calcul scientifique (paramètres et résultats) en limitant l'impact des aspects techniques informatiques ;
- un socle permettant la gestion des projets, l'instanciation des calculs ainsi que la gestion des ressources machine et autres tâches administratives de gestion de la plateforme ;
- les réseaux encapsulés dans des conteneurs [85], leurs données et résultats étant stockés sur disque, hors conteneur. Cette approche faiblement couplée à Agro'Deep [1] permet l'utilisation de ces mêmes conteneurs hors de la plateforme.

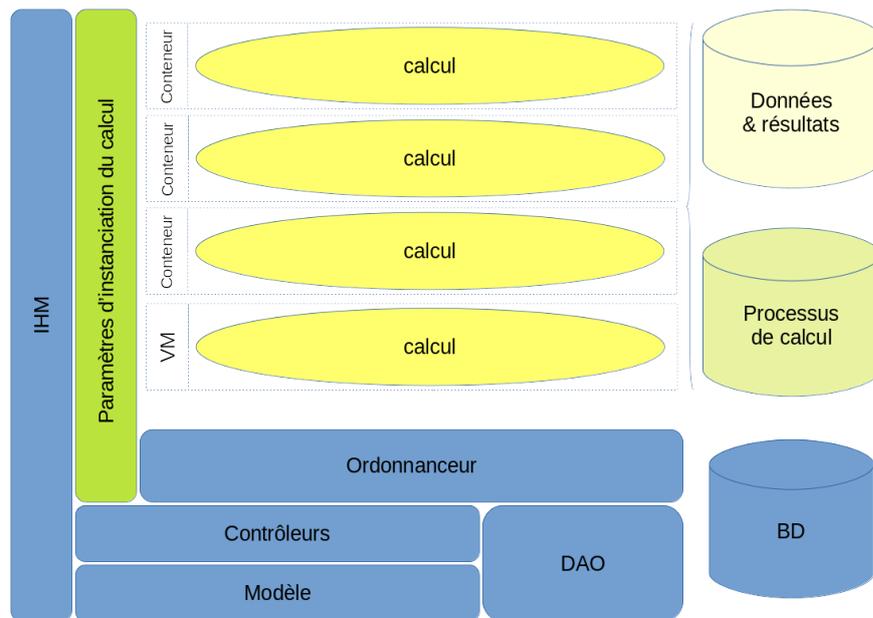


FIGURE 4.3. Architecture logicielle

4.3. ENVIRONNEMENT

Agro'Deep [1] repose sur des technologies web éprouvées et maîtrisées par l'équipe en charge du développement et de l'exploitation de la plateforme. Des solutions libres ont été choisies pour leur large diffusion, documentation, accessibilité et facilité de mise en œuvre et d'exploitation. L'ensemble est ainsi développé sous l'environnement LAMP [20], une architecture logicielle reposant sur le système

d'exploitation open source Linux, le serveur web Apache, le serveur de données MySQL et le langage de programmation PHP (*PHP Hypertext Processor*).

L'IHM et les couches internes sont essentiellement développées en PHP et complétées par du HTML (*HyperText Markup Language*) / CSS (*Cascading Style Sheet*), l'ordonnanceur en shell scripts et PHP. Ces langages sont toujours omniprésents dans la programmation web [87]. Les données sont gérées via MySQL / MariaDB : l'usage de la bibliothèque PHP Data Object (PDO) rend toutefois possible le passage à d'autres moteurs de base de données relationnelles.

Enfin, l'ensemble repose sur la solution de virtualisation libre Proxmox qui est utilisée pour sa facilité d'administration, le faible coût du support éditeur éventuel et l'aisance de son dimensionnement [2]. Il est bien sûr possible d'installer Agro'Deep [1] sur une machine physique.

4.3.1. Implémentation

L'implémentation, à l'image de l'environnement logiciel, repose sur des pratiques et techniques éprouvées et répandues afin de faciliter son évolution, sa maintenance et son exploitation. L'approche choisie a été d'utiliser la Programmation Orientée Objet (POO) et les patrons de conceptions [19] suivants :

- le patron de conception Model View Contrôleur (MVC) pour l'implémentation des couches métier, les vues étant générées par PHP en HTML / CSS ;
- le patron de conception Data Access Objet (DAO) pour l'accès aux données et leur sérialisation.

4.4. GESTION DE DONNÉES

Les différentes natures de données hébergées par Agro'Deep [1] posent différents problèmes tant par leur sensibilité que par leur cycle de vie. On en distingue quatre grandes familles :

4.4.1. Données administratives

Les données administratives sont celles concernant les utilisateur.trice.s et les projets. Elles sont considérées comme sensibles car nominatives et doivent être gérées conformément au cadre légal strict imposé par le Règlement Général sur la Protection des Données (RGPD) [51]. Il impose entre autres

- le renforcement de la sécurité sur les données à caractère personnel (nom, adresses, emails, contrats...) ;
- une information utilisateur.trice spécifique sur l'utilisation, les chaînes de traitement, le cycle de vie de ces données ainsi que les procédures pour l'exercice du droit de consultation ou de retrait de l'utilisateur.trice ;
- une documentation technique à jour sur ces traitements et leurs acteur.trice.s ;
- des procédures documentées pour les gestions de crise (fuites de données).

Ces données ont une durée de vie dépendante du choix de l'utilisateur.trice (clôture d'un projet) et des contraintes légales (conservation des données parfois encadrées). Leur validation peut-être externe à l'équipe de gestion d'Agro'Deep [1] comme par exemple les contrats qui sont validés par les services financiers du CIRAD.

4.4.2. Données de travail

Les données de travail sont potentiellement volumineuses et hétérogènes. Elles sont principalement constituées d'images ou de vidéos, d'annotations, de paramètres éventuels, de résultats produits et d'opérations nécessaires au calcul.

Leur sensibilité est définie par leur gestionnaire : publiques, à diffusion restreinte au sein de la communauté ou réservées à un projet. Leur durée de vie est dépendante de leur nature, de leur diffusion. Ainsi un réseau entraîné partagé à la communauté sera détruit soit par volonté du propriétaire, soit par l'obsolescence technique du traitement.

Ces caractéristiques imposent un soin particulier sur

- la sauvegarde et la gestion de crise en cas de panne matérielle ;
- la gestion de leur destruction afin de permettre le droit au remords de l'utilisateur.trice en cas de suppression (corbeille), l'envoi de gros volume de données pouvant être un frein à cause des débits réseaux à sa disposition ;
- les interfaces de dépôt de données consommées par les calculs ;
- les interfaces de présentation des résultats de calculs, qu'ils concernent les entraînements, les validations ou les prédictions ;
- la gestion de leur potentielle diffusion.

4.4.3. Ressources

Les ressources sont composées du temps de calcul, de l'espace de stockage disponibles et des ressources humaines investies dans l'exploitation de la plateforme. Le calcul de leur consommation, symbolisé par la notion de crédit, est un des facteur de rentabilité financière de la plateforme.

Ceci implique :

- un suivi de la disponibilité et de l'usage des ressources matérielles ;
- un suivi du temps humain consacré à l'exploitation de la plateforme ;
- un décompte de l'utilisation de ces ressources par projet ;
- la répartition du coût d'exploitation global sur l'ensemble de ces projets.

4.4.4. Meta-données

Les méta-données sont les données de gestion des calculs et servent à assurer un service de qualité en apportant des informations tant aux utilisateur.trice.s qu'aux exploitant.e.s d'Agro'Deep [1] sur :

- le cycle de vie d'un container utilisé par un calcul : début, fin et ressources consommées ;
- la gestion des versions des containers qui évoluent lors de leur développement dans le cadre des contrats de collaboration et de développement de réseau de neurones ;
- le suivi de l'obsolescence des algorithmes utilisés pour les calculs, ce domaine scientifique étant très dynamique.

4.5. PROCESSUS DE CALCUL

Le processus de calcul regroupe un ensemble de traitements appliqués tant sur les données que sur les résultats fournis par le réseau. Ces traitements permettent au final de passer de l'échelle *utilisateur.trice* à l'échelle *réseau*, et réciproquement. Ainsi un pré-traitement plus ou moins complexe est appliqué aux données fournies par l'utilisateur.trice pour les rendre compatibles avec les exigences du réseau de neurones qui constitue le cœur du traitement (tuilage, filtrage, etc.). Un post-traitement est *ipso facto* appliqué aux résultats fournis par le réseau pour les rendre interprétables par l'utilisateur.trice. Ces différentes étapes, réseau compris, se traduisent en termes de codes, le plus souvent développés en langage Python [48] et caractérisés par des contraintes d'implémentation. Un processus de calcul doit être vu comme une entité fonctionnelle à part entière, totalement indépendante des autres processus de calcul même si présentant

potentiellement des points communs. Du point de vue Agro'Deep [1], les processus de calcul se comportent comme de véritables boîtes noires appelées *conteneurs*[85][68].

La conteneurisation est une méthode répandue qui permet d'isoler, dans un environnement hermétique et contrôlé appelé conteneur, les ressources logicielles nécessaires à l'exécution d'une application. La plateforme Agro'Deep [1] utilise cette technologie pour réduire fortement l'impact des contraintes inhérentes à la mobilisation des processeurs de la carte graphique par les réseaux de neurones profonds [60] tout en se protégeant des dysfonctionnements.

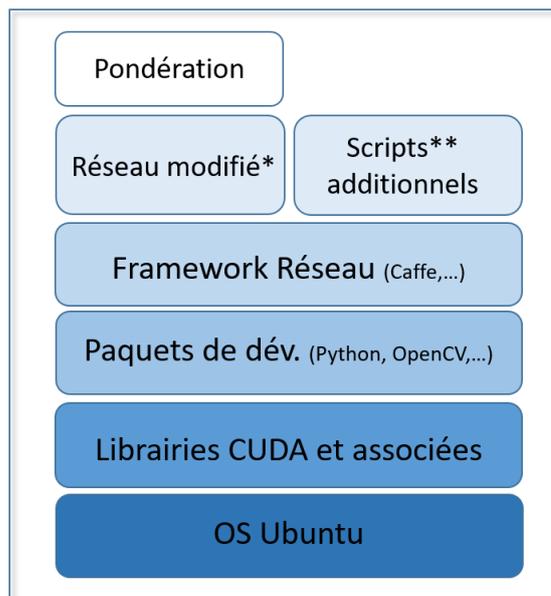


FIGURE 4.4. Conteneur : boîte hermétique qui embarque l'environnement fonctionnel du calcul, les pré et post-traitements respectivement à appliquer aux données et aux résultats, et les algorithmes de calcul à proprement parler. *Les données lui sont transmises lors de son appel.*

Dans cette première version, les processus de calcul sont encapsulés, comme illustré en figure 4.4, dans des **conteneurs Singularity**, l'extension aux *conteneurs Docker* est à l'étude pour les versions suivantes. *Singularity* est un système de conteneurisation multi-plateformes open source développé par Sylabs [21]. L'un de ses principaux avantages est de permettre la reproductibilité des calculs scientifiques en limitant les problèmes de compatibilité, de droits et de sécurité aux calculateurs sollicités [42][90]. La plateforme Agro'Deep [1] peut ainsi garantir des calculs rigoureusement identiques dans des environnements reproductibles sur des matériels fortement différents avec toutefois quelques réserves de compatibilité entre les bibliothèques de calculs et les pilotes embarqués dans le noyau de la machine hôte.

De nouveaux conteneurs intégrant des processus de calcul seront développés par les ingénieurs.e.s d'Agro'Deep [1], dans le cadre de collaborations scientifiques, afin de mettre à disposition de nouvelles technologies de réseaux, de nouvelles méthodes ou de nouveaux pré ou post traitements. Une fois le conteneur créé et testé, il peut alors être mis à disposition des utilisateur.trice.s pour spécialisation à un domaine thématique particulier via les fonctionnalités Agro'Deep [1].

4.5.1. *Conteneurs : avantages et inconvénients*

La conteneurisation apporte de multiples avantages, tant pour l'exploitation que pour le développement de nouveaux types de calculs.

En termes d'exploitation, la conteneurisation sous Singularity simplifie :

- *la sécurité* : les conteneurs Singularity ne nécessitent pas de droits administrateurs pour leur exécution sur les machines de production limitant ainsi l'impact de fonctionnement non désiré dans le code du conteneur.
- *la sauvegarde et la gestion de crise* : les conteneurs sont sous forme de fichier unique facilitant leur manipulation, sauvegarde et restauration en cas de panne matérielle.
- *la mise à disposition des calculs* : la conteneurisation permet de faciliter l'utilisation des conteneurs de calculs en dehors de la plateforme, permettant ainsi leur exploitation indépendante.
- *la migration matérielle* : le conteneur encapsulant l'environnement logiciel quasi complet, les seules contraintes de migration matérielles sont la compatibilité des bibliothèques embarquées avec les pilotes de carte graphique dans le cadre de l'exploitation des GPUs pour le calcul.
- *la répartition de charge* : les conteneurs peuvent être lancés sur une ou plusieurs machines, simultanément ou séquentiellement offrant ainsi une grande souplesse dans la répartition de la charge de calculs.
- *la haute disponibilité* : la possibilité d'exécution des containers sur des machines différentes permet l'exploitation de la plateforme en mode dégradé en cas de panne d'un nœud de calcul.

Le développement de nouveaux conteneurs de calculs, tout comme la maintenance et l'évolution des conteneurs existants sont facilités par l'usage de Singularity (ou Docker) car son fonctionnement base la construction de nouveaux conteneurs sur des fichiers texte en étendant éventuellement des containers déjà construits. Cette particularité facilite la gestion des versions car :

- des outils de gestion de sources (Version Control System : VCS) tels que GIT, Mercurial ou Subversion permettent la gestion des fichiers recettes ;
- des dépôts internes permettent la gestion des conteneurs socles ou finaux construits en interne ;
- le développement de conteneurs de tests peut s'appuyer sur l'extension de conteneurs socles existants qui prennent en charge les aspects techniques hors calcul.

Enfin, les nouveaux conteneurs de calcul sont développés sur l'ordinateur de leur concepteur.trice qui en a la maîtrise totale (environnement et droits nécessaires à leur conception). Leur intégration à Agro'Deep [1] se fait par leur dépôt et déclaration par un.e des administrateur.trice de la plateforme.

Il est à noter toutefois que si la conteneurisation limite grandement les problèmes de compatibilités logicielles, elle ne les élimine pas totalement. Il reste notamment quelques problèmes liés à la compatibilité des bibliothèques de calcul GPU avec le pilote du GPU qui est une composante du noyau de la machine hôte et n'est pas intégré au conteneur.

4.5.2. *Perspectives : encapsulation du calcul dans des machines virtuelles*

L'utilisation de machines virtuelles (Virtual Machine : VM), à la différence des conteneurs, permet d'embarquer dans un fichier unique la totalité des couches logicielles, pilotes graphiques compris. Cette particularité permet d'augmenter la robustesse des calculs, la condition de compatibilité n'étant plus entre les bibliothèques de calcul et le pilote GPU mais entre le pilote GPU et le matériel. Cette compatibilité est de fait plus large, les pilotes actuels des constructeurs couvrant une large gamme de matériel. Les technologies actuelles d'accès direct au matériel (passthrough) réduisent le coût de virtualisation en termes

de performances quasiment au niveau de la conteneurisation et limitent l'impact de la virtualisation complète sur les performances.

Utiliser des VM permettrait, tout en conservant une partie des avantages des conteneurs :

- d'augmenter la durée de vie d'un "conteneur de calcul", celui-ci n'étant plus dépendant des pilotes de la machine hôte ;
- de virtualiser une configuration matérielle existante pour peu qu'il soit possible d'ajouter à la machine hôte une carte GPU identique à celle d'origine ;
- de supporter du matériel âgé aux côtés de matériel plus récent, s'il est possible de l'intégrer matériellement dans l'hôte.

4.6. INTERFAÇAGE GESTION DE DONNÉES / CALCUL

Il a été choisi de permettre une utilisation des calculs indépendante de leur intégration à Agro'Deep [1] afin de faciliter leur exploitation dans des contextes matériels, environnementaux et commerciaux différents. Pour ce faire, Agro'Deep [1] s'appuie sur un ordonnanceur utilisant les informations fournies par la plateforme (jeu de données, conteneur à utiliser, dépôt de résultats, crédits de calcul disponibles...) pour instancier un calcul et servir ses résultats afin de les rendre disponibles via l'IHM. Cet ordonnanceur s'occupe en outre de gérer d'éventuels dysfonctionnements dans le calcul (sortie brutale, boucle infinie) afin d'éviter une consommation inutile de ressources et d'informer tant l'utilisateur que les exploitants du dysfonctionnement détecté. Il prend en charge :

- le lancement des processus de calcul, la mise à disposition des données d'entrée et l'espace disque nécessaire pour les résultats ;
- l'écoute des conteneurs et la surveillance du bon déroulement du calcul ;
- la mise à jour de la base de données Agro'Deep [1] avec les méta-données du calcul (temps d'exécution, crédits consommés...);
- la mise à disposition des résultats du calcul à la plateforme pour rendre leur récupération possible par l'IHM.

L'ordonnanceur peut être déployé sur plusieurs nœuds de calcul afin de répartir la charge sur chacun d'entre eux. Son faible couplage avec le reste de la plateforme lui permet de s'adapter à d'autres outils d'ordonnement de tâches plus sophistiqués.

5. AGRO'DEEP : UN MODÈLE ÉCONOMIQUE SIMPLE ET ADAPTÉ AU BESOIN UTILISATEUR

Agro'Deep [1] repose sur un **modèle économique équitable et participatif** : une contribution financière est demandée à chaque utilisateur pour supporter une partie des coûts de développement, de maintenance et de gestion des codes source, des matériels explicitement utilisés et des infrastructures implicitement mobilisées. Cette contribution financière passe par la contractualisation soit de prestations de service, soit de collaborations scientifiques. Dans tous les cas, la contractualisation s'insère dans les circuits institutionnels du Cirad et passe par les services d'appui tels que les Départements de Valorisation Scientifique et/ou des Affaires Financières ; elle débouche le plus souvent sur une facturation visant à couvrir d'une partie des coûts de fonctionnement de la plateforme Agro'Deep. La facturation est l'ultime étape du processus : quelque que soit le montant de la contribution demandée, c'est elle qui autorise l'accès aux ressources de calcul et de stockage de la plateforme.

6. ACCOMPAGNEMENTS MÉTHODOLOGIQUES ET TECHNIQUES

Si la plateforme Agro'Deep [1] donne un cadre général permettant de conduire des études selon des processus normalisés, elle autorise l'adaptation des traitements embarqués dans les conteneurs de calcul pour répondre à des besoins très spécifiques. Trois cas d'étude sont présentés dans cette section pour illustrer différentes natures d'ajustement réalisés dans le cadre des appuis méthodologiques fournis par les ingénieurs Agro'Deep [1] : **la détection de cerises de caféiers** ou *comment adapter le protocole d'apprentissage du réseau*, **l'identification de variétés de mangues** ou *comment ajuster la fonction d'identification pour détecter des objets visuellement très proches*, et **la classification des palmiers** ou *comment et pourquoi automatiser l'annotation des données*.

6.1. LE PROJET COFFEEDEEP : AJUSTEMENT DU PROTOCOLE D'APPRENTISSAGE

Dans cette étude, l'une des contributions des ingénieurs de recherche Agro'Deep [1] consista à **définir un protocole d'apprentissage** permettant de répondre réellement aux besoins des agronomes travaillant sur la **modélisation de rendement des exploitations de caféiers** en s'insérant dans les pratiques usuelles.

6.1.1. Contexte applicatif

Le café est la seconde matière première échangée dans le monde et la première matière agricole en volume. Selon l'Organisation Internationale du Café, la production mondiale de café s'élève à près de 7,4 milliards de kilos par an, soit 235 kilos de café toutes les secondes, essentiellement répartis à hauteur de 60% pour Arabica et 40% pour Robusta. La culture du café fait vivre près de 25 millions de familles principalement dans les pays en voie de développement. Parmi les 5 millions d'exploitations, 70% d'entre elles sont de taille modeste avec moins de 10 hectares. Que ce soit pour le Robusta côté à la bourse de Londres ou l'Arabica côté à la bourse de New York, les cours du café sont très volatiles puisque soumis tant à la loi de l'offre et de la demande qu'aux spéculations sur les récoltes à venir.

L'estimation précoce de la production mondiale est d'ailleurs un outil très demandé aussi bien par les grands torréfacteurs (Nestlé, JDE, Tchibo..) que par les négociants (Neumann, ECOM, Volcafé..) pour réguler les fluctuations de prix du marché et planifier la ventilation de la production.

Chaque année, les estimations de récolte sont faites manuellement et indépendamment, environ 4 à 5 mois avant la récolte. Le coût de ces estimations manuelles est élevé.

L'estimation de récolte repose sur un comptage manuel exhaustif des cerises de caféier ou *drupes* dans certains rameaux de quelques arbres témoins. Ces pratiques sont longues et fastidieuses, souvent entachées de fortes incertitudes du fait de la densité des glomérules, c'est-à-dire des « grappes de cerises » comme illustrées en figure 6.1. L'augmentation de la fiabilité des estimations passe par un comptage plus standardisé, plus rapide et plus fréquent au sein de toutes les exploitations, indépendamment de leur situation géographique et de leur taille. De plus, les opérateurs au champ sont habitués à réaliser leurs estimations de récolte sur un phénotype particulier de quelques variétés très diffusées durant les 10 dernières années (Catimors), fait qui conduit à des estimations très imprécises sur d'autres variétés traditionnelles ou récentes (hybrides F1).

Le projet CoffeeDeep se proposait d'évaluer l'apport de l'image numérique pour le développement d'outils de comptage de cerises au champ « rapides et peu contraignants » pour une estimation précoce et systématisée des productions variétales, à l'échelle des exploitations. Un tel outil serait probablement la première étape vers un outil de gestion de la ressource café à l'échelle des régions de production, et intéresserait à termes les acteurs principaux de la filière, en particulier les exploitants, les torréfacteurs et les traders.



FIGURE 6.1. cerises et glomérules du caféier

S'il est vrai que la révolution numérique permet aujourd'hui de disposer d'appareils photo peu encombrants et relativement précis à des coûts abordables, le traitement du contenu des images produites reste potentiellement un verrou méthodologique à prendre en compte. Les premières études concernant le dénombrement des cerises de caféiers sont au final très récentes et donnent avec des F-mesures d'à peine 60% des résultats potentiellement améliorables [78]. Il s'agit ici de configurations difficiles compte-tenu de la taille même des drupes, de la densité des glomérules, de l'occlusion partielle des fruits, des variations de couleurs dues à la maturité des fruits et aux conditions d'éclairage, etc. Sous ces conditions, les méthodes conventionnelles d'analyse d'image sont souvent avantageusement remplacées par des réseaux de neurones profonds, par exemple pour détecter ou identifier des grains de raisins [81] ou des myrtilles [61] dans des images d'arbres fruitiers.

Fin 2020, le projet CoffeeDeep se proposait donc d'évaluer la potentialité réelle de réseaux de neurones pour détecter et dénombrer les cerises visibles de caféiers dans des images numériques de rameaux afin de pouvoir alimenter les modèles d'estimation de rendement de parcelles. Il a été conduit sur la plateforme Agro'Deep [1] afin de réduire les coûts d'appropriation des méthodes et des environnements d'IA.

6.1.2. Données

La collecte d'images et de méta-données a été réalisée sur 8 parcelles étagées sur un gradient altitudinal de 720 à 1110 m dans la région de Matagalpa au Nord-Ouest du Nicaragua, l'une des principales régions

de production d'Arabica dans ce pays. Les 8 parcelles en production, de grande taille (10,5 à 45,5 ha) et âgées de 2 à 7 ans après plantation ou recépage, étaient plantées avec les variétés Marsellesa (Sarchimor), T5175 (Catimor) et Centroamericano (Hybride F1). Dans chacune des parcelles, 24 caféiers représentatifs de l'état global de la parcelle ont été sélectionnés en prenant en compte au maximum la variabilité de l'état de vigueur des plants. Sur chacun de ces caféiers, 3 rameaux plagiotropes représentatifs de la plante ont été sélectionnés équitablement sur les 3 étages productifs de la plante : tiers inférieur, médian et supérieur. Les 3 rameaux sélectionnés correspondaient à ceux « naturellement observés » lors du protocole classique de comptage manuel de fruits pour réaliser la prédiction de récolte d'une parcelle. Une image numérique de chacun de ces rameaux a été acquise à environ 70-80 cm de distance, sous éclairage naturel. Un jeu de 596 images de rameaux plagiotropes productifs a ainsi été constitué (8 parcelles x 24 plants x 3 rameaux).

Les annotations expertes ont consisté à délimiter par une boîte englobante rectangulaire les cerises visibles dans chaque image tout en distinguant celles portées par le rameau plagiotrope d'intérêt des autres, comme illustré en figure 6.2. Un tel travail devait permettre d'évaluer la capacité du réseau à contextualiser son apprentissage.



FIGURE 6.2. Annotations expertes images. Cerises de l'axe d'intérêt en orange, autres cerises en bleu.

6.1.3. Focus

La spécificité de cette étude portait essentiellement sur l'impact de l'occlusion et de la réduction de la zone d'observation sur les performances d'un réseau. En effet, l'agencement des drupes et leur

développement en glomérules portés à même les rameaux plagiotropes occasionnent de nombreuses occultations partielles voire totales de fruits. Par ailleurs, s'il est courant pour les agronomes de raisonner en termes d'organes ou d'axes structurants pour la modélisation des rendements, les algorithmes de détection travaillent classiquement à l'échelle du pixel, *l'élément structurant de l'image*, sur l'ensemble de l'image.

Il s'agissait donc de compléter les "processus standards de traitement" pour tenir compte de ces spécificités et de répondre au mieux à la demande de agronomes.

CALIBRER UN RÉSEAU DE NEURONES POUR DÉTECTER LES CERISES DE CAFÉ AVEC UN BON TAUX DE FIABILITÉ. — Les données annotées ont été réparties en 4 lots les plus « similaires » possibles en termes de nombre et de variabilité d'images. Les 124 premières images constituaient le lot d'entraînement avec près de 9 925 annotations, les 472 dernières étaient équi-réparties en 3 lots de validation. Dans cette première expérimentation, les cerises étaient considérées indépendamment de leur classe respective.

En première approche, un réseau Faster R-CNN (*region-based convolutional neural network*) [76] mono-classe était utilisé au vu des résultats récents obtenus par ce réseau pour la détection de différentes espèces de fruits [80][88]. La phase d'apprentissage consista à instancier un conteneur dont le rôle était de spécialiser à la détection des cerises de café un Faster R-CNN pré-entraîné sur la base d'images publiques Pascal Voc [86]. Le lot d'apprentissage était alors utilisé à cette fin, le processus de calcul sauvegardant automatiquement le calibrage du réseau à différentes étapes de l'entraînement.

Une fois cette première étape réalisée, un processus de validation était exécuté pour évaluer l'écart entre les annotations expertes et les prédictions du réseau à différentes étapes de l'entraînement. Cette validation, réalisée sur le lot d'entraînement, a permis d'apprécier la nature et la hauteur de la dérive du réseau et d'orienter le processus d'entraînement. *Annotations et prédictions étant deux à deux appairées, les annotations restantes formaient la classe des Faux Négatifs, les prédictions restantes celle des Faux Positifs. Défini comme la moyenne harmonique (meilleur compromis) entre la Précision et le Rappel, le F1-score était alors utilisé comme indicateur statistique global pour caractériser l'écart entre Annotations et Prédictions alors que la Précision permettait d'estimer la contribution des Faux Positifs (objets détectés à tort par le réseau) dans l'erreur globale du réseau, et le Rappel celle des Faux Négatifs (objets loupés par le réseau) [67].*

Comme illustré en figure 6.3, c'est bien la Précision qui, avec un taux 15% plus faible que celui du Rappel, pénalisait le F1-score estimé à peine 82%. Il convenait alors de réduire drastiquement le nombre de Faux Positifs (au regard des Faux Négatifs) et remonter ainsi la valeur moyenne de la F-mesure évaluée à 78.5% sur l'ensemble des 4 lots.

APPRENDRE DE SES ERREURS. — Il s'agissait alors d'apprendre au réseau à identifier ses propres erreurs pour améliorer significativement sa capacité à mieux détecter les cerises de café. Pour ce faire, un réseau bi-classes capable de détecter et d'identifier d'une part les « cerises de café » et d'autre part les « confusions du réseau » était proposé. Les VRAIS Faux Positifs, c'est-à-dire les erreurs expressément confirmées, de la validation précédente étaient utilisés comme données d'apprentissage de cette seconde classe.

Le processus de validation a été modifié pour ne comparer que les annotations et les prédictions de la seule classe « cerises de café ». La validation croisée permettait de constater d'une part une augmentation significative de près de 10% du taux de bonnes prédictions du réseau, et d'autre part une relative similarité des indicateurs entre les différents lots, comme illustré en Table 1 6.4.

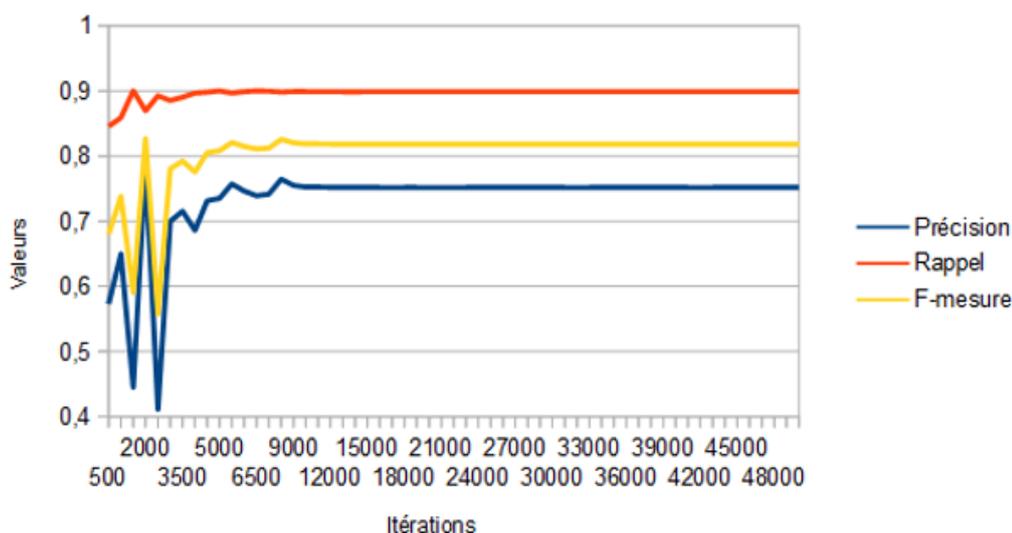


FIGURE 6.3. Fonctions précision, rappel et F1-score ou F-mesure en fonction du degré d'apprentissage du réseau.

Données	Précision	Rappel	F1-Score
Apprentissage	0,9022	0,8888	0,8954
LOT2	0,9113	0,8557	0,8826
LOT3	0,8943	0,8744	0,8842
LOT4	0,9225	0,8287	0,8730
<i>moyenne</i>	<i>0,9075</i>	<i>0,8619</i>	<i>0,8838</i>
<i>variance</i>	<i>0,0014</i>	<i>0,0067</i>	<i>0,0008</i>

FIGURE 6.4. Indicateurs du réseau bi-classes cerises, confusions par lots.

Ainsi, le Faster R-CNN présentait une bonne capacité à détecter de manière assez stable les cerises de caféiers dans des images prises du sol, avec **une précision 30% plus élevée** que celle de l'étude menée sur la variété Bourbon [78].

APPRENDRE À CONTEXTUALISER. — Dans l'idéal, le réseau se devait de ne détecter que les « drupes visibles de l'axe plagiotrope d'intérêt ». Cependant, le Faster R-CNN n'est pas connu pour sa capacité à restreindre sa détection à des fruits spécifiques selon leur position dans l'image. Ainsi, un réseau bi-classe entraîné à partir de la distinction experte a conduit sans surprise à un effondrement du F1-score moyen à 53

Une ultime expérimentation a été conduite pour évaluer la sensibilité du réseau à la détection des cerises de caféiers en fonction de l'éloignement à l'axe d'intérêt. Pour ce faire, des méthodes de filtrage de résultats en fonction de la taille d'un masque incluant l'axe plagiotrope d'intérêt ont été développées par les ingénieurs de la plateforme Agro'Deep [1] et incluses au conteneur de validation.

La validation croisée illustrée en figure 6.5 montra une augmentation sensible de la capacité du réseau à correctement détecter les drupes sur l'axe plagiotrope d'intérêt en atteignant un F1-score moyen de 93%. En conséquence, la solution consisterait soit à pré-segmenter efficacement l'image pour isoler l'axe

Données	infini	+50 px	+5 px
Apprentissage	0,8954	0,9113	0,9394
LOT2	0,8826	0,9108	0,9302
LOT3	0,8842	0,9022	0,9286
LOT4	0,8730	0,9006	0,9365
<i>moyenne</i>	<i>0,8838</i>	<i>0,9062</i>	<i>0,9336</i>
<i>variance</i>	<i>0,0008</i>	<i>0,0003</i>	<i>0,0002</i>

FIGURE 6.5. sensibilité du F1-score en fonction de la distance à l'axe d'intérêt.

plagiotope d'intérêt sachant que ce dernier ne présente ni les mêmes propriétés optiques ni la même localisation d'une image à l'autre, soit à réaliser un pré-zonage rapide pour limiter, par tracé au doigt ou à la souris, la zone de détection à une région de l'image se limitant à l'axe anatomique d'intérêt.

6.1.4. Conclusion

La plateforme Agro'Deep [1] a permis par son adaptabilité de conduire rapidement une étude visant à évaluer différentes hypothèses concernant la détection de cerises de caféiers dans des images prises *in situ*. Bien sûr, les développements informatiques nécessaires aux spécificités du projet ont nécessité l'intervention et l'appui des ingénieurs de la plateforme. Mais les outils développés ont pleinement rempli leur rôle en permettant aux chercheurs en agronomie d'être au final relativement autonomes dans le lancement des calculs, la gestion des données et l'interprétation des résultats. *Pour plus de détails sur les aspects appliqués, veuillez contacter Benoît Bertrand et/ou Luc Villain.*

6.2. LE PROJET DEEPMANGOCULTIVARS : AJUSTEMENT DE LA FONCTION D'IDENTIFICATION

Alors que les réseaux de neurones profonds ont prouvé leur efficacité pour détecter des éléments appartenant à des classes d'objets différentes, ils ne sont pas prévus pour détecter et différencier des objets visuellement très proches. Cette étude illustre l'apport des partenariats scientifiques et techniques proposés par l'équipe Agro'Deep [1], notamment sa capacité à adapter les réseaux au contexte spécifique des classes non séparables. En particulier, nous décrivons ici la modification amenée au mécanisme de détection de fruits pour permettre l'identification des variétés de fruits, en l'occurrence de mangues.

6.2.1. Contexte applicatif

Mesurer, estimer et prédire le rendement est un enjeu majeur en agriculture. L'incertitude associée a en effet des répercussions logistiques, organisationnelles, agronomiques ou encore économiques qui sont importantes aussi bien au niveau parcellaire qu'aux échelles de l'exploitation, du bassin de production, de la région ou du pays [13]. En Afrique le développement des filières fruitières est fortement freiné par le manque d'outils consultatifs factuels ou prédictifs permettant de dresser l'état de la production dans le temps et dans l'espace [82] [12].

L'estimation avant récolte de la production est importante pour les producteurs de fruits afin qu'ils organisent leurs travaux de récolte, le tri et le stockage de fruits et puissent anticiper leurs ventes. De plus, l'estimation et le suivi des récoltes des cultures fruitières sont des outils très attendus par les autres acteurs des filières : aujourd'hui, les acheteurs et les exportateurs luttent pour prévoir leurs approvisionnements ; les collectivités territoriales sont démunies pour concevoir des politiques agricoles

adaptées aux problématiques de leurs régions ; et les scientifiques sont en attente permanente de données quantitatives fiables pour répondre à leurs questions de recherches.

À ce jour, l'estimation des rendements dans les vergers en Afrique est basée sur une inspection visuelle d'un nombre limité d'arbres ; une méthode fastidieuse, longue et coûteuse qui dépend de la fiabilité et de la précision de l'observateur [82]. De plus, les producteurs d'Afrique de l'Ouest ont besoin d'outils qui peuvent leur fournir des informations sur la production de manière simple, peu coûteuse et pratique. Ces outils doivent être calibrés pour fonctionner dans les conditions de leurs systèmes de culture qui sont pour majoritairement de petite taille et très diversifiés, comportant plusieurs espèces fruitières parfois proches (c'est-à-dire issues du même genre) [24]. Ces systèmes peuvent également combiner plusieurs variétés d'une même espèce.

L'apprentissage profond appliqué à l'analyse d'images offre aujourd'hui des solutions pratiques pour le comptage des fruits et l'estimation du rendement. Au cours de ces dernières années, de nombreuses études ont utilisé des réseaux de neurones profonds, et plus particulièrement le Faster R-CNN [80][84], pour le comptage des fruits [70] et/ou l'estimation du rendement [30]. À notre connaissance, les meilleurs résultats sur la détection des mangues avec un F1-score de près de 97% et une précision moyenne de 98% sont ceux obtenus par [40] avec le réseau MangoYOLO sur des données homogènes prises la nuit.

Les performances des réseaux de type CNN diminuent lorsqu'il s'agit de détecter et d'identifier des objets de classes similaires (par exemple, différentes variétés de la même espèce de fruit). Même si un travail considérable a été réalisé sur les techniques de détection des fruits, il y existe actuellement peu de méthodes permettant l'identification des variétés d'une espèce de fruit. L'identification de variétés est essentielle pour l'estimation des rendements et la prévision des performances économiques des exploitations fruitières, en particulier dans les systèmes de culture diversifiés [24]. En effet, la culture de plusieurs variétés est une pratique courante dans les vergers traditionnels africains. Cette pratique garantit une production diversifiée et étalée dans le temps (différences phénologiques) sur une petite surface, rendant les producteurs moins dépendants des fluctuations des marchés économiques (culture de variétés d'exportation et de variétés locales) tout en préservant la biodiversité et en améliorant les services écosystémiques des cultures [53]. Dans ce contexte, la connaissance des niveaux de rendement (tonnes par hectare) par espèce et par variété est une mesure très appropriée pour la quantification de la production des vergers. Ainsi, l'identification des variétés, définie comme la classification des fruits détectés par variétés, est un défi majeur. À notre connaissance, les très rares études sur l'identification de variétés de litchis [64] ou de mangue récoltées [56] ont porté sur l'analyse de critères morphologiques des fruits en laboratoire. La transposition de ces approches aux images d'arbres acquises sur le terrain n'est pas anodine, le fruit étant rarement présenté sous un angle de vue favorable qui permette une bonne discrimination et classification.

6.2.2. Données

Cette étude a été réalisée sur la mangue dans le cadre du projet PixFruit qui met en œuvre une solution d'acquisition, de gestion, et de partage de données de production fruitière au bénéfice des acteurs des filières en Afrique [17]. La mangue est le 5ème fruit le plus produit dans le monde, cultivé dans les zones tropicales et subtropicales principalement par de petits producteurs. On ne dénombre pas moins de 1000 variétés de mangues dans le monde entier [59]. La mangue est de forme variable, ronde, ovale ou oblongue, selon la variété considérée. Sa peau lisse et brillante peut prendre différentes teintes allant du vert-jaune au rouge-violet. La couleur et l'aspect des fruits varient selon les variétés [5], mais aussi selon les stades phénologiques (du développement à la maturité du fruit [15]), sur un même fruit [62] et selon sa position dans l'arbre qui conditionne le microclimat et l'exposition à la lumière [49]. Dans cette étude, les scientifiques de l'UR HortSys, spécialisés dans le fonctionnement agroécologique et les performances des systèmes de culture horticoles, se sont intéressés à trois variétés cultivées dans les Niayes, un bassin de production de mangues important dans l'ouest du Sénégal [24] :

- La "Kent", un fruit de forme plutôt ovoïde avec une peau jaune et rouge dont le poids moyen ne dépasse pas 550 grammes,
- La "Keitt", de forme ovoïde et allongée, avec une peau rose présentant moins de 30% de rouge, et un poids moyen de 500 à 600 grammes,
- La BDH", nom court du cultivar local "Boucodiekhal", ovoïde-plat, avec une peau de couleur rouge à verte et un poids moyen de 450 grammes.

Près de 200 images couleur de cultivars de mangues "Kent", "Keitt" et "BDH" provenant de 30 vergers de trois systèmes de culture différents (petits exploitants extensifs, petits exploitants diversifiés et vergers commerciaux intensifs [77]) ont été collectées. Prises à une distance d'environ 5 mètres par un APN Sony Nex-7 RGB avec une longueur focale fixe de 18 mm, les images natives de 4 000 x 6 000 pixels ont été annotées manuellement et étiquetées, puis divisées en jeux d'entraînement et de validation contenant respectivement 7 500 et 10 000 données expertes.

6.2.3. Focus

Cette étude porta essentiellement sur la condition d'identification des fruits, c'est-à-dire le mécanisme de détection et de classification des variétés.

Dans le cas de classes d'objets séparables, les objets sont suffisamment différents pour que leur identification par le réseau ne soit pas ambiguë. Chaque objet détecté se voit attribuer une probabilité d'appartenance à chacune des classes possibles. Pour chaque objet détecté, la distribution de ces probabilités est la suivante : l'une de ces probabilités est normalement largement supérieure aux autres, indiquant par là même la classe à laquelle appartient l'objet détecté. Si aucune probabilité ne vérifie cette propriété, l'objet est non-identifiable et considéré comme non détecté. C'est parce que le réseau peut identifier un objet avec certitude que ce dernier est détecté. Du point de vue pratique, les différentes probabilités d'appartenance à une classe sont comparées à un seuil de confiance donné α , généralement fixé à une valeur strictement supérieure à 0.5. La somme des probabilités attribuées à chaque objet potentiel est égale à 1.

Dans le cas des variétés de mangue, les classes étaient trop proches les unes des autres : bien que les variétés présentaient des différences morphologiques suffisamment discriminantes pour l'œil humain, leur identification par le réseau s'avérait difficile sur les images acquises *in situ* en raison des angles de vue et/ou de l'occlusion partielle des fruits. Les classes de variétés n'étaient pas réellement séparables, contrairement aux classes de fruits.

Pour les fruits détectés présentant des caractéristiques relevant potentiellement de deux classes de variété proches, la distribution des probabilités de classe suivait un autre modèle : deux valeurs de probabilités proches plus élevées que les autres. Dans ce cas particulier, aucune des probabilités ne passait le seuil de confiance α , entraînant de facto la non-détection du fruit.

Pour préserver les fruits rejetés à tort, l'équipe d'appui Agro'Deep a introduit une fonction d'identification par hystérésis séparant la détection des fruits de l'identification (de la variété) des fruits détectés. Ainsi, la condition d'identification par hystérésis fonctionne comme suit : (1) la somme des probabilités des classes de variétés est supérieure au niveau de confiance donné α et (2) la probabilité la plus élevée des classes de variétés est supérieure au niveau de confiance donné β .

RÉSULTATS. — Le F1-score de la détection des mangues par un Faster R-CNN mono-classe s'élevait à 91% sur le jeu d'entraînement. Comme le montre le tableau 6.6, le F1-score moyen de l'identification des variétés par un Faster R-CNN multi-classes atteignait à peine 70% (avec un niveau de confiance α de 0,7). L'introduction d'une identification par hystérésis (avec des niveaux de confiance α et β respectivement de 0.7 et 0.55) a permis au F1-score moyen de remonter d'un peu plus de 10%, homogénéisant la réponse du réseau entre chaque variété, point particulièrement intéressant pour la quantification des rendements.

		$\alpha=0.7$	$\alpha=0.7, \beta=0.55$
Variétés	'BDH'	0,77	0,75
	'Keitt'	0,81	0,81
	'Kent'	0,46	0,81
moyenne		0,68	0,79

FIGURE 6.6. F1-scores et variétés

C'est toutefois La matrice de confusion qui permet de comprendre et confirmer sans aucune ambiguïté l'impact de l'identification par hystérésis, notamment en étudiant l'évolution des deux composantes de l'erreur, à savoir le défaut de détection des fruits et la mauvaise identification des fruits détectés. Ainsi sur le jeu de validation, le défaut de détection passa de 61% des fruits à 10% pour la variété 'Kent', de 21% à 13% pour la 'Keitt' et de 23% à 12% pour la 'BDH' ; dans le même temps, les erreurs d'identification de variété des fruits détectés restaient stables, oscillant entre 1 et 3% selon les classes. L'hystérésis, en distinguant la détection de fruits de l'identification des fruits détectés, a donc bien permis de "récupérer" les fruits écartés à tort par la méthode d'identification conventionnelle.

6.2.4. Conclusion

L'interaction des équipes de recherche applicatives de l'UR HortSys et des ingénieurs de recherche Agro'Deep [1] a permis d'adapter une solution publiée à un contexte particulier, notamment en modifiant certains scripts du réseau de neurones utilisé. Cette modification, totalement transparente pour l'utilisateur, a permis de sortir le réseau de sa zone de confort, notamment en l'amenant à réaliser ce pourquoi il a été développé (identification d'objets) dans un contexte pour lequel il n'a pas été conçu pour intervenir (classes non totalement séparables). Ces réflexions conjointes ont également permis de clarifier les notions de bases manipulées par les réseaux, et de bien séparer les aspects Détection des aspects Identification. *Pour plus de détails sur les aspects appliqués, veuillez contacter Émile Faye et/ou Julien Sarron.*

6.3. LE PROJET PALMDEEP : DONNÉES DE SYNTHÈSE ET ANNOTATIONS AUTOMATIQUES

Cette étude consistait à (tenter de) valider un modèle FSPM (Modèle Structure-Fonction de Plantes) en évaluant sur des données réelles les performances d'un réseau de détection entraîné à partir de données de synthèse produites en partie par le modèle à valider. Les principes de cette démarche ont été récemment présentés à la conférence FSPM2020 [34]. Au delà de cet objectif pour le moins original, elle a donné un cadre légitime pour aborder la question de l'automatisation des données d'entraînement et de validation des réseaux, aspect fortement sensible car visant à termes à supprimer toute expertise humaine dans la chaîne de mise au point des solutions. Rappelons que la pertinence d'une validation repose avant tout sur la qualité et la complétude de l'annotation des données de test.

6.3.1. Contexte applicatif

INTÉRÊT SOCIO-ÉCONOMIQUE DES RAPHIAS. — Les palmiers sont une des familles de plantes les plus utiles, fournissant sous les tropiques, de nombreux avantages économiques, écologiques et sociétaux [63][18]. L'espèce du genre *Raphia* est la plus largement utilisée et importante d'Afrique. Cependant, la pression anthropique a des impacts négatifs au niveau local et régional sur les Raphias et aucune

estimation des paramètres de base (nombre d'individus, biomasse . . .) n'a été entreprise. Le *Raphia* est une monocotylédone de la famille des *Arecaceae* pouvant atteindre 25 m de hauteur présente dans les milieux marécageux et le long des fleuves. Il n'a pas de stipe et son architecture est caractérisée par une tige monoaxiale constituée d'un bouquet de palmes mortes et vivantes [29]. Les feuilles sont disposées selon une symétrie radiale avec une phyllotaxie en hélice régulière autour de l'axe central. Sur une vue aérienne, un palmier adulte isolé apparaît comme une « étoile » constituée de feuilles disposées radialement autour d'un axe central avec des inclinaisons, des flexions et des torsions variables. En condition naturelle, ces *Raphias* se regroupent en forêts marécageuses appelées *Raphiales* où les couronnes sont imbriquées.

DE L'IMAGE AÉRIENNE AU DÉNOMBREMENT DES INDIVIDUS. — Il est donc très difficile d'individualiser les palmiers en milieu naturel à partir de vues aériennes. A ce jour, aucune étude n'a été réalisée sur le dénombrement des *Raphias* en forêt. Les études récentes de comptage de palmiers [14] [46] ne concernent que des plantations de palmiers à huile. Elles utilisent des approches « Deep Learning », et plus précisément de « Réseaux Neuronaux Convolutionnels » [45][41]. En imagerie satellite, des études [32] [57] montrent le potentiel de ces méthodes pour la reconnaissance d'objets, mais très peu de travaux sur les drones ont été conduits malgré le potentiel de ces vecteurs [89].

DES FSPM POUR ENTRAÎNER DES RÉSEAUX ET DES RÉSEAUX ENTRAÎNÉS POUR VALIDER LES FSPM. — Cette étude a mobilisé un réseau YoloV3 (*You Look Only Once*) [71] pour détecter les *Raphias* sur des images "couleur" de couverts forestiers acquis par drones. L'annotation experte des images réelles s'avérant incertaine voire impossible du fait de l'imbrication naturelle des arbres et de leur occlusion, il fut décidé d'utiliser des images de synthèse visualisant des maquettes issues de simulations pour constituer les jeux d'entraînement et de validation du réseau. A cette fin, les *raphias* ont été modélisés puis générés par le modèle de *Palmiers Principes* [37]. Des scènes virtuelles intégrant ces palmiers ont ensuite été générées avec un large panel d'autres maquettes 3D de plantes simulées issues de modèles structuraux génériques [73][75], du modèle fonctionnel *AmapSim* [7], et du modèle *GreenLab* [74]. Des vues aériennes de scènes ont finalement été produites pour entraîner le modèles de détection.

Il est important de rappeler que la validation des modèles FSPM reste l'un des aspects critiques et complexes de ces approches et peut être abordée de diverses façons : par une approche formelle méthodologie dédiée permettant l'étude théorique du modèle, l'assimilation des données et l'estimation des paramètres [39], par confrontation explicite avec des données traduisant des traits agronomiques [25], par confrontation avec des traits structuraux via une étude géométrique [9], ou par confrontation avec des grandeurs dites fonctionnelles indirectes à l'image d'études spectrales [28] ou d'échanges gazeux [69]. Les auteurs ont ici proposé une approche implicite globale de validation du modèle *Principes* sur le *Raphia* en évaluant sur des données réelles simples les performances d'un réseau de détection de palmiers entraîné à partir de données de synthèse produites par le modèle.

6.3.2. *Données*

Les données ont été générées en couplant plusieurs modèles d'arbres, dont *Principes* pour les différentes variétés de *Palmiers*, à des logiciels de synthèse permettant de définir des scènes plus ou moins complexes mélangeant des individus d'essence et d'âge différents. Deux types de sorties haute résolution étaient produites : d'une part une image de rendu réaliste [92] utilisant un modèle de calcul simple d'illumination par des cartes de profondeur [72] additionné d'effets visuels [33],[8], et d'autre part une image d'étiquettes de couleur permettant de rattacher chaque pixel de l'image à un élément spécifique de la scène 6.7. Les métadonnées telles que l'identifiant de l'individu, l'espèce, l'âge, les dimensions et la couleur de l'étiquette des individus visibles dans la scène étaient également fournies. Générer les sorties visuelles de 16 000

x 16 000 pixels d'une scène contenant de 5 000 à 20 000 plantes a nécessité de 15 à 60 minutes sur un ordinateur muni d'une RAM de 32 Go et d'une carte Nvidia GeForce GTX 1080 Ti.



FIGURE 6.7. Données de synthèse – gros plan d'une image de rendu réaliste de Raphias et de Cocotiers à gauche, étiquetage à droite

6.3.3. Focus

Cette étude a été entre autres l'occasion d'aborder la question sensible de la vérité image, c'est-à-dire de la qualité des annotations expertes, et en particulier la génération et la constitution automatique et pertinente de jeux de données annotées, étapes majeures tant pour l'entraînement des réseaux que pour leur validation. C'est donc ici le passage des images d'étiquettes aux annotations des données qui s'est avéré crucial : les recouvrements entre individus ont dû être gérés de façon à reproduire une annotation experte tenant compte de la pertinence des étiquetages visibles, l'idée étant à termes de se passer de toutes interventions humaines car hautement chronophages et potentiellement non reproductibles.

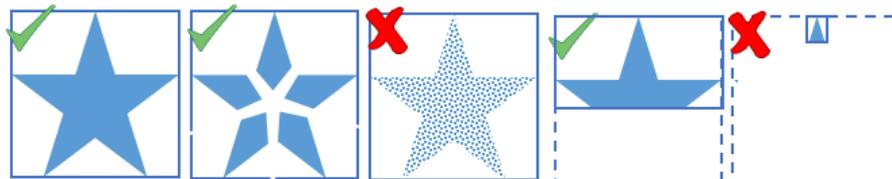


FIGURE 6.8. Occultations et annotations. Différentes configurations d'occultation partielle du motif initial présenté à gauche ont été étudiées pour définir les critères pertinents permettant d'automatiser les annotations. Le cas n° 3 a été rejeté car pas assez dense, le n°5 car pas assez représentatif.

Comme illustrés en figure 6.8, deux critères ont été simultanément considérés pour définir à partir de chaque étiquette une annotation réellement significative. D'une part la densité de l'annotation, c'est-à-dire le nombre de points visibles rapporté à la surface de la boîte englobante des points visibles, et d'autre part la représentativité visible de l'arbre, c'est-à-dire le nombre de points visibles rapporté au nombre

total de points de l'étiquette « hors toute contextualisation ». Un filtrage des annotations reposant sur un double seuillage a donc été appliqué à l'ensemble des annotations, tant sur le jeu d'entraînement que sur les jeux de validations comme montré en figure 6.9. L'âge et la nature des arbres sont venus compléter ce filtrage afin de bien contrôler le contenu des jeux de données annotées utilisés au cours des différentes expérimentations.



FIGURE 6.9. Annotations automatiques de Raphias dans une scène multi-essences. Les étiquettes présentaient un effet poreux du fait des occultations partielles des Raphias par d'autres essences

6.3.4. Résultats clés

La génération massive de données s'est avérée particulièrement utile pour « fixer » des valeurs optimales de seuils de densité et de représentativité permettant d'automatiser le passage de l'étiquetage à l'annotation pertinente des images à rendu réaliste. Une étude de l'impact des valeurs de ces seuils sur la capacité effective du réseau à « bien » détecter différentes essences de palmiers dans des couverts virtuels de forêts tropicales denses a permis de fixer les limites de densité et de représentativité respectivement à 0,25 et 0,3.

Les expérimentations conduites ont permis également d'aborder les relations entre détection et identification déjà évoquées dans l'étude Mangues. Comme indiqué en 6.10, près de 10% des individus ne semblaient pas être détectés ce qui potentiellement pointe un problème soit de méthode, soit de constitution de jeux d'entraînement et de validation.

		Prédictions			
		Cocotiers	Palmiers	Fond	Total
Cocotiers		472	3	63	538
Palmiers		35	355	58	448
Fond		49	52		
Total		556	410		

		Prédictions			
		Raphias	Palmiers	Fond	Total
Annotations	Raphias	356	23	69	448
	Palmiers	0	455	83	538
	Fond	30	49		
	Total	386	527		

FIGURE 6.10. Matrices de confusion des Cocotiers et Raphias sur le même jeu virtuel de validation.

Le résultat le plus significatif a consisté à estimer « à dire d'expert » la capacité du réseau entraîné sur des données virtuelles à détecter des Raphias sur des images réelles acquises par drones. Comme le

suggère la figure 6.11, les détections sont effectives tant que le contexte reste relativement simple, c'est-à-dire tant que les Raphias ne s'organisent pas en Raphiale, indiquant que le modèle structure-fonction Principes donne au final une description assez précise de la réalité des différentes essences de palmiers.



FIGURE 6.11. Détection des Raphias dans des images réelles aéroportées. Les prédictions du réseau sont données par les rectangles rouges.

6.3.5. Impacts clés

Du point de vue de la plateforme, cette étude a conduit à ouvrir les interfaces de calcul au paramétrage des pré et post-traitement embarqués dans les processus de calcul pour permettre l'approfondissement des études; il a été nécessaire de trouver un juste équilibre entre généralité et spécificité des IHM. Cet équilibre passe par l'utilisation d'une zone « libre » de saisie permettant de donner autant de paramètres que nécessaire selon les différents calculs proposés.

6.3.6. Conclusion

Cette étude a abordé le problème crucial de l'annotation automatique et de sa pertinence et a clairement posé les limites de la généralité des fonctionnalités de la plateforme. Elle a amené les ingénieurs de la plateforme à proposer des solutions permettant de spécialiser « en toute transparence » les IHM génériques de calcul, et ce indépendamment de la nature de ces derniers. *Pour plus de détails sur les aspects appliqués, veuillez contacter Frédéric Borne, Marc Jaeger et/ou Gaëlle Viennois.*

7. CONCLUSION

Cet article présente les aspects conceptuels, techniques et pratiques d'une plateforme de Calcul Applicatif expressément dédiée à l'agriculture numérique.

Depuis une décennie, l'Intelligence Artificielle (IA) contribue largement au développement de traitements innovants des données visuelles. Ainsi, les réseaux de neurones pénètrent massivement le domaine

de l'analyse d'image (détection et reconnaissance d'objets, extraction d'information) en agriculture de précision et relèguent les méthodes plus conventionnelles de segmentation ou de classification au second plan. Mais l'appropriation et la mise en œuvre de ces méthodes restent compliquées pour ne pas dire inaccessibles à de nombreuses communautés de recherche et de développement qui n'ont ni les moyens ni le temps d'investiguer ce domaine encore confidentiel de l'IA. Partant de ce constat, nous avons donc développé la plateforme numérique « collaborative » Agro'Deep qui vise à permettre à tout à chacun de bénéficier des apports potentiels de l'IA, et plus particulièrement des réseaux de neurones profonds, pour la résolution efficace d'aspects bien souvent en amont des questionnements scientifiques appliqués.

Agro'Deep est une plateforme de traitement distant de données visuelles par réseaux de neurones profonds proposant des services de détection, de dénombrement et de caractérisation d'organes de plantes pour l'agriculture numérique appliquée en particulier à l'agroécologie, l'agronomie, l'agroforesterie et l'agrobusiness. Elle fournit aux équipes de recherche thématique un cadre technique et un accompagnement méthodologique afin de développer, entraîner, adapter, valider et déployer des réseaux neuronaux de détection, de localisation et/ou de reconnaissance multiple d'organes spécifiques (fleurs, feuilles, fruits, arbres, etc.), et met à disposition de différentes communautés d'utilisateurs des réseaux neuronaux spécialisés pour des domaines spécifiques. Elle s'adresse avant tout aux unités de recherche publiques ou privées désireuses d'adapter ou de développer des méthodes d'identification de données visuelles basées sur des approches de Deep Learning dans le cadre de leurs questionnements scientifiques en s'appuyant sur des compétences et des ressources techniques externes. Elle concerne également les unités de production ou les sociétés privées confrontées au dénombrement ou à la caractérisation en masse et souhaitant évaluer des méthodes ou s'affranchir des contraintes et des expertises techniques propres à la gestion de données et à l'usage du Deep Learning.

Agro'Deep est une plateforme Web reposant sur un modèle économique équitable et participatif permettant l'accès à des ressources communes via un système de jetons. Du point de vue technique, il s'agit d'un Client Web léger conçu sur une architecture Modèle-Vue-Contrôleur Orientée Objet PHP qui couple la gestion de données, de ressources matérielles et des réseaux de neurones conteneurisés qui garantissent la reproductibilité des résultats et l'intégrité des serveurs de gestion et de calcul.

Un accompagnement technique et méthodologique des ingénieur.e.s de la plateforme est possible à travers des collaborations scientifiques. Trois exemples de support sont donnés : la détection de cerises de caféiers dans des images terrestres couleur pour illustrer l'utilisation des confusions du réseau pour le rendre plus pertinent et efficace, l'identification variétale de mangues dans des images terrestres couleurs montrant comment repousser les limites de l'identification d'objets visuellement très proches, et la classification des palmiers permettant d'aborder l'apport des images de synthèse pour optimiser l'apprentissage du réseau en vue de traiter des images aériennes prises par drones.

BIBLIOGRAPHIE

- [1] AGRO'DEEP, « Plateforme de Calcul Applicatif en Agroécologie, Agronomie et Agroforesterie numériques par Réseaux de Neurones Profonds », https://agrodeep-cirad.fr/AD_index.php.
- [2] S. A. ALGARNI, M. R. IKBAL, R. ALROOBAEA, A. S. GHIDUK & F. NADEEM, « Performance evaluation of Xen, KVM, and proxmox hypervisors », *International Journal of Open Source Software and Processes (IJOSSP)* **9** (2018), n° 2, p. 39-54.
- [3] N. ANTONOPOULOS & L. GILLAM, *Cloud computing*, London : Springer, 2010.
- [4] J. ASH & R. ADAMS, « On The Difficulty of Warm-Starting Neural Network Training », <https://openreview.net/forum?id=ry10cAVtPH>, 2020.
- [5] T. AYALA-SILVA, R. J. WINTERSTEIN, A. W. MEEROW, M. WINTERSTEIN, C. CERVANTES & J. S. BROWN, « Determination of color and fruit traits of half-sib families of mango (*Mangifera indica* L.) », *Florida State Horticultural Society* **118** (2005), p. 253-257.
- [6] G. BANNERJEE, U. SARKAR, S. DAS & I. GHOSH, « Artificial intelligence in agriculture : A literature survey », *International Journal of Scientific Research in Computer Science Applications and Management Studies* **7** (2018), n° 3, p. 1-6.

- [7] J. BARCZI, H. REY, Y. CARAGLIO, P. DE REFFYE, D. BARTHÉLÉMY, Q. DONG & T. FOURCAUD, « AmapSim : a structural whole-plant simulator based on botanical knowledge and designed to host external functional models », *Annals of Botany* **101** (2008), n° 8, p. 1125-1138.
- [8] A. VON BERNUTH, G. VOLK & O. BRINGMANN, « Simulating photo-realistic snow and fog on existing images for enhanced CNN training and evaluation », *Proc. of 2019 IEEE Intelligent Transportation Systems Conference (ITSC)* (2019), p. 41-46.
- [9] R. BEYER, D. BAYER, V. LETORT, H. PRETZSCH & P. H. COURNÈDE, « Validation of a functional-structural tree model using terrestrial Lidar data », *Ecological Modelling* **357** (2017), p. 55-57.
- [10] E. BISONG, « Google colabatory. In Building Machine Learning and Deep Learning Models on Google Cloud Platform », *Apress, Berkeley, CA* (2019), p. 59-64.
- [11] C. BÔMONT & A. CATTARUZZA, « Le cloud computing : de l'objet technique à l'enjeu géopolitique. Le cas de la France », *Herodote* (2020), n° 2, p. 149-163.
- [12] M. BURKE & D. LOBELL, « Satellite-based assessment of yield variation and its determinants in smallholder African systems », *Proceedings of the National Academy of Sciences* **114** (2017), p. 2189-2194.
- [13] C. CARLETTO, D. JOLLIFFE & R. BANERJEE, « From Tragedy to Renaissance : Improving Agricultural Data for Better Policies », *The Journal of Development Studies* **51** (2015), p. 133-148.
- [14] E. K. CHEANG, T. K. CHEANG & Y. H. TAY, « Using Convolutional Neural Networks to Count Palm Trees in Satellite Images », *arXiv preprint :1701* (2017), n° 06462.
- [15] P. H. DELGADO, M. ARANGUREN, C. REIG, D. F. GALVAN, C. MESEJO, A. M. FUENTES & M. AGUSTÍ, « Phenological growth stages of mango (*Mangifera indica* L.) according to the BBCH scale », *Scientia Horticulturae* **130** (2011), n° 3, p. 536-540.
- [16] O. DUJARDIN, « Détection, classification, identification », *Cj2R, Renseignement, Technologie et Armement* **15** (2020), p. 1-8, <https://cf2r.org/rta/detection-classification-identification/>.
- [17] F. E., S. J., D. J. & B. P., « PixFruit : un outil d'acquisition, de gestion, et de partage de données pour une normalisation de la filière Manguier en Afrique de l'Ouest aux services de ses acteurs », *AgriNumA 2019 Symposium "Agriculture Numérique en Afrique"* (2019).
- [18] W. L. EISERHARDT, J. C. SVENNING, W. D. KISSLING & H. BALSLEV, « Geographical ecology of the palms (Arecaceae) : determinants of diversity and distributions across spatial scales », *Annals of Botany* **36** (2011), n° 6, p. 1492-1522.
- [19] E. GAMMA, R. HELM, R. JOHNSON & J. VLISSIDES, *Design Patterns*, Addison Wesley, 2001.
- [20] J. GERNER, E. NARAMORE, M. OWENS & M. WARDEN, *Professional LAMP : Linux, Apache, MySQL and PHP5 Web Development*, John Wiley and Sons, 2005.
- [21] D. GODLOVE, « Singularity : Simple, secure containers for compute-driven workloads », *Practice and Experience in Advanced Research Computing on Rise of the Machines (learning)* (2019), p. 1-4.
- [22] I. GORTON, P. GREENFIELD, A. SZALAY & R. WILLIAMS, « Data-intensive computing in the 21st century », *Computer* **41** (2008), n° 4, p. 30-32.
- [23] C. GOUTTE & E. GAUSSIER, « A probabilistic interpretation of precision, recall and F-score, with implication for evaluation », in *European conference on information retrieval*, Springer, Berlin, Heidelberg, 2005, p. 345-359.
- [24] I. GRECHI, C. A. B. SANE, L. DIAME, H. DE BON, A. BENNEVEAU, T. MICHELS & J. Y. REY, « Mango-based orchards in Senegal : diversity of design and management patterns », *Fruits* **68** (2013), n° 6, p. 447-466.
- [25] Y. GUO, Y. MA, Z. ZHAN, B. LI, M. DINGKUN, D. LUQUET & DE REFFYE, « Parameter optimization and field validation of the functional-structural model GreenLab for maize », *Annals of botany* **97** (2006), n° 2, p. 217-230.
- [26] G. HAGER & G. WELLEIN, *Introduction to high performance computing for scientists and engineers*, CRC Press, 2010.
- [27] P. HENDERSON & V. FERRARI, « End-to-end training of object class detectors for mean average precision », in *Asian Conference on Computer Vision*, Springer, Cham., 2016, p. 198-213.
- [28] M. HENKE & G. H. BUCK-SORLIN, « Using a full spectral raytracer for calculating light microclimate in functional-structural plant modelling », *Computing and Informatics* **36** (2017), n° 6, p. 1492-1522.
- [29] M. HOFF & J. L. FLORENCE, « Note sur une raphiaie du Gabon », *Bulletin de la Société d'Histoire Naturelle de Colmar* **56** (1975), p. 191-197.
- [30] L. HOU, Q. WU, Q. SUN, H. YANG & P. LI, « Fruit recognition based on convolution neural network », *Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD), 2016 12th International Conference on, (IEEE)* (2016), p. 18-22.
- [31] A. HUSSAIN & M. ALEEM, « GoCJ : Google cloud jobs dataset for distributed and cloud computing infrastructures », *Data* **3** (2018), n° 4, p. 38-48.
- [32] D. IENCO, R. GAETANO, C. DUPAQUIER & P. MAUREL, « Land cover classification via multitemporal spatial data by deep recurrent neural networks », *IEEE Geoscience and Remote Sensing Letters* **14** (2017), n° 10, p. 1685-1689.
- [33] M. JAEGER, « Enhancing virtual natural scenes using quick and dirty image based recipes », *Proc. of 2012 IEEE 4th International Symposium on Plant Growth Modeling, Simulation, Visualization and Applications* (2012), p. 164-171.
- [34] M. JAEGER, G. VIENNOIS, M. BARIL, B. BORNE, H. REY, Y. NAGAO & P. BORIANNE, « Virtual plants and artificial tropical forest scenes as learning samples for deep learning plant classifiers. The case of *Raphia Hookeri* », *FSPM2020 : Towards Computable Plants ; the 9th International Conference on FUNCTIONAL-STRUCTURAL PLANT MODELS, 5-9 October, Leibniz University, Hannover* (2020).
- [35] R. JENNINGS, *Cloud computing with the Windows Azure platform*, John Wiley and Sons, 2010.

- [36] K. JHA, A. DOSHI, P. PATEL & M. SHAH, « A comprehensive review on automation in agriculture using artificial intelligence. », *Artificial Intelligence in Agriculture* **2** (2019), p. 1-12.
- [37] C. JOURDAN & H. REY, « Modelling and simulation of the architecture and development of the oil-palm (*Elaeis guineensis* Jacq.) », *Plant and soil* **190** (1997), n° 2, p. 217-233.
- [38] A. KAMILARIS & F. X. PRENAFETA-BOLDÚ, « A review of the use of convolutional neural networks in agriculture », *The Journal of Agricultural Science* **156** (2018), n° 3, p. 32-322.
- [39] M. KANG, J. HUA, X. WANG, P. DE REFFYE, M. JAEGER & S. AKAFFOU, « Estimating sink parameters of stochastic functional-structural plant models using organic series-continuous and rhythmic development », *Frontiers in plant science* **9** (2018), n° 1688.
- [40] A. KOIRALA, K. B. WALSH, Z. WANG & C. MCCARTHY, « Deep learning for real-time fruit detection and orchard fruit load estimation : Benchmarking of MangoYOLO », *Precision Agriculture* **20** (2019), n° 6, p. 1107-1135.
- [41] A. KRIZHEVSKY, I. SUTSKEVER & G. E. HINTON, « Imagenet classification with deep convolutional neural networks », *Advances in neural information processing systems* **25** (2012), p. 1097-1105.
- [42] G. M. KURTZER, V. SOCHAT & M. W. BAUER, « Singularity : Scientific containers for mobility of compute », *PloS one* **12** (2017), n° 5.
- [43] F. LANGNER, C. KNAUER, W. JANS & A. EBERT, « Side scan sonar image resolution and automatic object detection, classification and identification », *IEEE OCEANS 2009-EUROPE* (2009), p. 1-8.
- [44] M. LATHA, A. POOJITH, B. A. REDDY & G. V. KUMAR, « Image processing in agriculture », *International journal of innovative research in electrical, electronics, instrumentation and control engineering* **2** (2014), n° 6, p. 1562-1564.
- [45] Y. LECUN, Y. BENGIO & G. HINTON, « Deep learning », *Nature* **521** (2015), n° 7553, p. 436-444.
- [46] W. LI, H. FU, L. YU & A. CRACKNELL, « Deep Learning Based Oil Palm Tree Detection and Counting for HighResolution Remote Sensing Images », *Remote Sensing* **9** (2016), n° 12(22).
- [47] S. LIU, Y. YANG, W. G. QU & Y. LIU, « The business value of cloud computing : the partnering agility perspective », *Industrial Management and Data Systems* (2016).
- [48] M. LUTZ, *Programming Python : powerful object-oriented programming*, O'Reilly Media, Inc., 2010.
- [49] L. M., U. L. & J. J., « Chlorophyll Fluorescence, a Nondestructive Method To Assess Maturity of Mango Fruits (Cv. 'Cogshall') without Growth Conditions Bias », *J Agric Food Chem* **58** (2017), p. 7532-7538.
- [50] N. D. MAROM, L. ROKACH & A. SHMILOVICI, « Using the confusion matrix for improving ensemble classifiers », *IEEE 26-th Convention of Electrical and Electronics Engineers in Israel* (2010), p. 555-559.
- [51] F. MATTATIA, *RGPD et droits des données personnelles*, Eyrolles, 2019.
- [52] MBB@LR, « calcul intensif labex CeMeb Montpellier », <https://www.labex-cemeb.org/fr/montpellier-bio-informatique-et-biodiversite-mbb>.
- [53] C. MBOW, E. VAN NOORDWIJK, M. AND LUEDELING, H. NEUFELDT, P. A. MINANG & G. KOWERO, « Agroforestry solutions to address food security and climate change challenges in Africa », *Current Opinion in Environmental Sustainability* **6** (2014), p. 61-67.
- [54] W. MCCULLOCH & W. PITTS, « A Logical Calculus of Ideas Immanent in Nervous Activity », *Bull. Math. Biophys.* **5** (1943), p. 115-133.
- [55] MESO@LR, « HPC Montpellier », <https://meso-lr.umontpellier.fr/>.
- [56] A. S. A. METTLEQ, I. M. DHEIR, A. A. ELSHARIF & S. S. ABU-NASER, « Mango Classification Using Deep Learning », *International Journal of Academic Engineering Research (IJAER)* **3** (2019), n° 12, p. 22-29.
- [57] D. H. T. MINH, D. IENCO, R. GAETANO, N. LALANDE, E. NDIKUMANA, F. OSMAN & P. MAUREL, « Deep Recurrent Neural Networks for mapping winter vegetation quality coverage via multi-temporal SAR Sentinel-1 », *arXiv preprint arXiv :1708* (2017), n° 03694.
- [58] S. MITTAL & J. S. VETTER, « A survey of CPU-GPU heterogeneous computing techniques », *ACM Computing Surveys (CSUR)* **47** (2015), n° 4, p. 1-35.
- [59] S. MUKHERJEE & R. LITZ, *The mango : botany, production and uses*, Litz, R. E. (Ed.), 2009.
- [60] G. MUSCIANISI, G. FIAMENI & A. AZAB, « Singularity GPU containers execution on HPC cluster », *IEEE International Conference on High Performance Computing, Springer Cham.* (2019), p. 61-68.
- [61] X. NI, C. LI, H. JIANG & F. TAKEDA, « Deep learning image segmentation and extraction of blueberry fruit traits associated with harvestability and yield », *Horticulture Research* **7** (2020), n° 1, p. 1-14.
- [62] T. NORDEY, M. LÉCHAUDEL, M. GÉNARD & J. JOAS, « Spatial and temporal variations in mango colour, acidity, and sweetness in relation to temperature and ethylene gradients within the fruit », *Journal of plant physiology* **171** (2014), n° 17, p. 1555-1563.
- [63] F. I. OBAHIAGBON, « A review of the origin, morphology, cultivation, economic products, health and physiological implications of raphia palm », *African journal of food science* **3** (2009), n° 13, p. 447-453.
- [64] Y. OSAKO, H. YAMANE, S. Y. LIN, P. A. CHEN & R. TAO, « Cultivar discrimination of litchi fruit images using deep learning », *Scientia Horticulturae* **269** (2020), n° 109360.
- [65] M. PAK & S. KIM, « A review of deep learning in image recognition », *4th IEEE international conference on computer applications and information processing technology (CAIPT)* (2017), p. 1-3.

- [66] D. I. PATRÍCIO & R. RIEDER, « Computer vision and artificial intelligence in precision agriculture for grain crops : A systematic review. », *Computers and electronics in agriculture* **153** (2018), p. 69-81.
- [67] D. M. POWERS, « Evaluation : from precision, recall and F-measure to ROC, informedness, markedness and correlation », *arXiv preprint arXiv :2010* (2020), n° 16061.
- [68] M. G. C. M. . C. A. PÉREZ, A., « Serverless computing for container-based architectures », *Future Generation Computer Systems* **83** (2018), p. 50-59.
- [69] J. A. PRIETO, G. LOUARN, J. PEREZ PEÑA, H. OJEDA, T. SIMONNEAU & E. LEBON, « A functional–structural plant model that simulates whole-canopy gas exchange of grapevine plants (*Vitis vinifera* L.) under different training systems », *Annals of Botany* **126** (2020), n° 4, p. 647-660.
- [70] M. RAHNEMOONFAR & C. SHEPPARD, « Deep count : fruit counting based on deep simulated learning », *Sensors* **17** (2017), n° 4-905.
- [71] J. REDMON & A. FARHADI, « YOLOv3 : An incremental improvement », *arXiv preprint arXiv :1804* (2018), n° 02767.
- [72] W. T. REEVES, D. H. SALESIN & R. L. COOK, « Rendering antialiased shadows with depth maps », *ACM Siggraph Computer Graphics* **21** (1987), n° 4, p. 283-291.
- [73] P. DE REFFYE, C. EDELIN, J. FRANÇON, M. JAEGER & C. PUECH, « Plant models faithful to botanical structure and development », *ACM Siggraph Computer Graphics* **22** (1988), n° 4, p. 151-158.
- [74] P. DE REFFYE, B. HU, M. KANG, V. LETORT & M. JAEGER, « Two decades of research with the GreenLab model in Agronomy », *Annals of Botany* **127** (2021), n° 3, p. 281-295.
- [75] P. DE REFFYE, R. LECOUSTRE, J. DAUZAT, S. OUATTARA, A. FLORI & Y. N'CHO, « Modelling plant architecture. Application to tropical agronomic perennial plants. The particular case of the Palmaceae », *Oléagineux (Paris)* **44** (1989), n° 11, p. 537-546.
- [76] S. REN, K. HE, R. GIRSHICK & J. SUN, « Faster r-cnn : Towards real-time object detection with region proposal networks », *arXiv preprint arXiv :1506* (2015), n° 01497.
- [77] J. Y. REY, T. M. DIALLO, H. VANNIÈRE, C. DIDIER, S. KÉITA & M. SANGARÉ, « The mango in French-speaking West Africa : varieties and varietal composition of the orchards », *Fruits* **61** (2007), n° 1, p. 57-73.
- [78] J. P. RODRÍGUEZ, D. C. CORRALES, J. N. AUBERTOT & J. C. CORRALES, « A computer vision system for automatic cherry beans detection on coffee trees », *Pattern Recognition Letters* **136** (2020), p. 142-153.
- [79] F. ROSENBLATT, « The perceptron : a probabilistic model for information storage and organization in the brain », *Psychological review* **65** (1958), n° 6(386).
- [80] I. SA, Z. GE, F. DAYOUB, B. UPCROFT, T. PEREZ & C. MCCOOL, « Deepfruits : A fruit detection system using deep neural networks », *Sensors* **16** (2016), n° 8-1222.
- [81] T. SANTOS, L. DE SOUZA, A. DOS SANTOS & S. AVILA, « Grape detection, segmentation, and tracking using deep neural networks and three-dimensional association », *Computers and Electronics in Agriculture* **170** (2020), n° 105247.
- [82] J. SARRON, « Estimation spatialisée des rendements d'une culture pérenne en Afrique de l'Ouest : le cas du manguier au Sénégal », Thèse, University of Montpellier, 2019.
- [83] J. SOULE & J. PIPER, *Farming in nature's image : An ecological approach to agriculture*, Island Press, 1992.
- [84] J. P. VASCONEZ, J. DELPIANO, S. VOUGIOUKAS & F. A. CHEEIN, « Comparison of convolutional neural networks in fruit detection and counting : A comprehensive evaluation », *Computers and Electronics in Agriculture* **173** (2020), n° 105348.
- [85] S. J. VAUGHAN-NICHOLS, « New Approach to Virtualization Is a Lightweight », *Computer* **39** (2006), n° 11, p. 12-14.
- [86] S. VICENTE, J. CARREIRA, L. AGAPITO & J. BATISTA, « Comparison of convolutional neural networks in fruit detection and counting : A comprehensive evaluation », *Proceedings of the IEEE conference on computer vision and pattern recognition* (2014), p. 41-48.
- [87] W3TECHS, « Usage statistics of server-side programming languages for websites », https://w3techs.com/technologies/overview/programming_language.
- [88] S. WAN & S. GOUDOS, « Faster R-CNN for multi-class fruit detection using a robotic vision system », *Computer Networks* **168** (2020), n° 107036.
- [89] S. WICH, « Drones and conservation », *Drones and Aerial Observation : New Technologies for Property Rights, Human Rights, and Global Development* (2015), p. 63-71.
- [90] A. J. YOUNGE, K. PEDRETTI, R. E. GRANT & R. BRIGHTWELL, « A tale of two systems : Using containers to deploy HPC applications on supercomputers and clouds », *IEEE International Conference on Cloud Computing Technology and Science (CloudCom)* (2017), p. 74-81.
- [91] G. ZHANG & M. N. RAVISHANKAR, « Exploring vendor capabilities in the cloud environment : A case study of Alibaba Cloud Computing », *Information and Management* **56** (2019), n° 3, p. 343-355.
- [92] X. ZHANG, G. BAO, W. MENG, M. JAEGER, H. LI, O. DEUSSEN & B. CHEN, « Tree branch level of detail models for forest navigation », *Computer Graphics Forum* **36** (2017), n° 8, p. 402-417.