

A circular graphic in the top left corner shows a network of glowing blue and yellow nodes connected by thin lines, resembling a neural network or a complex biological structure.

# DEEP LEARNING ET AGRICULTURE

A large, semi-circular graphic of a green leaf with detailed vein patterns is positioned in the bottom right quadrant of the page.

> COMPRENDRE  
LE POTENTIEL  
ET LES DÉFIS À  
RELEVER

## REMERCIEMENTS

**Merci à tous ceux qui ont pris le temps de répondre à nos questions dans le cadre de cette étude :**

- > **Xavier L'Hostis**, Responsable Service Innovation - Adventiel,
- > **Théo-Paul Haezebrouck**, Responsable Produit - API-AGRO,
- > **Benoît De Solan**, Ingénieur de recherche - Arvalis, UMT Capte,
- > **Benjamin Wallace**, Responsable Xarvio Digital Farming France - BASF,
- > **Colin Chaballier**, Manager général - Carbon Bee AGTECH,
- > **Gérald Germain**, Président - Carbon Bee AGTECH,
- > **Macha Nikolski**, Directrice - Centre de BioInformatique de Bordeaux (CBiB),
- > **Emmanuel Bouilhol**, Doctorant - CBiB,
- > **Antoine Simon**, Ingénieur Agronome - Chouette Vision,
- > **Sébastien Giordano**, Ingénieur des Travaux Géographiques et Cartographiques de l'Etat - IGN, MATIS,
- > **Alexis Joly**, Co-responsable scientifique du projet PL@ntNet - INRIA,
- > **Emmanuel Benazera**, Chercheur - JoliBrain,
- > **Guillaume Infantes**, Chercheur - JoliBrain,
- > **Guillaume Avrin**, Responsable technique de l'activité Évaluation des systèmes d'intelligence artificielle  
Direction des Essais - Laboratoire national de métrologie et d'essais,
- > **Christian Germain**, Enseignant Chercheur - Laboratoire IMS / Bordeaux Sciences Agro,
- > **Lionel Bombrun**, Enseignant Chercheur - Laboratoire IMS / Bordeaux Sciences Agro,
- > **Sylvie Roussel**, Directrice - Ondalys,
- > **Lilian Vallette**, Responsable Etablissement de Bordeaux - Telespazio France,
- > **Elodie Pagot**, Ingénieure Recherche et Développement - Telespazio France.

# CONTENU



INTRODUCTION.....	4
<b>» 1   Qu'est-ce que le Deep Learning ?</b> .....	5
<b>1.1. De l'intelligence artificielle au Deep Learning</b> .....	5
> L'IA, un vaste domaine scientifique.....	5
> Le Machine Learning : qu'est-ce que c'est, à quoi ça sert ?.....	6
> Le Deep Learning : un sous-ensemble de méthodes d'apprentissage machine.....	8
<b>1.2. La révolution Deep Learning</b> .....	10
1.2.1. Quand soudain le Deep Learning fut.....	10
1.2.2. Ce que change le Deep Learning.....	11
1.2.3. Enjeux et opportunités pour l'Agriculture.....	12
<b>1.3. Des réseaux de neurones au Deep Learning</b> .....	14
1.3.1. Un exemple.....	14
1.3.2. Au commencement était le neurone simple ou neurone formel.....	14
1.3.3. Puis on ajouta des couches.....	15
1.3.4. Aujourd'hui, 3 grandes familles de réseaux profonds.....	17
1.3.5. Un écosystème en développement sur un socle opensource.....	21
<b>» 2   Que peut le Deep Learning pour l'Agriculture ?</b> .....	22
<b>2.1. Deep Learning et agriculture : un axe de recherche actif</b> .....	22
<b>2.2. De la recherche aux premières propositions commerciales : des exemples d'applications dans le secteur agricole</b> .....	22
2.2.1. En Productions animales.....	23
2.2.2. En Productions végétales.....	24
2.2.3. Autres cas où l'apprentissage profond change(ra) la donne en agriculture.....	32
<b>» 3   Deep Learning : questions et réflexions</b> .....	34
<b>3.1. Les données : la force et le talon d'Achille du Deep Learning ?</b> .....	34
<b>3.2. La puissance de calcul nécessaire au Deep Learning est-elle compatible avec l'agriculture, secteur de terrain ?</b> .....	39
<b>3.3. Peut-on avoir confiance dans des systèmes « boîtes noires » ?</b> .....	41
<b>3.4. Le Deep Learning est-il un phénomène de mode ?</b> .....	44
CONCLUSION.....	46
RÉFÉRENCES.....	47

# INTRODUCTION

S'il est un domaine en plein développement actuellement, c'est bien celui de l'intelligence artificielle.

De la reconnaissance de visages, aux assistants conversationnels, en passant par les véhicules autonomes et les systèmes de recommandations d'achats sur internet, ces nouvelles technologies envahissent notre quotidien. Et dans ce large domaine, un type de méthodes fait plus particulièrement parler de lui : **le Deep Learning**.

Le Deep Learning, ou apprentissage profond, est par exemple à l'origine du très médiatique succès d'AlphaGo, un programme de Google, qui, à plusieurs reprises, a battu les meilleurs champions de Go. Or, le Go est un jeu de stratégie réputé comme étant l'un des plus complexes au monde du fait de l'étendue des combinaisons possibles. Pour obtenir ce résultat, ce ne sont pas des développeurs qui ont codé toutes les règles et les coups possibles. Le système, basé sur un réseau de neurones artificiels, a étudié des milliers de parties menées par des joueurs de haut niveau et appris à jouer à partir de ces exemples.

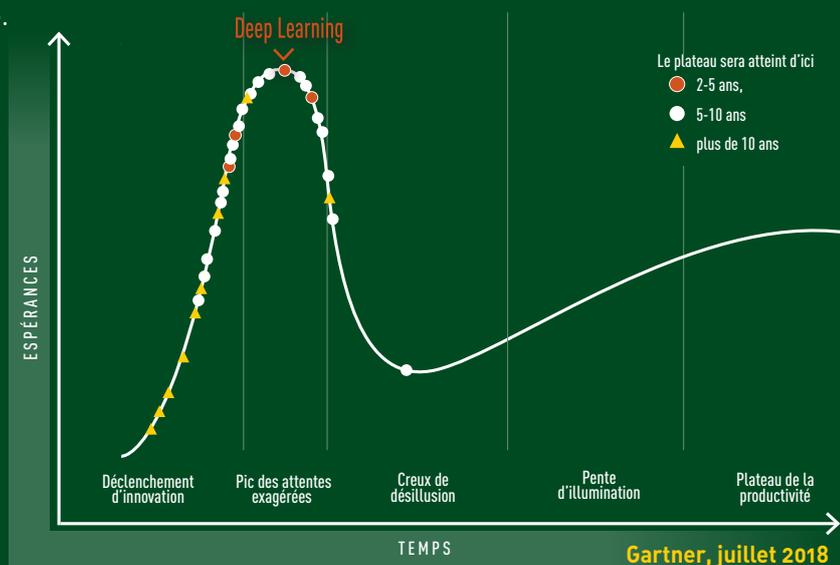
Le potentiel de ces technologies semble énorme. D'ailleurs, depuis deux ans, l'Institut Gartner les a placées tout en haut de sa fameuse courbe des technologies émergentes, au pic des espérances qu'elles peuvent générer.

Mais entre le potentiel et ce que l'on doit réellement en attendre, entre Deep Learning et autres domaines de l'intelligence artificielle, il n'est pas forcément facile de s'y retrouver...

La Chaire AgroTIC a donc souhaité s'intéresser de plus près à ce sujet, en particulier pour savoir où on en est dans le domaine de l'Agriculture.

En effet, le Deep Learning est déjà exploré depuis quelque temps en Agriculture. D'abord par le monde de la Recherche puis par celui de la Recherche et du Développement. A l'heure où les premières applications commerciales vont arriver sur le marché, il nous semble important de pouvoir poser sur ces technologies un regard éclairé : comprendre ce dont il s'agit, quelles en sont les applications, les limites et quelles sont les questions qui restent posées...

C'est donc ce que souhaite proposer la Chaire AgroTIC au travers de ce rapport : un point de situation sur le Deep Learning pour l'Agriculture, au travers de **3 PARTIES**, à lire dans l'ordre ou de façon indépendante :



## PARTIE 1

« **Qu'est-ce que c'est ?** »  
pour voir ou revoir les principes (et le vocabulaire) de base : de l'intelligence artificielle aux nouveaux outils et méthodes d'apprentissage profond.



## PARTIE 2

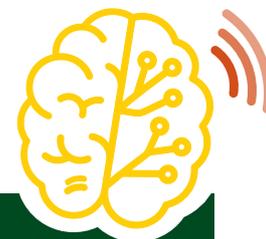
« **Que peut le Deep Learning pour l'Agriculture ?** »  
pour explorer les applications déjà envisagées (sachant bien sûr que d'autres sont encore à venir). Cette partie sera illustrée par les témoignages de ceux qui, aujourd'hui, se sont déjà lancés dans l'aventure...



## PARTIE 3

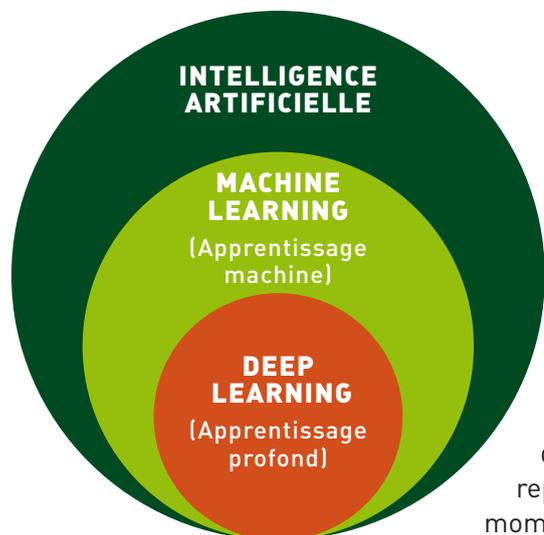
« **Questions et réflexions** »  
pour mieux comprendre les enjeux scientifiques, techniques, sociaux... liés à l'évolution de ce nouveau domaine technologique...

# PARTIE 1 : QU'EST-CE QUE LE DEEP LEARNING ?



## 1.1. De l'intelligence artificielle au Deep Learning

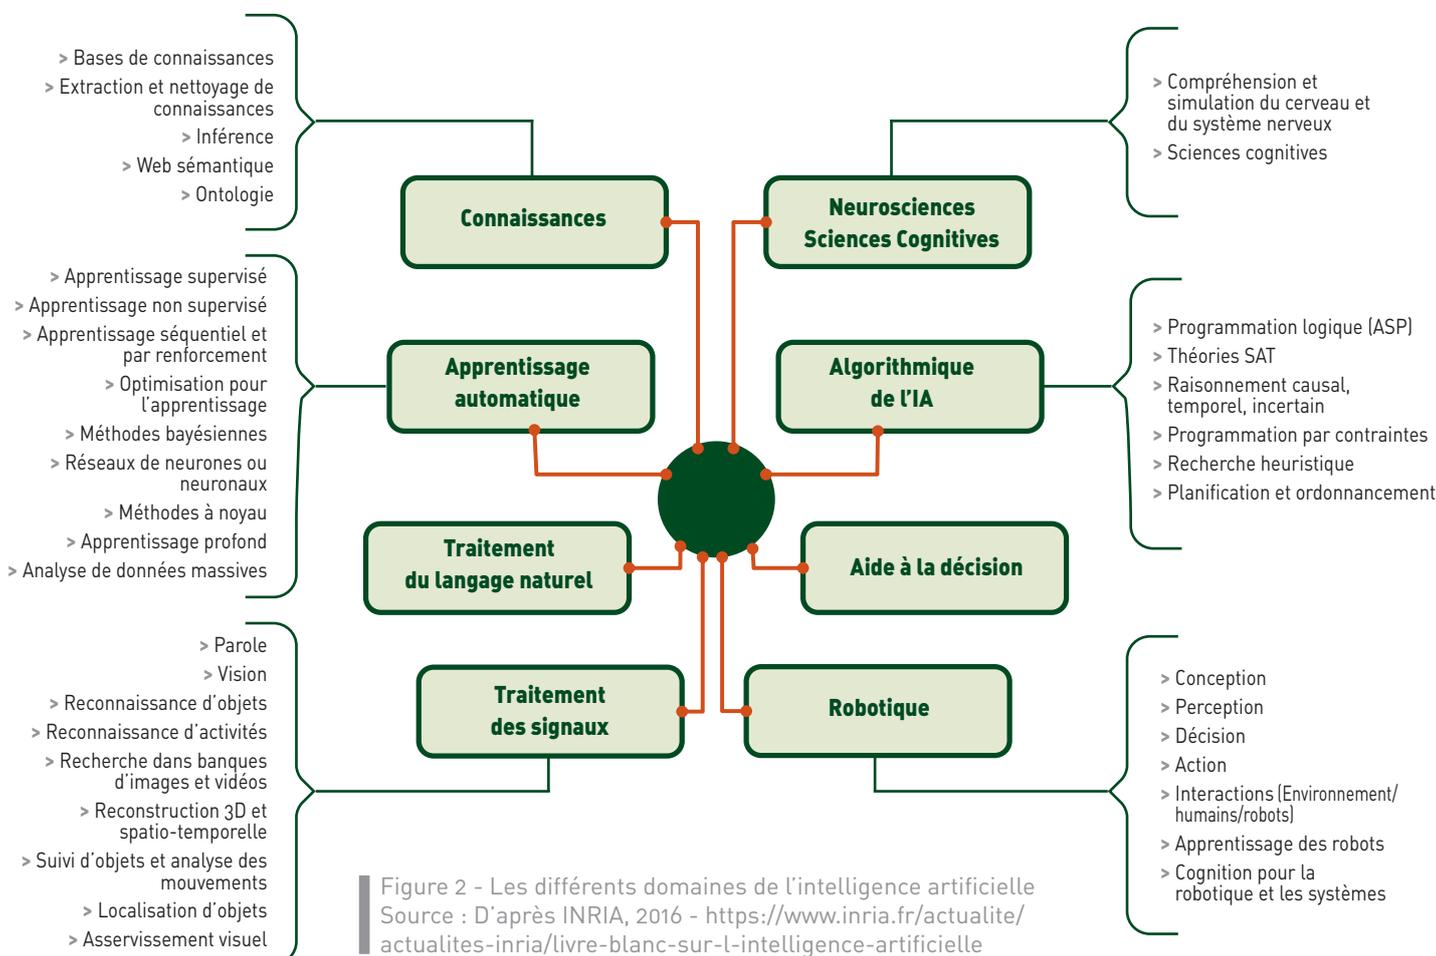
Pour commencer par le commencement, resituons le Deep Learning par rapport au vaste domaine de l'Intelligence Artificielle (IA ou AI en anglais). Le Deep Learning n'en est en effet qu'un sous ensemble. Il fait partie des méthodes d'apprentissage automatique (ou Machine Learning), constituant elles-mêmes l'une des branches de l'IA. Reprenons progressivement ces différents termes...



### L'IA, UN VASTE DOMAINE SCIENTIFIQUE

Notion apparue dès les années 50, l'intelligence artificielle peut-être définie comme l' « ensemble de techniques permettant à des machines d'accomplir des tâches et de résoudre des problèmes normalement réservés aux humains et à certains animaux » (1). Il s'agit donc de techniques qui visent à reproduire, imiter, simuler l'intelligence, ou en tout cas les capacités que l'on peut associer à ce terme : capacité à percevoir son environnement, à interagir avec lui, à communiquer au moyen d'un langage, à mettre en œuvre un raisonnement et à résoudre des problèmes, à planifier des actions afin d'atteindre un but, à représenter la connaissance, à appliquer cette connaissance au moment opportun...

Comme dit précédemment, le domaine est donc très vaste et s'organise en de multiples branches qui associent sciences cognitives, mathématiques, électronique, informatique...



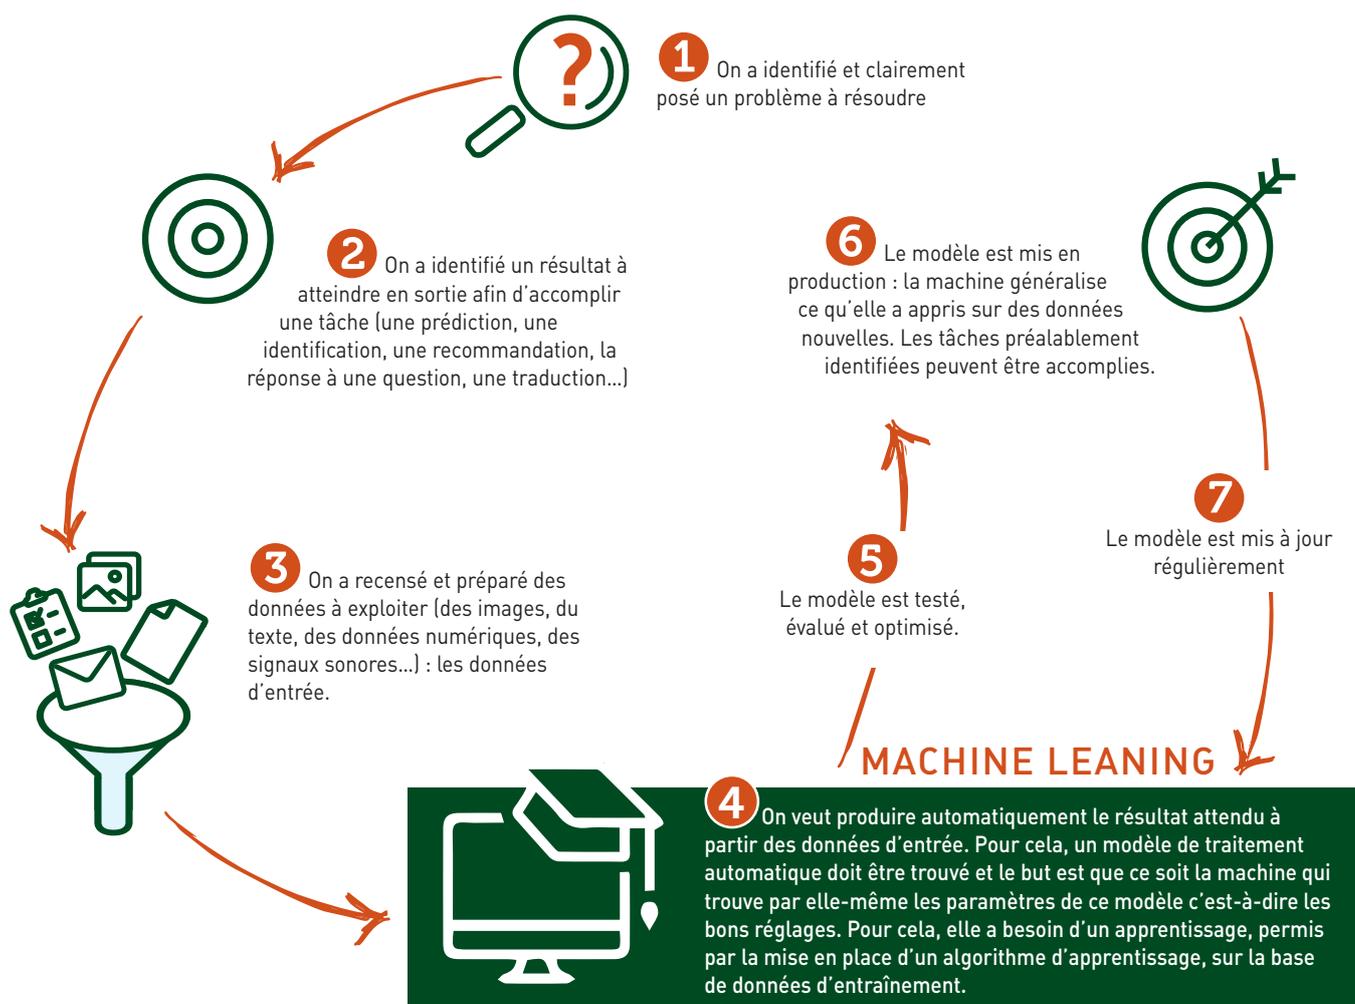
Les évolutions en matière d'IA ont suivi différents courants. Dans les années 80, par exemple, les « systèmes experts » correspondent à une approche basée sur la capacité à reproduire un raisonnement logique. Ces programmes permettent de répondre à des questions ou problèmes dans un domaine très spécifique, où la machine sert à mettre en œuvre des règles logiques décrites par des experts humains et implémentées dans des bases de connaissance. Ce type d'approche est encore assez proche de l'informatique classique où il faut identifier à l'avance toutes les informations à fournir au système. Elle peut vite être limitée pour des cas complexes où de multiples paramètres doivent être pris en compte.

Une autre approche consiste plutôt à s'inspirer du fonctionnement du cerveau, sa façon de modéliser et de s'adapter à l'environnement. Le **Machine Learning**, et donc le **Deep Learning**, relèvent plutôt de cette approche.

## LE MACHINE LEARNING : QU'EST-CE QUE C'EST, À QUOI ÇA SERT ?

Apparu dès les années 50, le **Machine Learning** correspond au fait de donner la capacité d'apprendre à la machine, par elle-même, quelle que soit la situation, sans que l'on ait formellement à écrire (ni même à connaître) toutes les règles.

La machine learning s'inscrit dans un processus de traitement d'un problème complexe, qui peut se présenter comme suit :



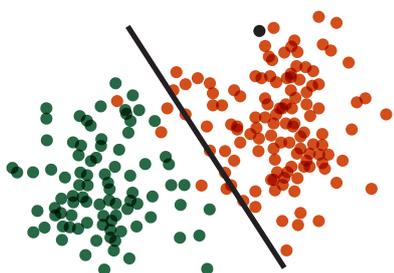
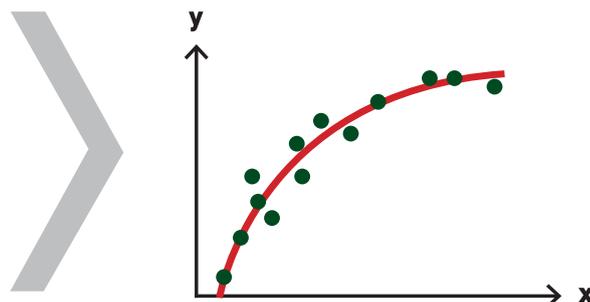
Attention, par *modèle* il faut simplement comprendre ici une chaîne de traitements qui permet de passer de données d'entrée à un résultat attendu.

Ce résultat peut viser par exemple à :

### PREDIRE un résultat Y en fonction de variables d'entrée X

Quand il s'agit de prédire une variable numérique, à partir d'une ou plusieurs autres variables numériques, on parle de « régression ».

Par exemple, on connaît la valeur Y de sortie pour une série de données X d'entrée : (X1;Y1), (X2;Y2), etc... En utilisant ces données, on veut que le système trouve une fonction mathématique,  $Y=f(X)$ , permettant d'estimer de façon suffisamment fiable Y pour une entrée X.



### Réaliser une classification

Il s'agit en fait là aussi d'une prédiction mais de variable qualitative...

On cherche à connaître à quelle « classe » l'individu peut être rattaché. Est-ce que l'individu en noir appartient à la classe verte ou à la classe rouge ? Beaucoup de problèmes d'analyse d'image par exemple correspondent à des cas de classification : est-ce que

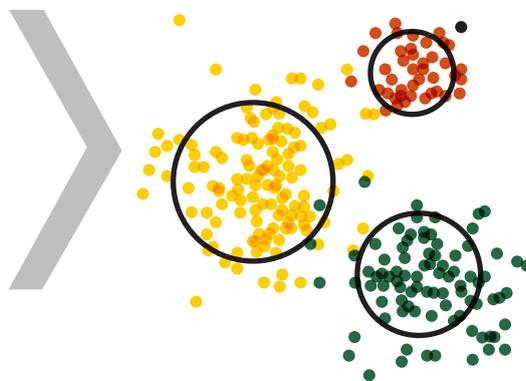
telle parcelle (voire tel pixel) correspond à du blé ou à de l'orge ? Est-ce que cette plante est une adventice ou bien du maïs ? Le résultat d'une classification se présente en général sous la forme d'un « score », une probabilité, d'appartenance à une classe donnée.

### Trouver des caractéristiques communes dans un ensemble de données, constituer des sous-groupes d'individus présentant des similarités entre eux au sein de cet ensemble.

On parle de « clustering ».

Par exemple, c'est ce type de techniques qui permet depuis de nombreuses années à nos sites d'e-commerce préférés de nous faire des recommandations en analysant notre profil utilisateur, en le rapprochant de celui d'autres utilisateurs et en nous suggérant d'acheter ce que ceux qui nous « ressemblent » ont acheté...

Ce type d'utilisation permet également d'identifier des individus qui ne se situent pas dans des groupes homogènes : cela permet par exemple de détecter des anomalies ou des fraudes.



La **phase d'apprentissage** repose sur un **algorithme d'apprentissage** c'est-à-dire la mise en place d'une architecture et d'un programme informatiques qui permettent à une machine de recevoir des données d'entrée, d'effectuer une série de traitements utilisant ces données d'entrée, de produire un résultat en sortie et, surtout, **de s'améliorer** pour produire ce résultat. Ce dernier point suppose qu'un objectif de résultat (et éventuellement une tolérance par rapport à l'atteinte de cet objectif) soit communiqué au système et que des **données d'entraînement** et les moyens **de mesurer ses performances** lui soient fournis. **C'est en cherchant à améliorer ses performances sur les données d'entraînement que la machine va apprendre.** Une fois que l'apprentissage sera terminé, la « machine » pourra produire le résultat de façon autonome sur des données d'entrée qu'elle n'aura encore jamais rencontrées.

Mais, selon le résultat visé, les données dont on dispose au départ et le contexte, il existe plusieurs façons de faire apprendre à une machine. On distingue notamment **l'apprentissage supervisé**, **l'apprentissage non supervisé** et **l'apprentissage par renforcement** (d'autres méthodes existent mais nous ne les développerons pas ici).



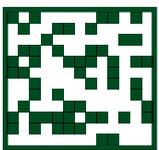
### > Apprentissage supervisé : apprendre par l'exemple

Dans le cas de l'apprentissage supervisé, le système est guidé dans son apprentissage. On lui indique le type de résultat à atteindre en le nourrissant d'exemples. Pour cela, on lui fournit des données d'entrée pour lesquelles le résultat est connu et communiqué au système. Le but est qu'il puisse ensuite généraliser ce qu'il a appris pour des données non connues. Par exemple, si le système doit apprendre à reconnaître des feuilles de vigne dans une image, on lui fournit des images où la feuille est signalée et où le label « feuille de vigne » est associé. On parle ainsi de données étiquetées ou annotées. Le jeu de données d'entraînement annotées permet au système de calculer ses erreurs en comparant ses résultats avec les résultats connus et ainsi d'ajuster le modèle pour progresser. Une partie des données annotées (non utilisées pendant l'entraînement) pourra également servir à vérifier l'efficacité du modèle, une fois l'apprentissage terminé.



### > Apprentissage non supervisé : apprendre en explorant

Dans le cas de l'apprentissage non supervisé, on ne donne pas d'exemples de résultats attendus au système. Seules les données d'entrée sont fournies et le système doit apprendre, de façon autonome, la meilleure façon d'explorer les données. Il doit chercher à identifier dans le jeu de données une façon de les structurer (trouver des modèles ou « patterns ») ou encore à extraire des caractéristiques particulières. La performance permettant l'ajustement du modèle est alors appréciée grâce à des indicateurs objectifs, comme, par exemple, des calculs de variabilité intra ou interclasses.



### > Apprentissage par renforcement : apprendre selon un principe de « cause à effet »

Le système apprend cette fois par interaction avec l'environnement. A chaque instant, le système connaît l'état actuel et toutes les actions possibles. Il effectue une des actions et reçoit un signal de retour qui lui notifie son nouvel état et la récompense associée. A force d'itération, le système doit pouvoir déterminer automatiquement le comportement idéal (celui qui maximise les récompenses) pour un contexte spécifique. Ce type d'apprentissage est également dit « semi-supervisé » dans la mesure où la récompense donne une indication sur le bon résultat à atteindre.

Notons que, si l'apprentissage non supervisé est une sorte de « graal pour les chercheurs en intelligence artificielle » [2] et si l'apprentissage par renforcement ouvre de belles perspectives, l'apprentissage supervisé reste de loin le plus exploré et pratiqué à l'heure actuelle, notamment pour des applications de régression ou de classification pour lesquelles il donne de meilleurs résultats.

## LE DEEP LEARNING : UN SOUS-ENSEMBLE DE MÉTHODES D'APPRENTISSAGE MACHINE

En fonction des différentes problématiques posées, les développeurs et chercheurs en IA ont exploré et mis au point une palette de familles d'algorithmes. Parmi les plus connues, on peut citer :

- **la méthode de k plus proches voisins** - apprentissage supervisé / classification,
- **les SVM (machines à vecteur de support)** – apprentissage supervisé / régression ou classification,
- **les arbres de décision et les forêts aléatoires (Random Forest)** - apprentissage supervisé / classification (en tenant compte de l'impact de la décision),
- **les réseaux de neurones** – apprentissage supervisé ou non supervisé.

Le Deep Learning peut être vu comme une sous-catégorie des « réseaux de neurones ». En effet, il s'agit d'un ensemble d'outils et de méthodes d'apprentissage automatique basés sur l'utilisation « avancée » de réseaux de neurones. On utilise les mots « deep » ou « profond » en référence au nombre de couches de neurones qui constituent ces réseaux : plus le nombre de couches est grand plus le réseau est profond et plus il permet de traiter des problèmes complexes. Les réseaux de neurones « simples », c'est-à-dire de profondeur plus modeste, sont eux nommés « Shallow Networks ».

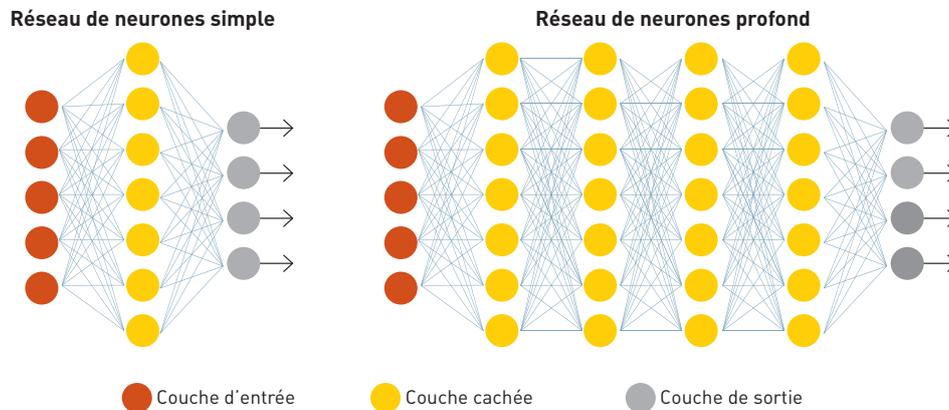


Figure 3  
Des réseaux simples aux réseaux profonds - Source : HackerNoon (depuis makina-corpus.com)

L'utilisation des réseaux de neurones en apprentissage automatique n'a rien de nouveau. Le tout premier algorithme, le Perceptron, a été proposé dès 1957 par Franck Rosenblatt.

Les réseaux de neurones artificiels s'inspirent (sans en être la copie) du fonctionnement des réseaux de neurones des cerveaux humains ou animaux. Le cerveau est constitué d'un très grand nombre de cellules spécialisées, les neurones, étroitement liées entre elles par des milliers d'interconnexions. Chaque neurone est capable de traiter de multiples informations en provenance de son environnement et de réagir en créant des messages électrochimiques. Un neurone seul ne réalise que des opérations élémentaires, mais associés en réseau, les neurones permettent aux hommes et aux animaux d'accomplir des tâches cognitives extrêmement complexes. Les réseaux de neurones artificiels reprennent ce principe en interconnectant de multiples unités élémentaires, les neurones formels, dans le but de résoudre des problèmes. Ils sont organisés en *couches* où **chaque couche répond à un niveau d'abstraction d'un problème.**

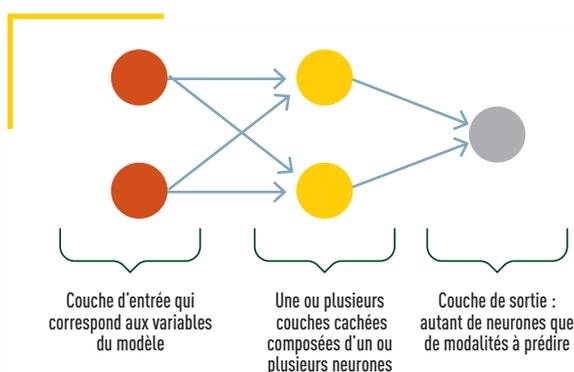


Figure 4  
Les types de couches d'un réseau de neurones

Dans le cas des réseaux multicouches (de type « *Perceptrons multicouches* ») :

- > la première couche correspond aux données d'entrée
- > la dernière couche correspond aux sorties attendues, par exemple les différentes classes dans un problème de classification.
- > les couches intermédiaires sont appelées « *couches cachées* ». Les sorties d'une couche deviennent les entrées de la couche suivante.

Mais, de leur invention jusque dans les années 2000, les réseaux de neurones utilisés étaient des réseaux peu profonds : au maximum deux couches cachées. Ils étaient utilisés parmi la gamme des outils de machine learning mais pour des usages limités du fait de la nécessité de disposer de grandes puissances de calculs. Aussi, d'autres algorithmes, tels les SVM ou les Random Forest, jugés plus performants, leur étaient souvent préférés.

**Mais ça, c'était avant 2012...**

## 1.2. La révolution Deep Learning

### » 1.2.1. | QUAND SOUDAIN LE DEEP LEARNING FUT

En 2012, les résultats spectaculaires obtenus lors d'une compétition d'analyse d'images bouleversent le paysage scientifique.

ILSVRC est une compétition annuelle où des équipes de recherche évaluent leurs algorithmes de traitement d'images sur le jeu de données ImageNet (une des plus grande base mondiale d'images annotées). En 2011, les plus faibles taux d'erreur de classification de la compétition ILSVRC étaient d'environ 25%. En 2012, un algorithme permet de faire baisser ce record à 16% ! Et cet algorithme, **SuperVision**, est basé sur un réseau de neurones « profond ».

Choc pour la communauté scientifique : Yann LeCun, l'un des pères de ces réseaux profonds (cité dans un article du Monde (3) ), évoque cette « révolution » :

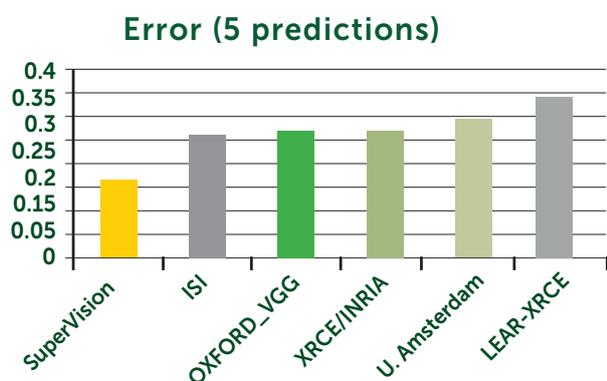


Figure 5 - Comparaison des taux d'erreur à l'issue d'ILSVRC 2012. Source : Tsang, 2018 [51]

« Il a gagné avec un taux d'erreur deux fois moins élevé que les compétiteurs les plus proches. Une révolution. On est passé d'une attitude très sceptique à une situation où tout le monde s'est mis à y travailler en un an et demi. Je n'ai jamais vu une révolution aussi rapide. Même si, de mon point de vue, elle a mis beaucoup de temps à arriver... »

Un réseau profond est un réseau constitué de plusieurs couches cachées, plus que les 1 ou 2 couches que l'on trouvait habituellement dans les réseaux classiques. Sans atteindre les 86 milliards de neurones du cerveau humain, on parle aujourd'hui de réseaux de plusieurs milliers de neurones répartis sur plusieurs dizaines de couches. (Notez cependant qu'il n'y a pas de règle précise en termes de nombre de couches ou de nombres de neurones nécessaires pour mériter l'appellation de Deep Learning...)

**Mais alors, qu'est-ce qui a changé ? Pourquoi d'un seul coup a-t-on pu empiler bien plus de neurones ?**

**En fait, deux facteurs clés peuvent expliquer ce saut de performance (en apparence) soudain :**

- > Les **progrès matériels**, notamment ceux des processeurs graphiques, ou GPU, qui permettent de disposer d'une puissance de calcul bien supérieure à ce qu'elle était jusque dans les années 90.
- > **Internet et la constitution de gigantesques bases de données annotées** (telle ImageNet) permettant de bénéficier de données d'apprentissage supervisé en quantité suffisante pour obtenir des résultats concluants.

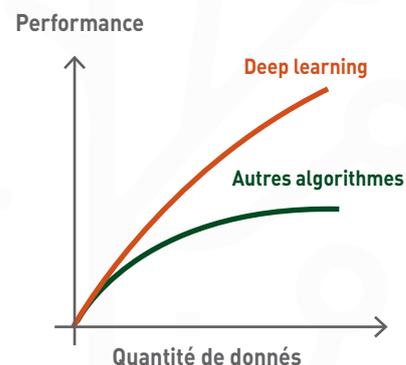
Sans ces deux avancées, il était impossible d'ajouter un nombre suffisant de couches cachées pour obtenir d'excellent résultats, car le temps à consacrer à l'apprentissage devenait rétrograde. Evidemment, **les algorithmes ont également continué à progresser**. On ne peut pas ajouter de plus en plus de couches sans mettre au point de nouvelles techniques : nouvelles architectures, nouveaux types de couches, nouvelles méthodes de calculs... **C'est cet ensemble de nouvelles méthodes (et celles à l'état de recherche) qui, aujourd'hui, constituent le Deep Learning.**

## » 1.2.2. | CE QUE CHANGE LE DEEP LEARNING

Le Deep Learning ouvre de toutes nouvelles perspectives en matière :

### > de performances, par rapport aux algorithmes utilisés jusque-là.

Au moins pour certains types d'usages. Ainsi, depuis la compétition ILSVRC de 2012, la quasi-totalité des travaux de recherche en vision par ordinateur (analyse d'images) utilisent les approches Deep Learning : la création de nouveaux réseaux ou l'amélioration des méthodes ne cessent depuis de faire progresser les performances. L'une des caractéristiques que l'on prête aux algorithmes de Deep Learning est que leurs performances évoluent avec la quantité de données d'apprentissage fournies, contrairement à d'autres algorithmes qui tendent à avoir des performances qui stagnent à partir d'un certain seuil.



### > de méthodes de travail.

Un processus de Machine Learning est complexe, coûteux en temps, notamment pour tout ce qui concerne la préparation des données avant l'entrée dans l'algorithme d'apprentissage.

Dans une démarche d'analyse d'image classique par exemple, une grande partie du travail et du savoir-faire de l'analyste, consiste à extraire les caractéristiques qui vont permettre la reconnaissance avant de les fournir en données d'entrée de l'algorithme d'apprentissage. Par exemple, si l'on cherche à reconnaître une adventice, les méthodes utilisées jusque-là peuvent se baser sur la réflectance, la morphologie, la texture, la hauteur, pris isolément ou combinés [4]. Nous verrons qu'en Deep Learning, cette méthode est grandement simplifiée par **la capacité des réseaux à extraire eux-mêmes ces caractéristiques à partir des données brutes** (ou presque). **On ne dit plus au système ce qu'il doit chercher (par des lignes de code), on lui montre simplement...**

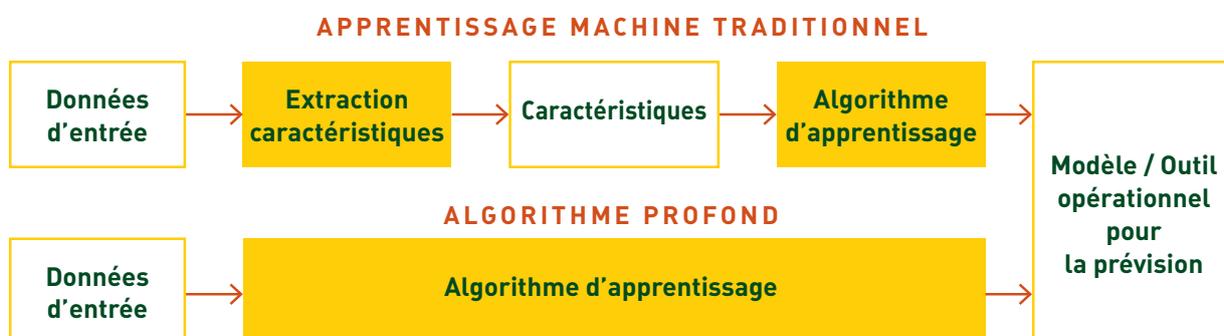


Figure 6  
Comparaison process Deep Learning Vs autres techniques d'apprentissage automatique

Il s'agit là d'une grande plus-value en termes de méthodes de travail car lorsque de nouvelles données ou de nouveaux cas apparaissent, il suffit de procéder à un nouvel apprentissage, sans avoir à revoir l'ensemble du processus.

Par ailleurs, la **forte capacité de généralisation** des réseaux profonds est particulièrement intéressante. Grâce à elle, des réseaux entraînés pour certains types de tâches peuvent être réutilisés pour des tâches similaires, dans un autre contexte. On parle d'apprentissage par transfert. Il est ainsi possible d'assembler des réseaux pré-entraînés et/ou de ne changer que les dernières couches pour l'adaptation au cas spécifique (on parle de réglage fin ou fine tuning).

**Pour toutes ces raisons, l'apprentissage profond concerne aujourd'hui tous les secteurs : l'industrie, la médecine, l'enseignement et bien sûr... l'agriculture.**

### » 1.2.3. | ENJEUX ET OPPORTUNITÉS POUR L'AGRICULTURE

L'Agriculture fait face à de grands enjeux :

- > **Produire en quantité**, pour nourrir une population mondiale en croissance : de 7,5 milliards en 2017, elle devrait passer à 9,8 milliards en 2050 (5) ce qui va impliquer de produire plus et/ou de modifier les régimes et modes de consommation ;
- > **Produire de la qualité**, avec une vigilance accrue en matière de santé publique,
- > **Produire de façon durable** avec des objectifs renforcés en termes de compétitivité économique, sociale et de réduction de l'impact environnemental (notamment en France, où une politique volontariste pour le développement de l'agro-écologie est engagée).
- > **Il est donc nécessaire de trouver des solutions pour produire plus et mieux en consommant moins d'intrants.**

Or l'Agriculture doit composer avec de nombreuses contraintes dont les changements climatiques, la modification des écosystèmes... Par définition, **l'Agriculture s'appuie sur le vivant**, des plantes ou des animaux, c'est-à-dire des organismes qui évoluent et dont l'évolution repose sur des interactions complexes avec l'environnement (climat, sol, pathogènes,...).

Pour ces raisons, les agronomes et agriculteurs cherchent à disposer de méthodes et outils permettant de **surveiller au plus près les facteurs de production et d'en prédire les évolutions** pour adapter, si besoin, les itinéraires culturaux et les modes de conduite des élevages.

Jusqu'ici deux grands types de modèles étaient utilisables :

#### 1) Des modèles mécanistes



Basés sur une connaissance très pointue de la physiologie et de l'écologie des espèces, ils permettent de prévoir de façon très robuste l'évolution des individus en fonction des paramètres de leur environnement. Mais ces modèles nécessitent souvent des données d'entrée très précises, parfois difficiles à obtenir en routine sur les exploitations du fait du temps ou de l'équipement nécessaire au recueil (voire de la méthode de mesure, parfois destructive),

#### 2) Des modèles statistiques



Basés sur des observations pour lesquelles on cherche à trouver une relation mathématique entre des variables d'entrée (par exemple des variables environnementales) et une variable d'intérêt (par exemple un taux de croissance). Ces modèles ne nécessitent pas de connaissances pointues d'écophysiologie mais exigent de disposer de suffisamment d'observations pour être précis et robustes dans différentes conditions

> **Le Deep Learning offre aujourd'hui une troisième possibilité, dans le prolongement des modèles statistiques, en permettant de traiter des problèmes complexes, tels ceux liant une plante à son environnement, sans nécessiter de connaître ou de comprendre les mécanismes mis en jeu, ni même de décrire une relation mathématique.**

**Les « modèles » Deep Learning reposent sur les données et sur leur nombre.** Or, les nouvelles technologies numériques, notamment le développement des usages du smartphone, de l'internet des objets, de la télé et proxidtection, permettent aujourd'hui d'espérer disposer de la masse critique de données et de la puissance de calcul nécessaires à leur mise en œuvre.

Par ailleurs, **l'Agriculture se construit et se raisonne sur de multiples échelles** : la parcelle, l'exploitation, le pays, le monde... Aujourd'hui, l'agriculteur et l'ensemble de ses prescripteurs ne peuvent raisonner seuls leurs prises de décision. Ils ont besoin de connaître les tendances locales et internationales qui vont influencer sur les marchés, les prix des denrées, la relation avec les consommateurs, etc.

> Parce qu'il permet d'intégrer de données massives et de sources hétérogènes, le Deep Learning peut proposer des solutions pour mieux anticiper ces tendances et aider les agriculteurs à prendre ses décisions.

Enfin, **l'Agriculture est spécifique par la diversité et la difficulté des tâches à accomplir**. L'agriculture est un domaine qui réclame une grande quantité de main d'œuvre, pour des tâches à la fois pénibles ou répétitives mais qualifiées : il n'est pas si simple de savoir identifier un fruit sous le feuillage, d'identifier un fruit parmi d'autres fruits, de savoir comment accéder au fruit, de le recueillir...

> Parce qu'ils permettent d'appréhender une diversité de situations, pour une meilleure perception de l'environnement, l'Intelligence artificielle et le Deep Learning en particulier, peuvent venir renforcer d'autres innovations, notamment robotiques.

## On retient :

- L'intelligence artificielle est un vaste domaine. Le Machine Learning en est l'une des branches. Le Deep Learning est un sous-ensemble du Machine Learning.
- Le Machine Learning correspond aux méthodes qui permettent de faire apprendre à une machine une « chaîne de traitements » ou « un modèle » permettant de résoudre un problème identifié nécessitant, par exemple, de réaliser une classification ou de distinguer des sous-groupes au sein d'une population.
- Une machine peut apprendre de différentes façons. La plus commune est de lui proposer un jeu d'entraînement pour lequel on connaît les données d'entrée et les résultats attendus. La machine apprend en cherchant à améliorer les résultats obtenus par rapport à ceux attendus.
- Le Deep Learning est basé sur l'utilisation de réseaux de neurones profonds, c'est-à-dire organisés en de multiples couches, inspirés du fonctionnement du cerveau humain ou animal et de sa capacité à décomposer un problème en différents niveaux d'abstraction. Les réseaux de neurones ne sont pas un concept récent mais les formidables progrès matériels et l'accès à de gigantesques sources de données ont considérablement accru leurs performances.
- Le Deep Learning constitue une nouvelle classe d'outils et de méthodes qui élargissent aujourd'hui le champ des possibles en matière d'intelligence artificielle, par les gains de performances et les nouveaux usages qu'il permet.
- Pour l'Agriculture, il ouvre de nouvelles possibilités pour répondre aux questions de suivi et de prévision posées par le travail avec le vivant, à différents échelles et pour des opérations difficilement automatisables jusque-là.

## 1.3. Des réseaux de neurones au Deep Learning

Il nous apparaît maintenant important d'aller un cran plus loin dans la compréhension des mécanismes de réseaux de neurones et des processus d'apprentissage afin de mieux appréhender ce qu'ils permettent mais aussi leurs limites.

### » 1.3.1. | UN EXEMPLE

Pour mieux comprendre, prenons un cas simple (ou simplifié) de prévision météorologique : on souhaite pouvoir prédire la météo à partir de différentes variables telles que la Température, la Pression atmosphérique, l'Hygrométrie, la Vitesse du Vent. Le résultat attendu variera entre 1 pour « beau temps » et 0 pour « mauvais temps ». Intuitivement, on aurait tendance à se dire que tous les paramètres n'ont pas la même importance sur le résultat : que selon le niveau de température, par rapport à une certaine vitesse du vent et un certain niveau d'humidité, on ne donnera pas le même qualificatif à la météo du jour... **Et bien c'est ce à quoi peut servir un réseau de neurones : il va permettre de « modéliser » l'importance (le poids) des différentes variables pour la prédiction attendue.** Pour cela, il va progressivement décomposer le problème en combinaisons très simples dans les premières couches, puis de plus en plus complexes à mesure que l'on progressera en profondeur dans le réseau. **L'apprentissage**, par exemple supervisé à partir de données météo passées, **consistera à trouver les poids les plus adaptés pour effectuer une prévision fiable.**

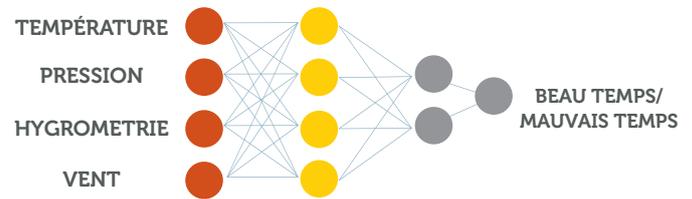


Figure 7  
Comprendre les réseaux de neurones

### » 1.3.2. | AU COMMENCEMENT ÉTAIT LE NEURONE SIMPLE OU NEURONE FORMEL

Comme nous l'avons dit précédemment, le neurone artificiel est inspiré du fonctionnement du neurone biologique.

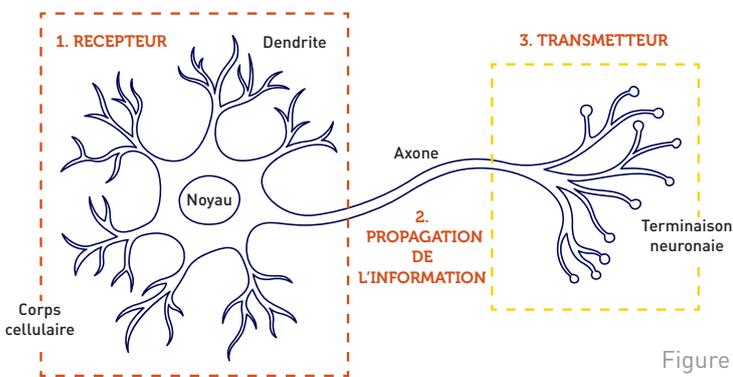


Figure 8  
Schéma d'un neurone biologique

Le neurone biologique est une **cellule excitable**. Il reçoit et traite en permanence des informations en provenance des dendrites, des stimuli qui vont agir sur la répartition des ions de part et d'autre de sa membrane. **Lorsque la somme de ces courants électriques atteint un certain seuil**, l'équilibre électrochimique est modifié localement et un influx nerveux (un courant électrique) est déclenché, se propage le long de l'axone puis atteint les neurones voisins reliés par les synapses. On parle de **potentiel d'activation**.

C'est de ce mécanisme dont est inspiré le neurone artificiel, ou **neurone formel**, modélisé initialement par Warren McCulloch et Walter Pitts en 1943. Dans sa forme la plus simple, il peut se représenter de la façon suivante :

Les valeurs ( $x_i$ ) sont les données d'entrée (les variables que l'on souhaite prendre en compte). On peut les comparer aux messages transmis par les liaisons entre les neurones (dendrites). Ces messages arrivent au neurone de manière pondérée c'est-à-dire que, pour traduire leur importance pour la résolution du problème, un poids ( $w_i$ ) leur est attribué (on parle de « poids synaptique »).

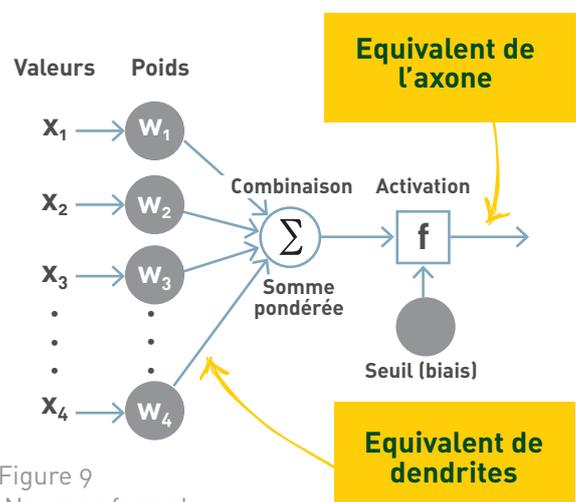


Figure 9  
Neurone formel

Le neurone combine d'abord ces informations en faisant la somme pondérée de tous les messages ( $z = \sum w_i x_i$ ). Puis, une fonction mathématique  $f$ , basée sur cette somme pondérée, permet l'**activation** du neurone c'est-à-dire la production d'un message  $Y$  en sortie.

La **fonction d'activation** s'apparente au potentiel d'activation du neurone biologique. Il peut par exemple s'agir d'une fonction de seuil qui renvoie 1 si un seuil ( $w_0$ ) est atteint et 0 si le seuil n'est pas atteint.  $Y = f(z) = f(\sum w_i x_i + w_0)$

**Comme le neurone biologique, le neurone formel permet donc de « transformer » de multiples variables d'entrée en un résultat  $Y$  unique en sortie.**

### » 1.3.3. | PUIS ON AJOUTA DES COUCHES...

Si l'on s'en tient à ce neurone formel (type « Perceptron »), on ne peut traiter que des cas simples, linéaires, comme par exemple répartir un ensemble d'individus parmi deux classes en traçant une simple ligne droite de séparation.

**Or dans le monde réel, la plupart des cas à traiter sont non linéairement séparables !**

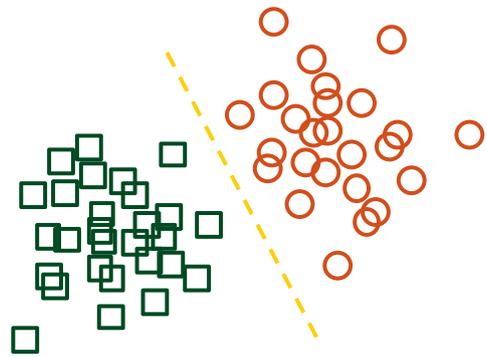


Figure 10 - Problème où la séparation linéaire est possible

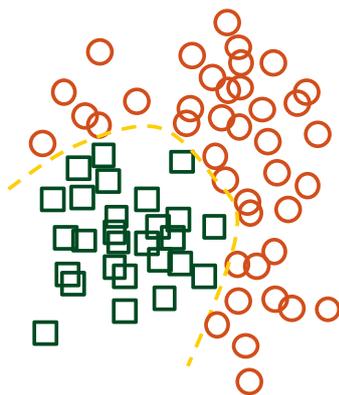


Figure 11  
Problème non linéairement séparable

**Il fallait donc trouver le moyen de traiter des problèmes beaucoup plus complexes en termes de modélisation, « non linéairement séparables ».** L'idée a donc germé de pouvoir décomposer ce type de problèmes en sous problèmes élémentaires permettant de changer d'espace de représentation et de revenir sur des problèmes linéairement séparables ou plus facilement traitables par des fonctions non linéaires élémentaires.

#### > C'est ce que permettent les réseaux de neurones multicouches.

On peut voir les réseaux à plusieurs couches comme des empilements de neurones formels. Pour mieux comprendre les réseaux de neurones multicouches prenons d'ailleurs l'exemple des Perceptrons multicouches (Multi Layer Perceptron ou MLP), qui sont en fait une combinaison de perceptrons simples.

Dans le cas des MLP, l'information circule vers l'avant c'est-à-dire de la couche d'entrée vers la couche de sortie (on parle de réseaux à propagation avant ou « feed-forward » en anglais) et toutes les couches sont complètement connectées : chaque neurone de la couche  $C+1$  est relié à chaque neurone de la couche  $C$ .

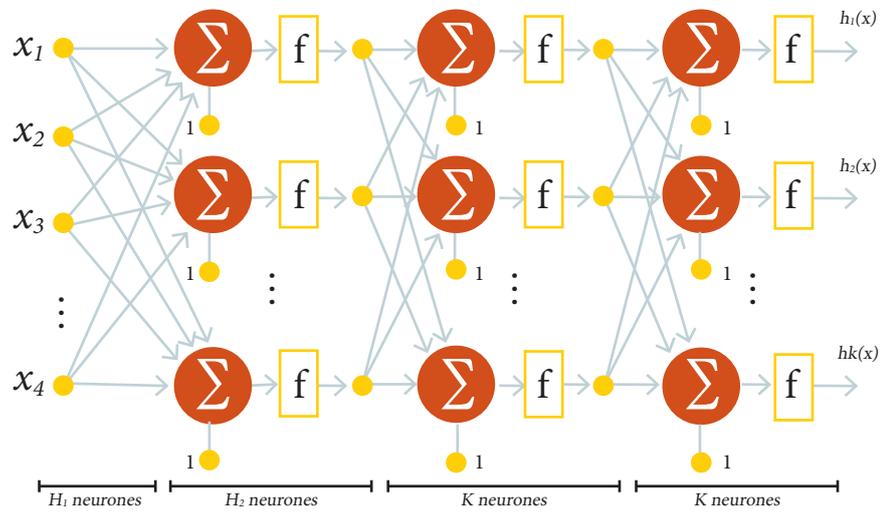


Figure 12  
Perceptron multicouche  
Source : Gagné Christian (6)

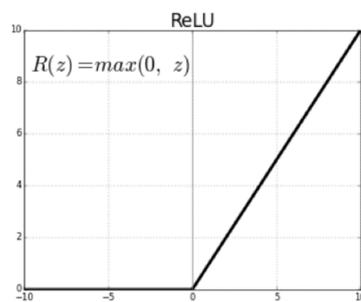
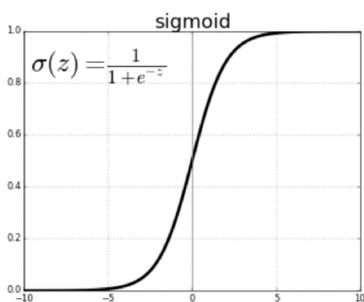
Cet assemblage de plusieurs neurones formels permet de résoudre des problèmes plus complexes car chaque neurone est capable de réaliser un traitement élémentaire :

### 1) une combinaison linéaire : la somme pondérée des entrées.

Chaque sortie d'un neurone de la couche C devient une entrée pour chaque neurone de la couche C+1, entrée associée à un poids synaptique. Le poids de chacune de ces liaisons est l'élément clef du fonctionnement du réseau. **Tout le travail d'apprentissage va consister à trouver les meilleurs poids à appliquer pour obtenir le résultat le plus proche de ce que l'on souhaite.**

### 2) une transformation (éventuellement) non linéaire via la fonction d'activation.

On va, pour certains cas où une « non linéarité » est recherchée, pouvoir utiliser ici des fonctions non linéaires élémentaires. Ces fonctions non linéaires permettent de transmettre des résultats plus nuancés que 0 ou 1 en sortie de neurone et ainsi d'agir plus finement sur le réseau : un petit changement des poids entrainera un petit changement sur le résultat de sortie du neurone (7). **Cette capacité à pouvoir suivre de petites différences de comportement est un point crucial pour l'apprentissage.**



Citons par exemple la fonction tangente hyperbolique ( $\tanh$ ), qui passe graduellement d'une valeur  $-1$  à une valeur  $1$ , la fonction sigmoïde qui permet d'obtenir en sortie n'importe quelle valeur entre  $0$  et  $1$ , ou la fonction ReLU (Unité de Rectification Linéaire) qui permet d'obtenir des valeurs de  $0$  à l'infini.

L'utilisation de ces fonctions d'activation a progressé au fil des évolutions des réseaux. C'est la fonction d'activation qui qualifie le type du neurone. Selon les besoins, le type de comportement recherché, le « data scientist » pourra choisir différentes fonctions d'activation pour les différentes couches du réseau.

> L'apprentissage pour ce type de réseaux multicouches consiste à optimiser conjointement tous les paramètres du réseau, c'est-à-dire à trouver les bons poids synaptiques, pour minimiser l'erreur de prédiction entre les résultats obtenus et les résultats attendus.

Pour cela, on utilise des algorithmes d'optimisation consistant à apporter des améliorations successives permettant d'aller dans le sens de la réduction de l'erreur (méthodes de **descente de gradient**) en partant de la couche de sortie et en revenant vers la couche d'entrée (méthode de **rétropropagation**). Sans entrer dans les détails, cela consiste à répéter les étapes suivantes :

1. Initialisation : on donne des poids aléatoires au réseau
2. Présentation d'un échantillon d'entraînement
3. Calcul de l'erreur globale en sortie de réseau
4. Calcul de l'erreur individuelle de chaque neurone (erreur locale).
5. Ajustement du poids de chaque connexion vers l'erreur locale la plus faible (couches cachées)
6. Ajustement des poids de la couche d'entrée
7. Recommencer à l'étape 2

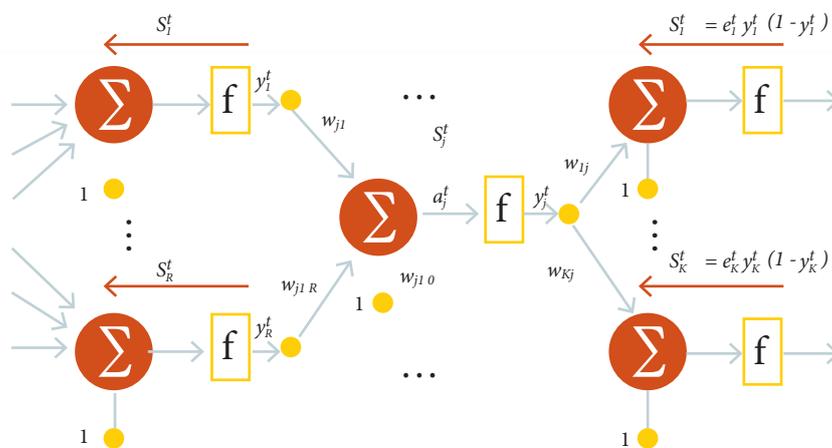


Figure 13  
Rétropropagation - Source : Gagné Christian (6)

**Ce processus d'optimisation des poids se fait donc au prix de multiples itérations.** Cela consomme beaucoup de ressources machine et la machine peut se « perdre » en route en ne parvenant plus à réduire l'erreur (problème de perte de gradient).

Si l'on augmente le nombre de couches ou le nombre de neurones par couche pour traiter des cas plus complexes, comme c'est le cas en Deep Learning, l'algorithme d'apprentissage a besoin de plus en plus d'itérations pour converger vers un résultat. Or, plus d'itérations, cela veut dire à la fois plus de puissance de calcul et plus d'échantillons d'apprentissage mobilisés...

Cela peut également induire **un risque de surapprentissage** (ou overfitting en anglais). A force d'itérations, la machine va finalement connaître son jeu de données « par cœur ». Elle saura obtenir un résultat parfait sur ce jeu mais ne saura pas généraliser sur un jeu de données nouvelles.

> Le choix de l'architecture du réseau est donc primordial. Le nombre de couches cachées, qui permet de traiter des problèmes de non-linéarité, et le nombre de neurones par couche cachée ont un impact direct sur le nombre de paramètres (de poids) à estimer et donc la complexité du modèle. Un compromis doit être trouvé entre la qualité du résultat attendu et la difficulté d'apprentissage. Par ailleurs, des paramètres tels que le nombre maximum d'itérations ou l'erreur maximum tolérée sont également à considérer.(8), (9)

### » 1.3.4. | AUJOURD'HUI, 3 GRANDES FAMILLES DE RÉSEAUX PROFONDS

Comme nous le disions précédemment, pour résoudre des problèmes de plus en plus complexes, il ne suffit pas simplement d'ajouter toujours plus de couches de neurones car la difficulté d'apprentissage et la complexité calculatoire croissante avec le nombre de couches restent des problématiques très présentes malgré les progrès matériels. Il est donc nécessaire de proposer des approches différentes suivant les problèmes à résoudre : nouveaux neurones (via l'utilisation de fonctions d'activation différentes), nouvelles façon de connecter les couches entre elles (sans que toutes les couches soient totalement connectées par exemple...), de connecter et entraîner les réseaux entre eux, nouvelles stratégies d'optimisation des poids...

Aujourd'hui, on distingue plusieurs grandes familles de réseaux profonds permettant de résoudre différents types de problèmes.

Citons en particulier :

> **Les réseaux de neurones convolutifs (Convolutional Neural Networks, ConvNets ou CNN).**

Les réseaux qui ont permis d'atteindre les résultats spectaculaires de 2012 sont issus de cette famille. Proposés par Yann LeCun dès les années 90, ils sont inspirés des processus biologiques du cortex visuel des animaux et permettent de transformer un problème global de reconnaissance en une succession d'étapes plus faciles à résoudre.

Ainsi, l'architecture des CNN comprend :

- une alternance de couches de traitement (couches de *convolution*, d'activation et de simplification ou *pooling*) qui permettent d'extraire des caractéristiques,
- puis des couches semblables à celle d'un MLP classique (couches Fully Connected) qui, après mise à plat (*flattening*) des « cartes » issues de l'extraction de caractéristiques, effectuent la classification finale.

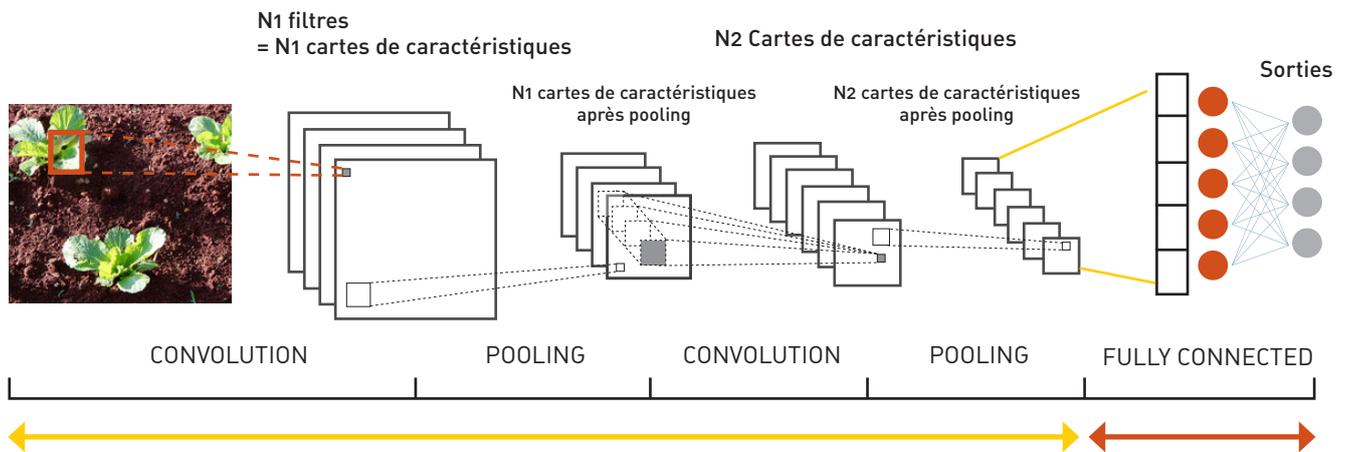


Figure 14  
Architecture (simplifiée) des réseaux convolutifs

Comme les MLP, ces réseaux ont un fonctionnement par propagation vers l'avant. Mais à la différence des MLP, toutes les couches ne sont pas entièrement connectées. Ainsi, au premier niveau de couches, ce que l'on observe est une combinaison de pixels sur un petit voisinage. Au deuxième niveau, c'est une combinaison des combinaisons issues du niveau précédent et ainsi de suite. Les premiers niveaux permettent d'extraire des constituants élémentaires (des petites portions de contours, des points, des zones homogènes...) et plus on progresse vers les couches profondes, plus on obtient des combinaisons complexes donc de plus en plus abstraites.

La convolution consiste à faire glisser des filtres sur les images pour faire ressortir de façon marquée certaines caractéristiques (1 filtre = 1 type de caractéristique). **Un filtre est en fait une matrice de poids.** C'est l'opérateur qui choisit l'architecture du réseau (nombre et taille des filtres...) mais c'est la machine qui, par l'apprentissage, va découvrir les bons poids à appliquer et ainsi construire ses filtres sur mesure.

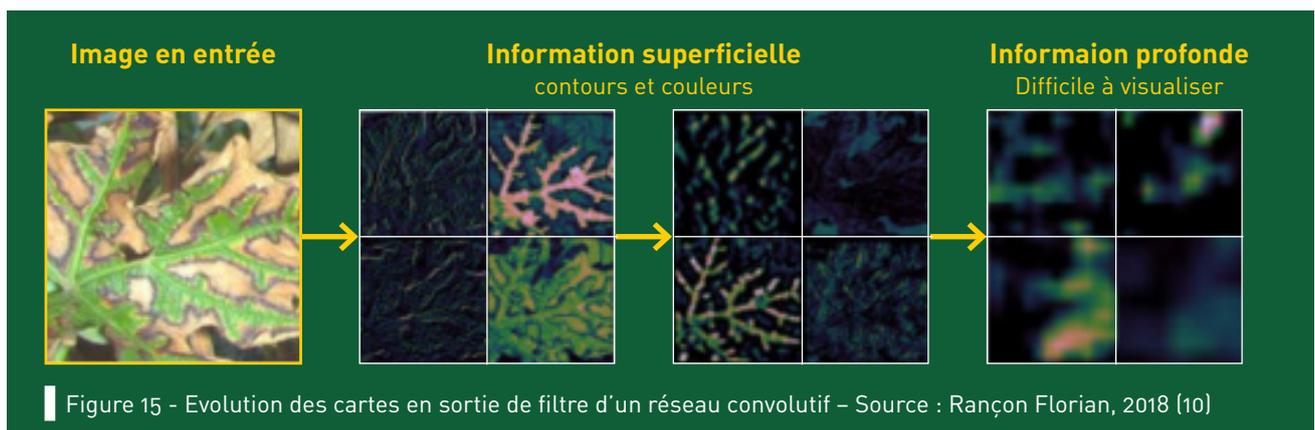


Figure 15 - Evolution des cartes en sortie de filtre d'un réseau convolutif – Source : Rançon Florian, 2018 (10)

De par leur nature, ces réseaux sont principalement utilisés en analyse d'images mais leur utilisation se diversifie sur bien d'autres cas dès lors qu'il est possible d'extraire des sous éléments comme on extrait des pixels d'une image. Par exemple, un signal audio peut être décomposé en un ensemble de petits morceaux plus courts et chacun de ces morceaux peut être décomposé en différentes bandes de fréquence.



**Pour en savoir plus sur ce sujet :**  
voir la série de conférences données par Yann LeCun au Collège de France : (11)

## RNN

### > Les réseaux neuronaux récurrents (RNR ou Recurrent Neural Networks, RNN, en anglais).

Un réseau de neurones récurrent peut être considéré comme plusieurs copies du même réseau, chacune transmettant un message à son successeur.

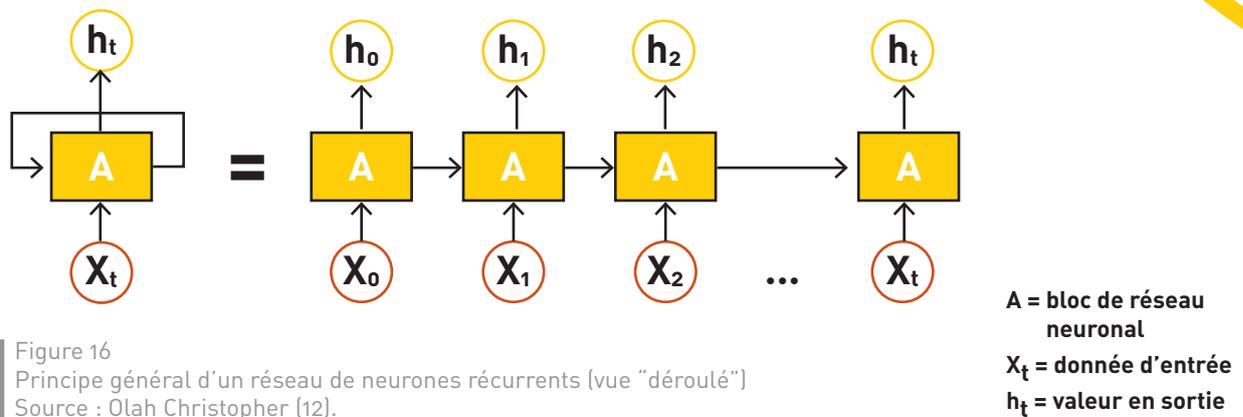


Figure 16  
Principe général d'un réseau de neurones récurrents (vue "déroulé")  
Source : Olah Christopher (12).

Ils peuvent intervenir lorsqu'une dimension temporelle ou le traitement de séquences est à prendre en compte. En effet, en intégrant au moins une boucle dans la structure du réseau, ils permettent aux informations de persister et visent ainsi à traduire l'une des propriétés de l'intelligence : la capacité à se remémorer le passé pour mieux prédire et planifier.

Les RNN sont par exemple utilisés pour l'analyse du langage naturel : pour la traduction, la production de légendes pour les images, les systèmes de dialogues. Nous verrons également que des travaux de recherche en cours visent à les exploiter pour le traitement de séries temporelles d'images en vue prédire les types de cultures par exemple.

**EXEMPLE :** si l'on veut prédire le dernier mot du texte « J'ai grandi en France... je parle couramment le français ». Des informations récentes suggèrent que le mot suivant est probablement le nom d'une langue, mais si nous voulons préciser quelle langue, nous avons besoin du contexte (la France) et il faut donc remonter plusieurs étapes en arrière.

Les RNN traditionnels permettent de se remémorer des informations court terme c'est-à-dire acquises lors du cycle précédent. Des versions plus sophistiquées de ces réseaux, tels les réseaux de neurones récurrents à mémoire long terme et court terme ou LSTM (Long Short Term Memory) ou encore les GRU (Gated Recurrent Unit), sont capables d'apprendre des dépendances à long terme. Ils constituent un axe de recherche prioritaire car ils permettent de prendre en compte des notions de contexte pour affiner une prédiction.



### A lire pour mieux comprendre fonctionnement de ces réseaux :

- 1) Comment les Réseaux de neurones récurrents et Long Short-Term Memory fonctionnent, de Charles Crouspeyre (Octobre 2017) (13),
- 2) Understanding LSTM Networks de Christopher Olah (Août 2017) (12),
- 3) The Unreasonable Effectiveness of Recurrent Neural Networks de Andrej Karpathy (Mai 2015) (14).

A chaque nouvelle entrée, le système met à jour l'état d'une mémoire à court terme et d'une mémoire à long terme à partir des nouvelles observations et de l'état de la mémoire à court terme de la date antérieure. Des portes (ou gates) permettent d'oublier certaines informations qui ne sont plus jugées pertinentes (elles sont alors enlevées de la mémoire à long terme), de sélectionner l'information pertinente à ajouter dans la mémoire à long terme ou de sélectionner l'information à transmettre à la date suivante. On peut ainsi pour chaque date si on le souhaite proposer des probabilités d'appartenance aux classes attendues en sortie.

### > Les réseaux antagonistes génératifs (en anglais Generative Adversarial Networks ou GANs).



Il s'agit d'algorithmes d'apprentissage non-supervisé. Ils reposent sur l'association de 2 réseaux de neurones en compétition. L'un, dit le générateur, a pour but de créer des données similaires aux échantillons de données réelles. L'autre, le discriminateur (« adversaire »), reçoit à la fois des données réelles et des « fausses » données créées par le générateur. Sa tâche est d'identifier quels échantillons sont réels et quels sont ceux qui sont faux. Les 2 réseaux apprennent par feedback : le générateur est informé des données qui ont été reconnues comme fausses, le discriminateur des données qu'il a considérées vraies alors qu'elles étaient fausses (et vice-versa). Ces réseaux sont ceux qui sont utilisés pour créer de belles images extraordinaires. Mais au-delà de cet usage qui pourrait sembler gadget, ces réseaux sont aujourd'hui utilisés dans des processus de « débruitage » d'images, de détection et de cartographie d'anomalies, dans les domaines industriel et médical notamment. En effet, pour créer des échantillons réalistes ou pour distinguer les vrais des faux, les 2 réseaux doivent bien « comprendre » les échantillons de l'ensemble de données, vraies et fausses, en en dégagant les caractéristiques. En se renforçant l'un l'autre, ces réseaux peuvent fonctionner avec moins de données d'apprentissage que d'autres.

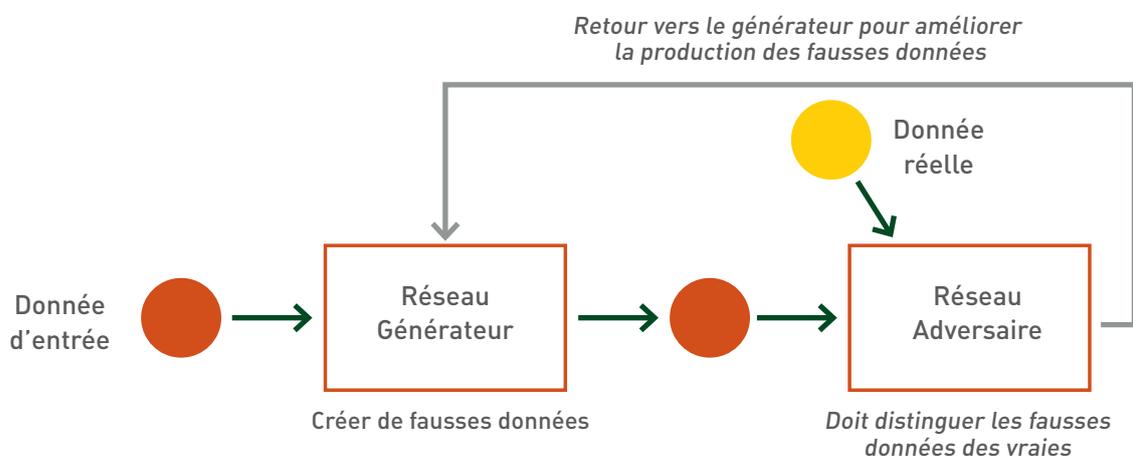


Figure 17

Principe d'un réseau GAN - Source : d'après <http://www.aplus.ai/download/deeplearning-guide.pdf>



### » 1.3.5. | UN ÉCOSYSTÈME EN DÉVELOPPEMENT SUR UN SOCLE OPENSOURCE

Le développement rapide du Deep Learning est favorisé par le fait que **l'écosystème**, au départ initié par le monde la recherche, est majoritairement **open source**. Il est ainsi « relativement » simple pour quelqu'un ayant des connaissances de base en informatique et/ou mathématique de faire fonctionner des réseaux de neurones en s'appuyant sur des frameworks en accès libre, des infrastructures de développement permettant aux développeurs d'accéder facilement à des bibliothèques d'algorithmes pré-établis. La plupart des géants du numérique (Google, Facebook, Amazon...) ont aujourd'hui passé leurs frameworks en open source. Parmi les frameworks les plus utilisés, citons **Tensor-Flow** (Google), **Caffe**, **Caffe2**, **Theano**, **Torch**, **MXNet**, **Keras**, **H2O**... Ces frameworks sont très documentés et nourris en continu par une grande communauté de contributeurs. Ils sont en général compatibles avec plusieurs langages informatiques (Python, C++, R, ...)

L'intérêt pour les grandes firmes est d'inviter ensuite les développeurs et data scientists à rejoindre leurs services payants, notamment toutes les plateformes (Azure ML de Microsoft, Google ML, Facebook fb Learner,...) et les services hébergés dans le Cloud.

En parallèle de ces fournisseurs d'infrastructures et de services Deep Learning, se développent également rapidement les fournisseurs de « Hardware », notamment ceux qui permettent d'exécuter les calculs pour l'apprentissage (GPU de NVIDIA, AMD, Intel, Google...).

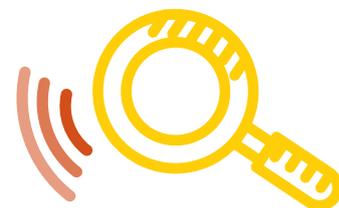
#### On retient :



- L'organisation en différentes couches de neurones élémentaires permet de décomposer des problèmes complexes en sous-problèmes plus simples; chaque couche prend en entrée la sortie de la précédente et permet de progresser dans la résolution.
- L'apprentissage automatique consiste à faire trouver au système les bons poids à appliquer aux liaisons entre couches pour se rapprocher d'un résultat attendu à partir de données d'entrée.
- Plus les réseaux sont profonds, plus le nombre d'itérations nécessaires à l'apprentissage augmente, impliquant la nécessité de disposer d'un jeu de données d'apprentissage conséquent.
- La complexité de l'apprentissage et la puissance de calcul qu'il nécessite exigent d'étudier avec soin les choix architecturaux pour apporter une réponse adaptée au problème posé, avec un équilibre entre la qualité de résultat attendue et l'effort d'apprentissage à produire.
- Le Deep Learning propose aujourd'hui de nouvelles architectures et de nouvelles méthodes apportant des réponses à différents types de problèmes : analyse de signaux (sonores, visuels...), traitement et génération du langage, génération de représentations complexes...
- Le Deep Learning correspond aujourd'hui à un écosystème qui évolue en continu sous l'impulsion de la recherche et d'une grande communauté open source.

# PARTIE 2 :

## QUE PEUT LE DEEP LEARNING POUR L'AGRICULTURE ?



L'Intelligence artificielle est déjà une réalité en agriculture. D'après **Research and Markets** (15), le marché de l'IA en agriculture était évalué à près de 518,7 millions en 2017 et devrait se développer de plus de 22,5% par an pour atteindre 2.6 milliards d'ici 2025. En particulier, l'utilisation croissante des technologies de vision par ordinateur pour les applications agricoles et la demande croissante de surveillance continue et d'analyse de la santé des cultures contribuent à la progression du marché des solutions d'IA basées sur la technologie de vision par ordinateur.

### 2.1. Deep Learning et agriculture : un axe de recherche actif

Les réseaux de neurones (profonds ou non) pour des cas agricoles sont explorés/utilisés de façon importante par les chercheurs. Le graphique ci-contre, issu de l'étude (16) montre la part des réseaux de neurones par rapport aux autres algorithmes utilisés pour des cas agricoles.

**Pour une grande part, il s'agit de travaux basés sur la vision : l'analyse d'images.** Deux familles de réseaux sont largement utilisées : les réseaux convolutifs, dans une très large majorité, et les réseaux récurrents, en augmentation. Les Réseaux de type GAN, plus récents, ne sont utilisés que marginalement, pour débruiter des images par exemple (17).

Notons enfin également que les articles scientifiques peuvent évoquer des usages agricoles au titre de simples cadres d'utilisation (transposables à d'autres domaines) pour l'optimisation d'architectures de réseaux ou de méthodes (par exemple utilisation d'autres algorithmes pour pré-entraîner les réseaux de façon non supervisée (18)).

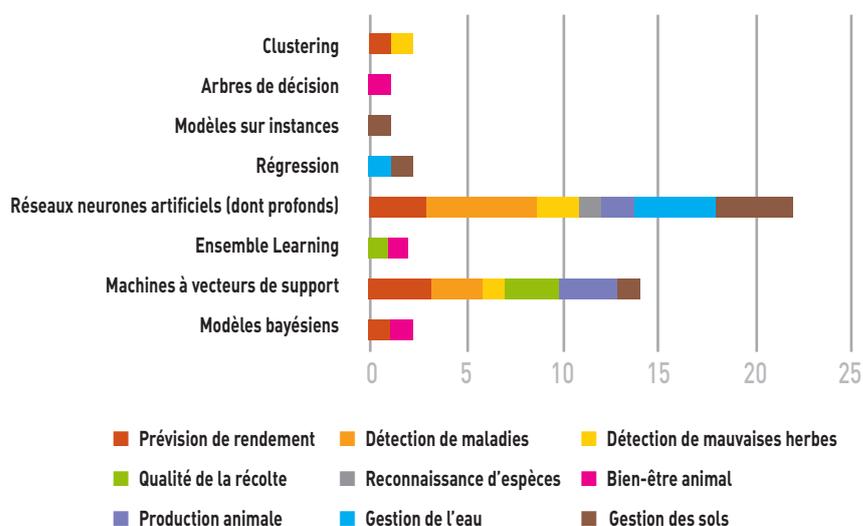


Figure 18 - Nombre de modèles de machine learning pour des usages agricoles d'après étude couvrant une période de 2004 à nos jours - Source : Liakos et al. (16)

### 2.2. De la recherche aux premières propositions commerciales : des exemples d'applications dans le secteur agricole

Pour établir ce panorama, nous nous sommes basés sur différents articles scientifiques analysant les travaux de recherche traitant du Machine Learning et/ou du Deep Learning pour l'agriculture (16) (17) (19) et sur une veille et des recherches bibliographiques sur les mots clés « Intelligence artificielle » + « agriculture », « Deep Learning » + « agriculture » / « yield prediction » / « crop » / « cattle » / « livestock » / « fish » (et termes français équivalents). Des entretiens et échanges par courriel, au fil des opportunités, avec des représentants de différentes entreprises fournisseurs de produits et services basés sur des technologies Deep Learning ont permis ensuite de compléter qualitativement cette première approche.

En conséquence, ce panorama ne vise qu'à donner un aperçu des applications possibles et des travaux de recherche et de R&D en cours. Il n'a aucun caractère d'exhaustivité en termes de solutions et d'organismes de recherche ou entreprises citées. Nous nous attarderons plus longuement sur les applications végétales, domaine probablement investi plus récemment par la recherche. Notons le caractère récent de l'ensemble des travaux (dans (19), la plupart des articles datent d'après 2015 et sur 37 articles : 28 concernent les cultures ou la détection des mauvaises herbes et seulement 3 l'élevage).



## » 2.2.1. | EN PRODUCTIONS ANIMALES

### Le Deep Learning est exploré en élevage pour :

- L'Identification animale (et le comptage des animaux en liberté)
- La Prédiction de comportements animaux
- Le Contrôle des paramètres d'élevage (milieu, nourriture...)



### Les enjeux

- > **Environnementaux et économiques** : anticiper et adapter au plus juste les approvisionnements et les ressources humaines, éviter les pertes de cheptel...
- > **Sociaux** : faciliter le travail des éleveurs.
- > **Sanitaires** : garantir la santé animale et humaine.

### C'est compliqué parce que...

- > **Les animaux bougent ! Ils sont (le plus souvent) élevés en groupes.**
- > **De multiples facteurs interconnectés peuvent agir sur les animaux (facteurs environnementaux, maladies, alimentation...) : les données utilisées doivent permettre de décrire les problèmes ciblés dans toute leur complexité...**

A la différence des productions végétales concentrant l'effort sur l'utilisation de la « vision », les sources de données exploitables pour l'utilisation des réseaux de neurones profonds en élevage sont plus diversifiées.



#### DES EXEMPLES :

Dès 2010, une équipe de chercheurs anglais utilisait un réseau de neurones récurrent pour décrire la croissance variable dans le temps des poulets de chair. Le modèle a été entraîné à partir de données générées sur un lot de poulets exposés à des changements soudains de quantité d'alimentation, intensité lumineuse, température et humidité relative. Les résultats préliminaires montraient que le modèle pouvait prédire avec précision la quantité d'aliment nécessaire pour suivre des courbes de croissance prédéterminées, calculer un taux de croissance compensatoire après des jours de retard de croissance et prédire la consommation totale de nourriture pour toute la période de croissance.

Des expérimentations similaires ont également été menées en élevage porcin, également avec succès [21].

Les sons produits par les animaux constituent également une piste explorée. Les chercheurs essaient d'identifier des « modèles » dans les sons émis par les animaux qui pourraient renseigner sur leur état de santé. Différents travaux dont ceux d'une équipe de **The University of Georgia**

**and Georgia Institute of Technology** entre 2014 et 2016 ont consisté à enregistrer les sons produits par les poulets, notamment leurs vocalises, en réponse à des situations stressantes - telles que des températures élevées, des niveaux élevés d'ammoniac dans l'air et des infections virales légères [20]. Les résultats montrent qu'il est au moins possible de détecter les états de stress mais des difficultés demeurent : en effet, dans les élevages industriels, les niveaux de bruit de fond sont élevés, du fait des appareils de chauffage et de ventilation. Il est donc difficile de détecter de légères variations dans les sons émis par les poulets et il faut entraîner les algorithmes à se concentrer sur leurs vocalises.

Le Deep Learning est également utilisé pour l'identification animale : que ce soit pour le comptage des animaux (par exemple par utilisation de vidéos acquises par drone pour le comptage de bovins en pâturage libre [22]) ou l'identification précise d'individus. Citons par exemple, l'expérience menée par une équipe de chercheurs indiens pour identifier les bovins de façon individuelle à partir d'images de museaux en vue de traiter le problème des animaux perdus ou échangés et des fraudes aux assurances [23].

••• Aujourd'hui, les applications concrètes arrivent dans les élevages un peu partout dans le monde. Ainsi, en Chine, **Alibaba Cloud**, la filiale du géant chinois du e-commerce, a lancé une opération **ET Agricultural Brain** destinée à proposer un ensemble de services basés sur l'intelligence artificielle. Déjà implanté dans plusieurs élevages de porcs du pays, le programme prévoit d'utiliser différentes technologies : la reconnaissance d'images (pour le suivi des numéros d'identification tatoués sur le corps des animaux), la reconnaissance vocale (pour lutter contre la mortalité des porcelets écrasés par leur mère en détectant leurs cris ou pour surveiller la toux des animaux) et l'utilisation de données de capteurs (capteurs infrarouges pour surveiller la température corporelle des porcs et pouvoir croiser ces données avec leurs déplacements quotidiens en vue d'estimer leur état de santé) (24), (25). En France, **l'Ifip**, l'Institut technique de Recherche et de Développement de la filière porcine, suit également de près ces nouvelles technologies (26).

••• Aux Etats-Unis et en Europe, l'entreprise **Connectera** propose la solution **Ida** (Intelligent Dairy Farmer's Assistant) basée sur l'utilisation d'un détecteur de mouvement attaché au cou des

bovins qui, par mobilisation d'un système d'IA, permet de suivre le comportement individuel (savoir si la vache se nourrit, si elle est allongée, si elle boit ou si elle se promène) (27).

••• En Corée du Sud, **LG Inotek**, la filiale dédiée aux composants électroniques du groupe **LG**, vient de se lancer dans le développement d'un projet de ferme autonome d'élevage de poules qui reposera sur l'intelligence artificielle (28).

••• L'aquaculture n'est pas en reste : la startup américano-norvégienne **Aquabyte** a annoncé avoir collecté 3,5 millions de dollars de fonds de démarrage pour constituer une équipe de développeurs et affiner son logiciel destiné à réduire les coûts en pisciculture. Les algorithmes se baseront sur de multiples données d'entrée : données issues de caméras 3D sous-marines, données environnementales telles que la température et l'oxygène, et autres données d'entrée telles que la quantité d'aliments (29).

Notons que nombre des travaux de recherche menés dans le domaine de la médecine humaine, et utilisant les approches Deep learning, pourront également trouver une transposition pour la médecine animale.

## » 2.2.2. I EN PRODUCTIONS VÉGÉTALES

**En productions végétales, le Deep Learning peut être utilisé pour résoudre des problèmes de :**

- Détection / Classification / Reconnaissance de plantes
- Détection / Reconnaissance de maladies
- Identification / Classification des stades phénologiques
- Classification Occupation sol / cultures
- Estimation de rendements
- Comptages de fruits
- Détection d'obstacles
- Prédiction météorologiques
- Prédiction de caractéristiques du sol (humidité...)

Nous proposons ci-après d'explorer certains de ces usages au travers d'exemples.



# Détection / Reconnaissance de plantes (ou de fruits)

## Les enjeux

- > **La biodiversité** : Pouvoir identifier des plantes pour caractériser un peuplement (composition de prairies par exemple) ou la biodiversité (quantification et qualification des espèces).
- > **La lutte contre les adventices** (réduction des coûts et/ou de l'impact environnemental, limiter les tâches manuelles pénibles et répétitives) :
  - Pouvoir identifier des plantes pour savoir les traiter chimiquement (déterminer le bon produit et la bonne dose).
  - Pouvoir identifier et localiser des plantes non souhaitées pour pouvoir les éliminer.

## C'est compliqué parce que ...

- > **400 000 espèces végétales sur terre + des variétés et sous-variétés d'espèces cultivées.**
- > **Il faut détecter des plantes non désirées parmi les plantes cultivées.**
- > **Il faut être capable de détecter des individus avec des inter-rangs faibles, voire en intra-rangs, avec des superpositions possibles de plantes.**
- > **Adventices, plantes cultivées, fruits passent par différents stades phénologiques ou stades de maturité et sont soumis à des environnements variables (luminosité, obstacles...).**



Parmi les exemples et témoignages que nous avons pu étudier, l'objectif visé est la détection d'adventices ou de fruits sur la base de données acquises en proxidtection : smartphones ou caméras embarquées sur différents types de vecteurs (drones, robots, quads, chenillards...). Dans tous les cas, ce sont pour le moment des réseaux de neurones convolutifs qui sont utilisés. On peut distinguer deux catégories d'applications :

### > Des applications basées sur une reconnaissance ponctuelle (une plante, une image), notamment à partir d'images acquises par smartphones :

- Par exemple, **BASF** qui commercialise les solutions **Xarvio** (développées par Bayer avant rachat par BASF), s'adresse directement à l'agriculteur équipé d'un simple smartphone. Elle annonce, au travers de l'application **Xarvio Scouting** (assistant de poche pour le tour de plaine), la capacité de reconnaissance de 82 adventices avec une précision de plus de 80% pour 75% des adventices détectées.

La reconnaissance est notifiée à l'utilisateur avec un niveau de confiance.



Couverture	Périmètre	Précision	Niveau de confiance	Projets
Stades précoces	✓		Moyen	Prochaine étape
61 adventices testées	✓	50 - 100 %	Elevé	Améliorer la précision
47 plus pertinentes	✓	80 - 100 %	Elevé	

Figure 19

Identification des adventices par Xarvio Scouting- Source : BASF, octobre 2018

L'application intègre également la reconnaissance de maladies (blé, maïs, colza, soja), d'insectes, la quantification de dégâts foliaires et du taux d'absorption d'azote. Pour Xarvio, l'intérêt est de proposer un mode de fonctionnement collaboratif : les photos prises par chaque agriculteur viennent enrichir la base d'apprentissage en continu et les informations ainsi recueillies (de localisation et de quantification des symptômes et adventices) sont réinjectées dans les modèles agronomiques afin d'affiner les outils d'aide à la décision. Pour ce type d'application, Xarvio recommande au moins des images 5 MegaPixels. Cependant, pour la reconnaissance des mauvaises herbes, des images de résolution inférieure (en dessous de la résolution VGA - 640 x 480 pixels) peuvent également être prises en charge.

”

« Nous avons étudié la technologie la plus appropriée pour répondre aux besoins des agriculteurs et capable de s'adapter rapidement aux nouveaux problèmes et régions. L'apprentissage profond nous offre la meilleure précision de reconnaissance et présente l'avantage de tirer des leçons de chaque image envoyée par les utilisateurs. Nous avons étudié d'autres technologies telles que les SVM, les Random Forest avec des fonctionnalités extraites à la main, etc. Cependant, elles n'ont pas répondu à nos besoins... Aujourd'hui, nos perspectives sont de continuer à développer l'application jusqu'à ce qu'elle puisse donner une analyse complète d'un champ observé pour divers aspects en temps réel. », **BASF via Benjamin Wallace, Xarvio Digital Farming France.**

- Dans un esprit similaire mais au départ, avec un objectif de recensement et de préservation de la Biodiversité, citons également l'application **Pl@ntNet**. Initiée en 2010 en tant que projet de recherche financé par la fondation Agropolis et réunissant 4 partenaires (**l'INRIA, l'INRA, l'IRD** et le **CIRAD**), Pl@ntNet est une application de reconnaissance des plantes par smartphone. Chaque observation est géolocalisée et donne lieu à une demande envoyée sur un serveur. Un algorithme de Deep Learning effectue un premier calcul de probabilité de reconnaissance qui est renvoyé à l'utilisateur. Celui-ci peut confirmer ou infirmer. Puis s'enclenche un mécanisme de révision collaborative : la communauté peut proposer d'autres identifications et donner son avis sur la qualité de la photo ; les probabilités associées à la reconnaissance d'une espèce sont pondérées en fonction du niveau d'expertise des personnes qui révisent. D'après une étude d'impact récente, 12% des utilisateurs utilisent Pl@ntNet à titre professionnel, la moitié pour des enseignements, l'autre moitié pour la gestion d'espaces naturels ou l'agriculture par exemple (pour l'identification d'adventices notamment). **Alexis Joly, co-responsable scientifique du projet** a accepté de nous en dire plus sur l'utilisation du Deep Learning dans le cadre de cette application.

”

### **Pourquoi utiliser une approche Deep Learning pour Pl@ntNet ? Quel intérêt y voyez-vous ?**

« Etant du monde de l'informatique et des data sciences, on a identifié très tôt le potentiel du Deep learning. Avant 2015, on utilisait d'autres méthodes et puis, soudain, on a vu les progrès spectaculaires qui étaient opérés en analyse d'image. En tant que chercheurs, nous participons et co-organisons régulièrement un challenge, le LifeCLEF, qui permet de comparer les performances de systèmes et... nos systèmes y arrivent en bonne position ! »

### **Est-ce que Pl@ntNet peut reconnaître n'importe quelle plante ? Y a-t-il des difficultés ?**

« Oui, il y a 2 difficultés principales : 1) La rareté des données : actuellement, on estime qu'il existe 400 000 espèces végétales sur la planète. Pl@ntNet en « gère » 18 000. On pense que notre système peut marcher très bien pour 20 à 30 000 espèces. Mais pour le reste, le manque de données d'apprentissage nuit aux performances. 2) L'ambiguïté pour la reconnaissance entre certaines espèces (comme entre deux carex par exemple). Même pour des experts il est parfois difficile d'effectuer une reconnaissance sur la seule base de la vision. Il faut vraiment opérer une reconnaissance multicritères, avec parfois recours à l'odeur par exemple... De même, Pl@ntNet n'est pas très bon pour la reconnaissance de variétés au sein d'une même d'espèce. Il est difficile d'accéder à des données très structurées pour des variétés horticoles ou maraichères mais nous y travaillons... »

### **Quelles perspectives voyez-vous pour Pl@ntNet ?**

« Je pense que nous allons rester sur le monde végétal (on aurait pu imaginer développer quelque chose de similaire pour les animaux). Nous allons creuser certaines problématiques : reconnaissance de sous-variétés, stades de croissance, épidémiologie, cartographie et distribution d'espèces. L'idée est de pouvoir rediffuser de la connaissance au public. Mais a priori, nous allons continuer à être de gros utilisateurs de Deep Learning car nous n'avons plus de doute sur l'intérêt de ces technologies. »

### > Des applications basées sur des acquisitions systématiques et automatisées (on ne cadre pas une plante en particulier), à partir de dispositifs embarqués :

- L'entreprise **Telespazio France**, spécialisée dans les services et applications satellitaires, travaille depuis 3 ans avec un groupe industriel sur la problématique de reconnaissance de certaines adventices en Grandes Cultures (pour des raisons de clauses de confidentialité, nous ne pouvons pas préciser la nature exacte des travaux). Une première campagne menée en 2017 sur une culture a montré une amélioration significative des résultats en termes de qualité de la discrimination par rapport aux méthodes classiques. Les points de vigilance soulevés par Telespazio lors de l'entretien portent sur les temps de traitement (comment améliorer le modèle sans dégrader le temps de traitement), la qualité nécessaire du jeu de données (images à très haute résolution permettant de reconnaître formes et textures) et la difficulté de compréhension de certains résultats (nous reviendrons sur ce point).
- L'entreprise **Carbon Bee** propose des services de pilotage du désherbage en grandes cultures : cartographie des adventices et détection / discernement des espèces pour une pulvérisation au bon endroit, en combinaison avec des technologies d'injection directe. L'entreprise utilise des algorithmes de Deep Learning pour la détection et la reconnaissance d'une quinzaine de mauvaises herbes. Carbon Bee s'est intéressé au Deep Learning dès le début de la mise au point de ses produits pour différentes raisons :

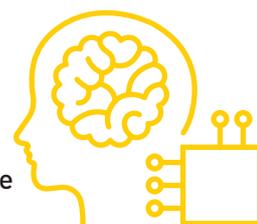


« Le Deep Learning nous permet d'appréhender la très grande variabilité de conditions et de situations auxquelles est soumise la détection de plantes ou de symptômes. Par exemple, pour la reconnaissance de plantes, il nous faut gérer des cas de carences, des stades phénologiques différents, des différences de taille entre les individus, petits ou grands, biscornus ou pas, avec ombre ou pas, une multitude de variétés, etc... On cherche donc une vraie souplesse et flexibilité d'usage. Ensuite, il répond au type de problématique que nous souhaitons pouvoir traiter, à savoir proposer des algorithmes « tout terrain ». On veut pouvoir aller chercher différents symptômes en embarquant les mêmes capteurs sur un quad et en faisant tourner les mêmes algorithmes. La seule chose qui doit changer, ce sont les données d'entrée, les bases de connaissance mises en œuvre. », **Colin Chaballier, Carbon Bee AgTech**

Carbon Bee travaille également sur la détection de maladies pour la vigne (Mildiou, Esca, Flavescence dorée).

## Des usages couplés à la Robotique et au Machinisme :

Le Deep Learning rejoint évidemment des innovations en matière de robotique agricole et d'équipements agricoles.



- Dans le cadre du **Challenge Rose**, plusieurs équipes associant chercheurs et ingénieurs du monde académique, des entreprises et des organismes techniques, utilisent la vision embarquée et les technologies de Deep Learning pour concevoir des solutions innovantes de désherbage intra-rang afin de réduire, voire supprimer, l'usage des herbicides. Le Challenge (<http://challenge-rose.fr/>) est cofinancé par les ministères chargés de l'Agriculture et de la Transition Ecologique via l'Agence Française pour la Biodiversité (AFB) et le ministère chargé de la Recherche via l'Agence Nationale de la Recherche (ANR). Il est organisé par le Laboratoire National de métrologie et d'Essais (LNE) et Irstea.

- La startup française **Bilberry** propose des algorithmes pour l'identification des mauvaises herbes couplés à un système de pulvérisation automatique pour une application de précision. Initialement imaginé pour fonctionner avec des drones, le système est finalement couplé à des buses pilotables individuellement sur des rampes de pulvérisation installées sur les côtés d'un tracteur. La startup a signé un partenariat avec l'entreprise **Agrifac** qui diffuse aujourd'hui la technologie en Australie avec un objectif de diminution des quantités de produits phytosanitaires (30).

- Toujours en matière de pulvérisation de précision, la start-up suisse **Ecorobotix**, propose un robot utilisant des algorithmes de reconnaissance d'adventices pour une pulvérisation ultra-localisée sur l'inter-rang voire le rang. Le robot embarque deux réservoirs d'une vingtaine de litres qui alimentent des buses placées au bout de bras articulés. Le prototype, testé au printemps 2017 par la Chambre d'Agriculture du Loiret en conditions réelles chez des producteurs de betteraves, montrait une efficacité allant de 30 à 80% selon le stade des betteraves (la détection au stade précoce étant encore difficile) [31].

- Agrobot, proposé par **NVIDIA Jetson** est un système de récolte robotique autonome conçu pour automatiser la récolte de baies. Agrobot utilise l'apprentissage profond pour déterminer quand les fruits sont à maturité pour être cueillis puis jusqu'à 24 bras robotisés permettent de séparer le fruit de sa tige. Agrobot utilise un scanner de détection 3D avec des capteurs de couleur et infrarouge à courte portée intégrés. La méthode s'appuie sur un réseau de neurones convolutif pour classer chaque pixel de l'image entrante dans la classe « fraise » ou non. Toutefois, si les fraises se chevauchent dans l'image, ce type de segmentation de l'image ne suffit pas. Agrobot envisage d'étendre son système pour effectuer une segmentation d'instances où chaque fraise est unique.[32]

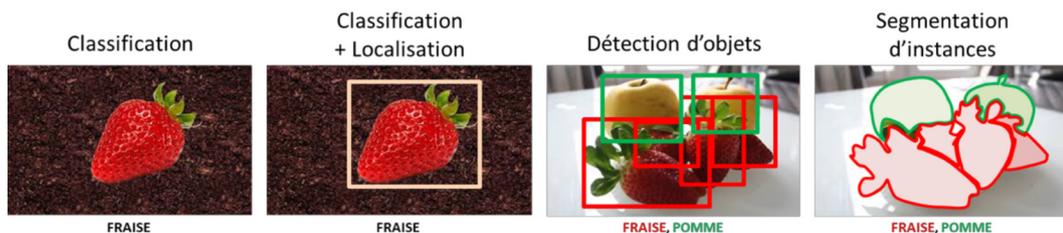


Figure 20  
Différents types de tâches  
en vision par ordinateur

## Détection / Reconnaissance de maladies (ou carences)

### Les enjeux

- > **La lutte contre les maladies** (objectifs de réduction des coûts liés à la perte de production ou à l'utilisation d'intrants, de réduction de l'impact environnemental). On veut par exemple :
  - Pouvoir reconnaître des plantes malades de plantes saines.
  - Pouvoir détecter et/ou identifier des maladies sur une zone pour déterminer une stratégie de gestion (zonage).
  - Pouvoir détecter et/ou identifier des maladies à certains stades pour agir au bon moment.
  - Pouvoir identifier/localiser les individus touchés .
  - Pouvoir évaluer la part de plante touchée afin de traiter avec le bon produit / la bonne dose.
  - Pouvoir identifier et localiser des plantes non souhaitées pour pouvoir les éliminer.

### C'est compliqué parce que ...

- > **Plusieurs symptômes sur différentes parties de la plante sont parfois nécessaires pour établir un diagnostic.**
- > **Plusieurs maladies peuvent avoir des symptômes similaires.**
- > **Plusieurs problèmes peuvent être concomitants (carences, diverses maladies...).**
- > **Les symptômes ne se présentent pas toujours sur les surfaces facilement accessibles (peuvent être situés sous les feuilles ou masqués par des obstacles).**



#### DES EXEMPLES :

- Développée à la **Penn State University** sur la base d'un partenariat entre l'Institut international d'agriculture tropicale et l'Organisation des Nations Unies pour l'alimentation et l'agriculture, **PlantVillage Nuru** est une application « de service public » pour aider les agriculteurs à diagnostiquer les maladies des cultures sur le terrain, à partir de photos prises par smartphones. L'application utilise l'outil d'apprentissage automatique Tensorflow de Google et une base de données d'images collectées par des experts des maladies des cultures à travers le monde. Son originalité est de travailler hors ligne et peut donc être utilisée dans les régions où la connectivité Internet est médiocre ou inexistante. Elle vise à aider les agriculteurs qui n'ont pas toujours de grands moyens d'accéder à la technologie. Elle est notamment déployée et testée actuellement dans 7 pays d'Afrique.

- En Inde (et autres régions du monde), c'est l'application **Plantix** développée par la start-up **Peat** qui rend un service similaire et propose une application Android pour smartphones compatibles 3G. L'application se sert des technologies Deep Learning pour identifier l'espèce et la maladie potentielle. Elle propose un ensemble de services allant de mise à disposition d'informations et de conseils sur la culture et les moyens de lutte contre la maladie et permet la mise en relation avec une communauté d'utilisateurs et d'experts au niveau local ou mondial.



- En France et en Europe, nous avons déjà évoqué l'application **Xarvio Scouting**, qui annonce la possibilité de reconnaissance, toujours à partir d'images smartphone, de 24 maladies du Blé, Colza, Maïs et Soja :

Culture	Maladies reconnues
<b>Blé</b>	rouille brune (90%), rouille jaune (71%), helminthosporiose (66%), septoriose (68%), dégat de criocère des céréales (89%), oïdium (84%), microdochium (99%), piétin-verse (78%), fusariose (90%)
<b>Colza</b>	phorna (99%), sclérotinia (94%)
<b>Maïs</b>	helminthosporiose (53%), rouille du maïs (92%), cercosporiose (45%), rouille brune du Sud (52%), fusariose de l'épi (100%), kabatiellose (50%)
<b>Soja</b>	taches brunes (93%), rouille du soja (97%), cercosporiose (39%), anthracnose (98%), taches ocellées (94%), oïdium (97%), nématode à galles (95%)

Figure 21  
Maladies reconnues par Xarvio Scouting – Source : BASF, Octobre 2018

- L'entreprise **Adventiel** annonce un prototype d'application pour la reconnaissance de la septoriose et la rouille brune du blé nommée **PhotoDiag**.

- En vigne, ce sont les maladies telles que Mildiou, Esca et Flavescence dorée qui mobilisent les chercheurs et ingénieurs spécialistes du Deep Learning. Ces maladies comptent en effet parmi les plus grandes menaces des vignobles. L'absence de prévention efficace pour certaines de ces maladies et/ou les moyens curatifs (souvent l'arrachage des plants) induisent d'importantes pertes économiques.

Parmi les opérateurs commercialisant des produits et services basés sur l'intelligence artificielle, l'entreprise **Chouette Vision** propose une solution « clé en main » au viticulteur lui permettant d'acquérir un drone et de bénéficier de services de repérage et de cartographie de ces maladies (ainsi que les pieds manquants, l'estimation de la surface foliaire, etc).



« Nous travaillons à partir d'image à haute résolution (mm/pixel) pour une reconnaissance de symptômes visibles, comme un humain le ferait sur le terrain, mais le drone permet de couvrir l'ensemble des ceps des parcelles. Notre but est de cartographier ces symptômes, d'obtenir des zonages, de façon à comprendre la répartition dans le vignoble et ainsi pouvoir définir une stratégie de lutte. Le premier objectif est déjà de faire la différence entre individus sains et individus malades. Ensuite, la performance dépend de la complexité de la parcelle : présence de carences, de différentes maladies, etc. Pour l'Esca, nous travaillons sur la forme lente. Pour la flavescence dorée, nous travaillons sur les cépages rouges. Avec une résolution suffisante, les nervures des feuilles sont visibles par exemple. On peut voir si elles sont colorées ou non et réduire la confusion avec d'autres maladies ou carences. [...] Pour nous, les méthodes basées sur le « spectral » n'étaient pas assez robustes, pas facilement transposables d'une région à l'autre par exemple. Aujourd'hui, nous sommes convaincus qu'avec le Deep Learning nous ne faisons pas fausse route mais évidemment il faut être prudent. Nous en sommes encore au début et l'apprentissage se fait en continu, comme pour un humain».

**Antoine Simon, Chouette Vision**

- Les résultats obtenus en recherche sont très encourageants, même si des tests supplémentaires sont à opérer pour obtenir des résultats robustes. Ainsi un article scientifique à paraître traite des travaux menés par l'équipe de recherche du **Laboratoire IMS** (Bordeaux) pour la reconnaissance des symptômes de l'Esca (symptômes foliaires en été, présentant un motif tigré typique) montre la plus grande efficacité d'un réseau de neurones profond par rapport à l'utilisation d'une méthode à la pointe de l'état de l'art basée sur l'extraction de caractéristiques spécifiques (points clés communiqués au système). Les travaux montrent également que l'utilisation des réseaux profonds permet de séparer de façon efficace des plantes légèrement symptomatiques de plantes sévèrement atteintes (10).

## Estimation de récolte / rendements



### Les enjeux

- > **Environnementaux et économiques** : anticiper et adapter au plus juste les intrants et les ressources (y compris humaines), sélectionner les variétés optimales.
- > **Humanitaire** : organiser des compléments d'approvisionnements en cas de rendements estimés faibles.
- > **Economique** : ajuster le prix de vente sur pied, prévoir les évolutions du marché.

### C'est compliqué parce que...

- > **Pour un dénombrement, les fruits/épices peuvent être à l'ombre, occultés par le feuillage, les branches ou se masquer les uns les autres...**
- > **Les facteurs influençant le rendement (ou la capacité à prévoir de façon précoce) sont nombreux : conditions météorologiques, irrigation, fertilisation, variétés cultivées, etc...**



#### UN EXEMPLE :

En France l'**UMT CAPTE** basée à Avignon qui travaille sur des outils de phénotypage, d'aide à l'expérimentation et à la décision pour le pilotage de l'exploitation, s'est récemment intéressée à l'estimation de la densité d'épis de blé à partir d'images couleur haute résolution en utilisant des techniques Deep Learning (33).



« L'objectif est de trouver une bonne méthode pour automatiser et accélérer ces mesures. Elles sont en effet utiles pour caractériser le comportement des variétés et, en cours de campagne, pour prédire le rendement. Mais le comptage d'épis de blé, c'est compliqué. Les méthodes manuelles sont chronophages et posent la question de l'échantillonnage. On ne s'en sortait pas. » **Benoît de Solan, Arvalis Institut du Végétal, UMT Capte**

L'étude compare en fait deux réseaux de type CNN, l'un basé sur la détection d'objets et l'autre sur une régression par comptage local. Les résultats montrent que les deux approches sont toutes deux performantes mais que celle basée sur la détection d'objets est plus robuste sur des données acquises à une autre date (donc avec d'autres conditions d'arrière-plan et de maturité des plants). Cette robustesse se fait cependant au prix d'un effort de calcul plus important. L'étude indique en outre une similarité de résultat « raisonnable » compte tenu de la taille réduite de l'échantillon (erreur relative de 15% qui augmente avec les fortes densités) entre la méthode par détection d'objets et la méthode par comptage manuel in situ qui tendrait à confirmer que la densité d'épis dérivée de l'imagerie couleur haute résolution peut remplacer la méthode de comptage traditionnelle.

# Classification de l'occupation du sol



## Les enjeux

> **Multiples (contrôles, prévision des prix, assurances, prévision de pénuries...)** : les cartes d'occupation des sols et des types de cultures sont une source d'informations essentielles pour de nombreuses applications en agriculture. On veut par exemple :

- Pouvoir déterminer les différents types de cultures.
- Pouvoir déterminer les stades phénologiques.
- Pouvoir déterminer les surfaces.

## C'est compliqué parce que...

- > **La végétation évolue.** Il existe des cultures d'été et des cultures d'hiver. Il faut parfois pouvoir distinguer les rangs des inter-rangs.
- > **Les données d'entrée, les images, peuvent avoir des informations manquantes (du fait de nuages ou d'ombres).**
- > **Les données exploitables peuvent être hétérogènes (de différentes résolutions spatiales notamment).**

Différentes études dont [34] indiquent l'efficacité, voire la supériorité des approches Deep Learning pour le traitement de données de télédétection tant optiques (imagerie hyperspectrale et multispectrale) que radar. Ces résultats, conjugués au lancement, ces dernières années, d'une constellation de satellites (Sentinel 1 et 2, Landsat-8) offrant des images gratuites à un rythme régulier, ouvrent les perspectives pour des usages agricoles. Aujourd'hui, les recherches s'orientent vers l'exploitation des séries multi-temporelles et dans ce cadre, les approches utilisant les réseaux récurrents trouvent tout leur intérêt.

### UN EXEMPLE :



• **L'ASP** (Agence des Services et des Paiements, qui assure les paiements des aides PAC et les contrôles règlementaires y afférents) participe avec d'autres agences de paiements nationales à des projets européens visant à changer le mode opératoire des contrôles. A l'heure actuelle, les agriculteurs ont, chaque année, jusqu'au 15 mai pour déclarer les cultures pratiquées durant l'hiver et celles prévues pour l'été. L'ASP effectue ponctuellement des contrôles sur la base d'images optiques à très haute résolution spatiale (1m environ) acquises à 3 périodes de l'année. L'objectif est de les systématiser par un traitement automatique sur la base des séries Sentinel (10m de résolution spatiale, passage tous les 5 jours environ). 3 niveaux sont envisagés :

#### 1 : « CONTINUOUS MONITORING »

Les agriculteurs continueront à déclarer leurs surfaces mais des contrôles seront opérés en continu : un système permettra d'indiquer la probabilité que l'occupation de la parcelle corresponde à un type de culture donné. Le système sera ouvert : les agriculteurs pourront voir la probabilité proposée et réagir en fonction.

#### 2 : DÉCLARATION PRÉ-REMPLE

Ce service s'adresserait directement aux agriculteurs. Il permettrait de leur proposer une base de déclaration, obtenue en fonction des images Sentinel 1 et 2 et tenant compte des rotations passées pour les cultures annuelles et les anciennes versions des déclarations pour les prairies et cultures permanentes.

#### 3 : DÉCLARATION TOTALEMENT AUTOMATISÉE

A plus long terme, les agriculteurs ne rempliraient plus de déclaration. Tout serait basé sur la reconnaissance automatique.

Pour ces 3 cas il est nécessaire de s'intéresser aux types et surfaces des cultures. C'est la raison pour laquelle, **l'IGN**, qui participe à réalisation de ces missions, souhaite aujourd'hui explorer le potentiel des réseaux de neurones récurrents pour la prédiction de types de cultures et de surfaces à partir d'images Sentinel. L'institut vient de lancer une thèse sur le sujet.



« Il nous est apparu que les Réseaux de neurones récurrents, qui permettent d'entretenir une mémoire de l'information, pouvaient être une bonne option. [...] Des comparaisons de performances ont d'ores et déjà été réalisées pour de la reconnaissance de cultures à partir d'images Sentinel 1 et 2. Globalement les performances avec LSTM et GRU (2 types de réseaux RNN) sont supérieures à celles des Random Forest (de +1 % à +35 % selon les classes). [...] Pour nous, il y a également des enjeux scientifiques intéressants comme par exemple répondre aux problématiques de données manquantes actuellement rencontrées avec Sentinel, ou d'échantillonnage temporel (les satellites Sentinel fonctionnent en décalé) » **Sébastien Giordano, IGN**

- Monitorer l'agriculture du local au mondial : l'entreprise biélorusse **OneSoil** a annoncé en octobre 2018 la mise à disposition (gratuite) d'une carte, **OneSoil Map**, permettant à tous les acteurs du secteur agricole d'explorer et de comparer les champs et les cultures en Europe et aux États-Unis - 43 pays au total. La fonctionnalité clé de la carte est qu'elle permet aux utilisateurs de voir comment ces champs ont changé au cours des trois dernières années (2016 - 2018). OneSoil utilise des données satellites (données radar Sentinel 1) couplée aux technologies de Deep Learning pour offrir une visualisation des surfaces, des types de cultures et un classement des cultures par pays ou région.

### » 2.2.3. I AUTRES CAS OÙ L'APPRENTISSAGE PROFOND CHANGE(RA) LA DONNE EN AGRICULTURE

#### LES BIOTECHNOLOGIES AGRICOLES

Le Deep Learning peut fournir de nouvelles pistes d'exploration de données d'origines diverses, notamment les données « omics » (liées à la génomique, la protéomique,...), permettant de mieux comprendre la structure génétique des organismes pour la production ou le traitement des produits agricoles. Ainsi, plusieurs études du domaine de la bioinformatique ont montré les gains de performances obtenus par l'usage de réseaux de neurones profonds pour la prédiction de la structure de protéines, la régulation de l'expression génique, la classification des protéines ou d'anomalies génétiques. Les RNN, en particulier, peuvent constituer des architectures intéressantes pour analyser les séquences biologiques. Ceci peut ouvrir des perspectives pour la sélection variétale par exemple. Notons que, dans ce domaine, les processus d'acquisition de données peuvent s'avérer complexes et coûteux ce qui, en limitant la taille des jeux de données, peut constituer un frein. Cependant, l'apprentissage par transfert, permettant d'utiliser des réseaux pré-entraînés sur des problématiques similaires offre là encore des pistes de réponses. [38]

#### LA MAINTENANCE PRÉVENTIVE DES MACHINES AGRICOLES

Des travaux de recherche récents ont proposé d'utiliser des réseaux convolutifs pour l'analyse des signaux vibratoires des systèmes mécaniques. Il s'agit en fait d' « écouter » le moteur pour diagnostiquer de façon précoce des dégradations ou autres anomalies. Par exemple, ces techniques détectent en temps réel des amorces de fissures sur des roulements à billes. Ceci laisse envisager une implantation directe dans les moteurs et systèmes mécaniques des machines agricoles [35].

#### LES VÉHICULES AGRICOLES AUTONOMES

Le Deep Learning est au cœur des enjeux liés aux véhicules autonomes. Rendre un véhicule autonome n'est pas chose aisée : le véhicule doit être en mesure de « voir et comprendre » son environnement, de se localiser, de prédire des trajectoires en fonction de ce qui se passe autour de lui et d'adapter son comportement. Les approches Deep Learning peuvent apporter des réponses. D'abord en permettant de traiter efficacement et en temps réel le très grand nombre d'informations nécessaires. Ces informations sont fournies en direct par l'ensemble des capteurs qui bardent les véhicules (Lidar, caméras vidéos et infrarouge, radar, GPS...). Mais il permet également d'y ajouter un ensemble de données « d'expérience »: des données qui ont servi à l'apprentissage, issues de multiples essais et mises en situations permettant d'identifier des cas d'usages variés et tout ce qui peut survenir...

Dans le domaine agricole, des prototypes de tracteurs autonomes ont d'ores et déjà été présentés (T4.110 F NHDrive de **New Holland** pour la vigne par exemple [36], ou les tracteurs Quadtrac et Steiger de **Case IH**)

et visent à se positionner en tant qu'auxiliaires de l'agriculteur en lui évitant la pénibilité du travail ou la pénurie de main d'œuvre, en lui ouvrant des fenêtres d'action plus efficaces (travail de nuit par exemple) et en réduisant les coûts de fonctionnement et d'entretien par le respect scrupuleux des conditions d'utilisation. Mais pour ce qui est d'une utilisation effective par les agriculteurs, l'automatisation des engins agricoles va probablement se faire par étapes progressives : du simple autoguidage à l'automatisation totale, en passant par l'automatisation supervisée par un opérateur (37). La plus-value apportée par le Deep Learning correspond donc à un stade avancé en termes de besoins. Ces technologies sont coûteuses, ne serait-ce que par le matériel à embarquer, or la rentabilité de ces nouveaux engins devra être démontrée... L'agriculture devrait cependant rapidement profiter des avancées de l'industrie automobile en la matière.

## LES ASSISTANTS CONVERSATIONNELS

Difficile de parler intelligence artificielle sans évoquer les assistants conversationnels ou **Chatbots**.

Alors que la guerre entre les géants **Alexa, Cortana, Google Assistant** et autres fait rage, les agriculteurs découvrent également de nouveaux services dédiés. En France par exemple, l'entreprise **Adventiel** propose **Hubixeo**, une plateforme de chatbots professionnels dédiés à l'agriculture, lauréate Innov'Space 2017.

En permettant une interaction en langage naturel, écrit ou oral, les chatbots sont pensés pour faciliter l'interface homme/machine. Ils permettent par exemple d'accéder sur simple demande aux multiples applications (voire aux objets connectés) utilisées sur l'exploitation, de recevoir des alertes explicites, d'obtenir rapidement des informations ou d'en enregistrer...

Mais il y a chatbots et chatbots... Tous ne relèvent pas véritablement d'intelligence artificielle : dans certains cas, ce sont de simples moteurs de recherche fonctionnant par mots clés, dans d'autres cas il s'agit plus de systèmes experts permettant de proposer des phrases en fonction de règles pré-établies. L'Intelligence artificielle commence véritablement lorsque le système parvient à s'enrichir au contact des utilisateurs. Et dans ce cadre, les approches Deep Learning peuvent intervenir parmi un ensemble de services cognitifs. C'est ce que nous confirme Xavier L'Hostis responsable Innovation chez Adventiel :

« Pour détecter les intentions des utilisateurs, nous nous appuyons sur une plateforme d'IA (services cognitifs cloud) qui fait de l'analyse sémantique et syntaxique de phrases associées à des intentions (fonctionnalités) paramétrées dans la plateforme. La pertinence de prédiction est liée à l'apprentissage du moteur d'IA (nombre de phrases / formes de phrases associées à chaque intention). Nous intégrons de l'auto-apprentissage dans la plateforme : ajout automatique de phrases en fonction des réponses des utilisateurs (ils doivent confirmer la détection par le moteur d'IA de la bonne intention associée à une phrase dès lors que le pourcentage de prédiction est faible). Voixeo [application d'assistance vocale pour les éleveurs], intègre de la reconnaissance vocale (qui peut aussi s'appuyer sur des services cognitifs cloud et donc du Deep Learning), associée à de l'intelligence vocale métier développée par Adventiel (mais n'utilisant pas de Deep Learning). »  
**Xavier L'HOSTIS, Adventiel**

## On retient :

- Depuis 2015, l'exploration des approches Deep Learning pour des usages agricoles s'est intensifiée en matière de recherche et donne aujourd'hui lieu aux premières propositions commerciales.
- Les cas d'utilisation les plus facilement appréhendés sont liés à la vision (à l'analyse d'image).
- Les réseaux convolutifs sont les plus couramment utilisés. Les réseaux récurrents se développent permettant une meilleure prise en compte de la dimension temporelle.
- En permettant l'intégration de données massives et hétérogènes, et en association avec les innovations dans les domaines des capteurs et objets connectés, de la robotique et du machinisme agricole, l'apprentissage profond apporte de nouvelles réponses, performantes, en matière de suivi des productions animales et végétales, d'aide à la décision pour la gestion des exploitations et de facilitation de la vie de l'agriculteur.

Pour le moment, nous avons brossé un tableau plutôt idyllique de ces approches. Mais où en est-on véritablement ? Aujourd'hui, le Deep Learning est un axe de recherche actif. Des données à l'interprétation des résultats, en passant par des problèmes d'optimisation d'architecture, d'algorithmes, et d'équipement hardware, nous allons voir que de nombreuses questions se posent encore...

# PARTIE 3 :

## DEEP LEARNING : QUESTIONS ET RÉFLEXIONS



### 3.1. Les données : la force et le talon d'Achille du Deep Learning ?

Les technologies Deep Learning sont pilotées par les données. C'est ce qui en fait leur force mais également ce qui peut être leur faiblesse. Ainsi, les articles scientifiques ou les témoignages recueillis pour cette étude, font ressortir différents points saillants liés aux données :



**Le Deep Learning exige des jeux de données conséquents pour obtenir des modèles performants.**



Le Deep Learning consomme de très grands ensembles de données. D'autant qu'il est souvent nécessaire de disposer de plusieurs jeux de données :

- > des données pour l'apprentissage : celles qui vont permettre d'entraîner le modèle par l'algorithme d'apprentissage,
- > des données pour le test : les données gardées de côté, encore inconnues du système, qui vont permettre de mesurer l'erreur du « modèle ».

Plus le problème à résoudre est compliqué (par exemple un grand nombre de classes à identifier et / ou une petite variation entre les classes), plus le nombre de données nécessaires a tendance à être grand (19). Il peut atteindre des milliers voire des dizaines de milliers de données d'entrée.

Ces données doivent pouvoir couvrir des variétés de situations (stades de végétation, luminosité, humidité...) et nécessitent donc parfois un recours à des sources multiples, plus ou moins facilement accessibles.



« Ce qu'il faut savoir, c'est que même avec une grosse communauté d'utilisateurs comme celle de Pl@ntNet, le flux de données entrantes véritablement nouvelles est faible. On nous remonte souvent les mêmes espèces... Pour enrichir la base d'apprentissage, nous avons donc importé des données d'Encyclopedia of Life, avec laquelle nous avons un partenariat, des données personnelles et de plus en plus, des données issues du web, telles Google Images qui donnent des résultats très satisfaisants. Mettre en place un modèle de Deep Learning, c'est « assez facile » car très documenté mais les sources de données d'apprentissage restent le point critique ». **Alexis Joly, Pl@ntNet**

Plusieurs bases de données sont d'ores et déjà utilisables en accès public : **Image-Net, Plant Village, Leafsnap, LifeCLEF, Flavia Leaf, Leafsnap** ((19) annexe C)... Dans le cadre de travaux de recherche, les chercheurs les utilisent mais complètent souvent avec leurs propres acquisitions pour des applications plus spécifiques.

Ils doivent souvent avoir recours en plus à des techniques d'augmentation des jeux de données : effectuer des rotations, des retournements, des recadrages, des découpages d'une même image en plusieurs images (39). Dans certains cas, et afin d'éviter des problèmes de surapprentissage, du bruit peut également être introduit dans des images.

Des techniques plus sophistiquées (encore balbutiantes) voient également le jour, au travers de l'utilisation de réseaux de neurones de type GAN susceptibles de créer de nouvelles images (40).

Les évolutions en matière d'apprentissage par transfert apportent également des solutions au problème de volume de données nécessaires. En effet, les réseaux peuvent être pré-entraînés sur de très gros volumes de données (notamment des bases en accès libre comme ImageNet) puis être utilisés en tant que composants de l'architecture pour un jeu de données beaucoup plus étroit. Ceci a pour autre avantage de réduire de façon significative le temps à consacrer à la phase d'apprentissage.





## Le Deep Learning, en apprentissage supervisé, exige des données annotées

En dehors de cas où de très grandes bases de données « communautaires » (c'est-à-dire enrichies et annotées par la participation d'une communauté) peuvent être utilisées, la question de l'annotation des données est cruciale en Deep Learning. En effet, ce processus qui consiste à associer une ou plusieurs étiquettes à une donnée (associer une image ou des objets contenus dans une image à une maladie par exemple) est extrêmement chronophage et exige un certain savoir-faire. Il est en général assuré par des experts agronomes car il conditionne la performance du système : les résultats mais aussi le temps d'apprentissage. La question de la main d'œuvre se pose pour ce type de tâches lorsque l'on passe d'un contexte de R&D à une mise en production à plus grande échelle (voir encadré).

Aujourd'hui des techniques d'annotation automatique (ou semi-automatique) existent, d'ailleurs basées sur l'utilisation de réseaux de neurones, mais ne peuvent pas toujours être utilisées pour toutes les tâches.

### “La problématique de l'annotation, Interview de Colin Chaballier, Carbon Bee Agtech.”

#### > CHAIRE AGROTIC (CA) : DANS VOTRE CAS, À QUOI CORRESPOND L'ANNOTATION ?

L'annotation correspond à une sorte de coloriage des images selon des zones d'intérêt pour leur associer des « labels » ou étiquettes. Il y a 2 étapes : la première consiste à repérer ce qui nous intéresse et la deuxième à la « colorier ». La difficulté de l'exercice varie beaucoup d'un cas à l'autre. Par exemple, un cas simple, c'est repérer un chardon dans du maïs. Un cas difficile, c'est repérer une graminée donnée parmi d'autres graminées. Il faut dans ce cas une vraie expertise, et pour la reconnaissance et pour le marquage.

#### > CA : EN QUOI EST-CE UNE ÉTAPE CRITIQUE DU PROCESSUS DE DEEP LEARNING ?

Nous souhaitons entraîner nos algorithmes avec le moins d'images possible de façon à accélérer la phase d'apprentissage. Il est donc très important pour nous de quantifier le travail, l'effort à fournir par rapport à l'objectif d'opérationnalité visé. Or, cette phase d'annotation est très chronophage et nécessite une main d'œuvre qualifiée. C'est une étape à mettre dans de bonnes mains car si on se trompe, on fait apprendre de mauvaises choses au logiciel. Or, si quelques erreurs peuvent être acceptables, dans certains cas, 10 ou 20 % d'erreur sur une reconnaissance, ça peut être une catastrophe !

#### > CA : VOUS POUVEZ ME DONNER QUELQUES POINTS DE REPÈRE ? POUR UN PROCESSUS D'APPRENTISSAGE « STANDARD », L'ANNOTATION VA CONCERNER COMBIEN D'IMAGES ET PRENDRE COMBIEN DE TEMPS ?

On fonctionne sur différents niveaux de bases de connaissance. En général, on commence avec un niveau standard et puis, ensuite, on étend la base. Disons, qu'en standard, ça peut concerner une centaine d'images mais encore une fois, le niveau de difficulté varie. Donc ça peut prendre de 2 mn à 1h par image : tout dépend de ce qu'il faut reconnaître et de la facilité de « coloriage ». Mais nous avons peut-être une approche très qualitative... En fait, on manque de points de comparaison avec ce qui se fait ailleurs. En tout cas, cela représente une charge de travail en permanence et nous enregistrons une vraie montée en charge.

#### > CA : VOUS AVEZ DIT QUE VOUS « ÉTENDIEZ LA BASE », QU'EST-CE QUE CELA SIGNIFIE ?

Cela signifie qu'après un premier lot d'images, on diversifie

les cas. Par exemple, pour du chardon dans du maïs, il va nous falloir différencier les différents stades phénologiques du chardon et du maïs (maïs à 4 feuilles, 6 feuilles...) et les conditions (petit matin, luminosité faible, etc). C'est toute cette complexité qui pose des problèmes de compréhension pour les experts IA et les agronomes. Il y a un vrai enjeu sur la définition des critères qui vont permettre un bon apprentissage. Cela dépend de l'objectif visé en fait. Le problème n'est pas le même si on vise à déterminer l'efficacité d'un herbicide ou si on cherche à détecter une mauvaise herbe. Dans le premier cas, il nous faut être capable de calculer la surface foliaire résiduelle, dans l'autre il nous suffit de voir un bout de chardon par exemple. Cet objectif oriente la stratégie pour construire la base de connaissance, le reste du travail portant ensuite sur le post traitement statistique et la construction d'indicateurs (dans le premier cas par exemple, on peut raisonner sur des pourcentages de pixels détectés ou pas et, dans le deuxième, sur un nombre de plants détectés ou manqués).

#### > CA : QUI EFFECTUE CETTE TÂCHE ?

Habituellement, l'annotation était faite par nos « data scientists » avec un outil développé en interne. Mais ceci est difficilement tenable pour passer à l'échelle et nous souhaitons plutôt aujourd'hui qu'ils aient un rôle de commanditaires. Nous envisageons d'externaliser cette activité et testons plusieurs voies actuellement, en essayant de composer des équipes mixtes, avec du personnel de Carbon Bee et des intervenants extérieurs, tels que des étudiants, des prestataires et des personnels des clients partenaires (surtout sur des sujets agronomiques complexes ; cette année cela a concerné une dizaine de projets). On peut imaginer automatiser partiellement cette tâche, par exemple au moins pour pré-détecter certaines zones d'intérêt. Par contre, nous sommes encore très frileux, par rapport à nos objectifs qualitatifs, quant à utiliser des solutions de sous-traitance clés en mains.

#### CA : D'OÙ VIENNENT VOS DONNÉES D'APPRENTISSAGE ?

Nos images sont entièrement acquises par nos capteurs mais il peut s'agir d'acquisitions réalisées par nos clients (qui ne sont pas situés près de nous).

#### CA : COMMENT ON TESTE LA QUALITÉ DE L'ANNOTATION ?

Ça, ce n'est pas le point le plus critique. En général, cela ne représente pas une si grande quantité de données. On réalise un échantillonnage et nos experts vérifient. Si c'est OK pour ces images, on considère que c'est bon. Il y a aussi possibilité d'automatiser quelques tests.



## Le Deep Learning exige des données de bonne qualité

C'est un point soulevé par différents interlocuteurs, dans des contextes d'analyse d'images, mais qu'il faut évidemment rapporter aux problématiques traitées. En proxidtection, par exemple, quand il s'agit de reconnaître des adventices sur la base d'un plant totalement cadré (comme avec un smartphone) où l'intégralité de la forme pourra être perçue, une résolution moyenne à faible (quelques millimètres par pixel) peut être suffisante. Lorsqu'il s'agit de travailler sur des « scènes », où les plantes ne sont pas cadrées, où elles ne seront vues que partiellement ou parmi d'autres, de plus grandes résolutions sont attendues afin de pouvoir atteindre des niveaux de reconnaissance liés, par exemple, à la texture des objets : souvent moins d'un millimètre par pixel.

A la résolution s'ajoute la problématique de la géométrie et de la qualité spectrale de la prise de vue. Plusieurs opérateurs ont ainsi choisi de proposer l'outil d'acquisition en plus du service d'analyse d'image afin d'être sûrs de disposer de données de « qualité » suffisante.



« Nous avons choisi de porter de gros efforts sur l'outil d'acquisition des images, un drone équipé d'une caméra, que le viticulteur peut acheter et utiliser de façon autonome. Il permet de prendre des images à hauteur stable -4m par rapport au sol-, feuilles visibles sur le dessus, avec un petit angle, au rythme de 800 photos/ha permettant un recouvrement de 100% des ceps. C'est à notre sens ce qui fait notre force car le fait d'avoir un seul outil d'acquisition nous permet d'avoir moins de difficultés liées à la qualité des images ».

**Antoine Simon, Chouette Vision**

Sur ces aspects, le Deep Learning n'est donc pas différent des autres méthodes mais il permet au moins de s'affranchir d'un certain nombre d'étapes de pré-traitements, telles que l'extraction des caractéristiques à traiter.

Notons cependant que si le Deep Learning est réputé pour fonctionner à partir de données brutes, les articles scientifiques et les témoignages indiquent pratiquement tous le recours à des actions de pré-traitement des données en vue d'une homogénéisation à l'entrée de l'algorithme ou pour une réduction de l'effort d'apprentissage en mettant en évidence des zones d'intérêt : redimensionnement (souvent réduction de la taille) des images, segmentation des images, réduction du bruit des images (suppression de pixels d'arrière-plan ou ne concernant pas des zones d'intérêt – sur la base d'indices de végétation par exemple –), conversion des couleurs... Les images satellite ou aériennes impliquent une combinaison d'étapes de prétraitement telles que l'orthorectification, la calibration et correction de terrain, la correction atmosphérique (19).

## Le Deep Learning ne fait pas de miracles !

Cela va sans dire mais pour que ces outils soient performants, il faut que les données fournies contiennent bel et bien les éléments pour parvenir à la décision !



« Si un humain est capable d'effectuer la tâche, facilement, presque sans réfléchir alors le Deep Learning pourra également donner de bons résultats. Si l'humain doit prendre un temps de réflexion, cela demandera de vérifier la faisabilité».

**Emmanuel Benazera, JoliBrain**



« On s'est rendu compte en observant les spectres de plantes atteintes de 2 maladies différentes ayant des symptômes ressemblants qu'en fait, il n'y avait pas suffisamment de différences entre les 2 maladies par rapport à la variabilité des symptômes au sein de chaque maladie. Le Deep Learning utilisé dans un contexte de classification peut être plus performant que tous les outils que l'on connaît mais si les données dont on dispose ne sont pas suffisantes pour parvenir à la décision, cela ne fonctionnera pas ! ».

**Christian Germain, Laboratoire IMS/Bordeaux Sciences Agro**



## UNE RÉFLEXION SUR LA VALEUR DES DONNÉES ET LEUR NÉCESSAIRE MUTUALISATION

En apprentissage profond, une grande partie de la valeur créée provient des données nécessaires à l'apprentissage, souvent plus que de l'algorithme. La valeur accordée aux données et la façon d'y accéder appellent à une réflexion collective, par exemple à l'échelle des filières, comme le souligne **Théo-Paul Haezebrouck**, responsable produit de la plateforme **API-AGRO** :



« En Deep learning, les technologies sont facilement accessibles et documentées (frameworks type TensorFlow et autres). Mais disposer de données annotées, en quantité suffisante, pose problème. Ces données nécessitent souvent un haut niveau d'expertise ; par exemple, pour annoter précisément des symptômes de maladies. Or, à l'échelle des filières, ces données pourraient exister : voir par exemple ce qui s'est structuré autour des bulletins de santé du végétal ou même les informations génétiques dans les filières animales. Mais il n'est pas toujours facile d'y accéder. Ma crainte est que l'IA ne perce pas en agriculture à cause de freins liés à la propriété des données et à qui en tire de la valeur (seulement celui qui implante l'algorithme ?)... C'est là où les filières ont un rôle à jouer : pour analyser précisément les besoins et la valeur qui peut être tirée des données et ensuite, pour organiser la redistribution de cette valeur. »  
**Théo-Paul Haezebrouck**

Cette problématique devrait rapidement évoluer puisque le 18/09/2018, le gouvernement a lancé un appel à manifestation d'intérêt pour la mutualisation des données pour l'IA.



## UNE VIGILANCE RENOUVELÉE PAR RAPPORT AUX SYSTÈMES D'INFORMATION .

C'est un point soulevé par plusieurs témoignages : l'importance cruciale d'un bon système d'informations pour gérer la masse de données nécessaires au fonctionnement des réseaux de neurones. Elle porte autant sur l'infrastructure matérielle, les ressources humaines mais également la bonne gestion de la propriété des données, notamment dans un contexte de Règlement Général sur la Protection des Données (voir encadré sur la Règlementation en vigueur).



« On lance des apprentissages une à deux fois par mois. On fait tourner des clusters de machines équipées chacune de 4 GPU. Chaque session prend environ une quinzaine d'heures. En recherche, nous expérimentons des techniques d'apprentissage profond distribué avec des supercalculateurs : on teste des modèles sur plusieurs milliers de nœuds, des dizaines de milliers d'images pour des centaines de milliers de classes en sortie. Evidemment nous n'en sommes pas là en production... Mais ce qu'il faut savoir c'est que la partie « Deep Learning » n'est pas la plus compliquée à gérer lors du passage à l'échelle. Ce qui l'est, c'est toute la gestion des données : mettre les données au bon endroit, avec la bonne infrastructure matérielle, qualifier les données... » **Alexis Joly**



« On s'équipe de plus en plus de machines et on fait tourner les GPU. Ça reste gérable, abordable, mais cela peut tout de même constituer un frein pour certains. Par ailleurs, on manipule vraiment beaucoup de données, qu'il faut stocker, échanger, etc. La question de l'architecture informatique et des réseaux est donc cruciale. Pour nous, c'est un point en tension. Par exemple, là où nous sommes implantés, il n'y a pas la fibre optique et cela pose un problème. » **Colin Chaballier**



## LA RÉGLEMENTATION, UN FREIN AU DEEP LEARNING ?

Comme pour toute innovation, un certain flou juridique existe encore autour du machine learning en général. Des évolutions sont en cours dans le domaine, notamment par rapport à la notion de responsabilité et d'éthique, mais des règles existent déjà et doivent être appliquées :

### > Concernant la propriété intellectuelle :

- En France, par définition un algorithme, assimilable à une formule mathématique, n'est pas protégeable par le droit de la propriété intellectuelle. Seuls des moyens de protection indirects tels que l'intégration dans un code source de logiciel est protégeable au titre du droit d'auteur, ou l'intégration dans une invention brevetable au titre du droit des brevets.
- Les « modèles » de Deep Learning sont basées sur les données. Mais à qui appartiennent les données ? L'état de la réglementation ne donne pas pour le moment de valeur intrinsèque à la donnée agricole. Ce sont les bases de données qui peuvent bénéficier de la protection juridique du droit d'auteur, sous-réserve de leur caractère nouveau (leur « originalité »).
- Au-delà de ces aspects clairement définis, il devra être mis en place un contrat précisant explicitement à qui appartiennent les résultats.

### > Concernant l'usage des données, notamment les données personnelles :

- C'est la nouvelle réglementation RGPD qui prévaut en Europe (et pour les données relevant de ressortissants européens). Elle prévoit que les personnes soient clairement informées et aient consenti à l'utilisation de leurs données pour des finalités clairement définies et que toutes les mesures nécessaires à la traçabilité, sécurité et confidentialité de ces données soient mises en œuvre. Les implications de cette réglementation telles que la nécessaire gestion des consentements, l'anonymisation des données y compris dans le cadre de très gros jeux de données, l'applicabilité des décisions qui en ont résulté peuvent être autant de freins, ou au moins points de vigilance, pour les apprentissages et les mises en production des modèles utilisant ce type de données sensibles. Prenons pour exemple des outils de prévisions de tendances de marché ou de risques pour les assurances qui se basent sur de gros volumes de données, de sources multiples, à l'échelle de plusieurs pays : il est difficile de prévoir à l'avance les données précises à collecter et l'usage qui en sera fait....

## 3.2 La puissance de calcul nécessaire au Deep Learning est-elle compatible avec l'agriculture, secteur de terrain ?

Nous l'avons vu, pendant la phase d'apprentissage des réseaux, le calcul des poids synaptiques, basé sur de multiples itérations, est extrêmement consommateur de ressources mémoire et de puissance de calcul. En phase de production (ou d'inférence), c'est-à-dire d'exécution des modèles sur de nouvelles données après l'apprentissage, des problèmes de performances et de consommation d'énergie se posent également. En effet, les systèmes doivent être en capacité de répondre rapidement, sans latence.

Pour ces deux phases, il y a deux façons d'aborder les calculs :

> **dans le cloud (internet)** : les calculs sont délocalisés sur des serveurs distants ;

> **en embarqué** : les données sont traitées en local (sur le tracteur, le drone, le robot, le smartphone...).

Chaque approche a ses avantages et inconvénients.

Un traitement dans le cloud permet d'accéder à une puissance de calcul et une mémoire sans limites réelles. Par contre, cela se fait au prix d'un lien constant avec des serveurs distants et pose donc d'éventuels délais de traitement (latence), quand ce ne sont pas des problèmes d'accès internet ou de débit. Par ailleurs, les services cloud sont souvent hébergés à l'étranger, et n'offrent pas toujours des garanties de sécurité ou d'intégrité des données manipulées. Ceci peut être délicat lorsqu'il est question de données sensibles (notamment de données personnelles) et impliquer d'avoir à gérer en plus des systèmes de cryptage des données, de gestion des consentements, etc.



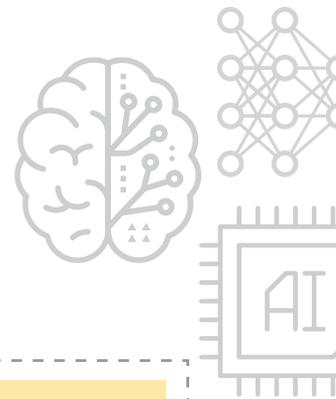
« Quand nous utilisons des données de la déclaration PAC, pas de souci pour les données de types occupation du sol qui sont déjà en libre accès pour tous. Ce qui peut être sensible ce sont les données liées à la propriété : qui possède quelle parcelle ? Ces données pourraient être facilement utilisées en interne car l'ASP et l'IGN en disposent. Par contre, si nous utilisons des services Cloud (calculs et hébergement des données sur des serveurs distants), comme cela est prévu dans le cadre du programme Copernicus DIAS (Data and Information Access Services), il peut être plus compliqué d'utiliser à distance des données sensibles. » **Sébastien Giordano**

Des choix stratégiques doivent donc être réalisés. Ils dépendent de l'application finale, de la réglementation liée à cette application, des données à traiter et de leur degré de sensibilité, des niveaux de performances attendus... Un exemple souvent pris est le cas de la voiture autonome. Cette application nécessite une grande puissance de calcul. Toutefois, il n'est pas envisageable d'effectuer les traitements sur des serveurs distants, pour le simple fait que la latence serait désastreuse, et la réponse non garantie (que ferait la voiture si la 4G n'était plus disponible ?). Un seul paramètre (ici la garantie d'accès) peut suffire à choisir, même si ce choix pose de grandes contraintes techniques (la puissance de calcul)...

**En agriculture, où la propriété des données est un point sensible et où il est difficile d'avoir accès en permanence à internet, il peut y avoir un réel intérêt à embarquer l'intelligence...**

Mais ce n'est pas si simple... « Les algorithmes d'intelligence artificielle posent un problème de portabilité sur les systèmes embarqués ; », explique Cyrille Batarière, ingénieur en traitement d'image chez **Thales Optronics**, cité dans un article de l'Usine Nouvelle (41), « Ils augmentent les besoins de calcul par un facteur 10, alors qu'il est difficile d'accroître d'autant l'enveloppe thermique. » [l'enveloppe thermique correspond au transfert de chaleur qui doit s'opérer vers l'extérieur pour qu'un processeur, puisse fonctionner correctement]

Développer le Deep Learning en agriculture appelle donc une réflexion sur deux axes :



## PROPOSER DES ALGORITHMES OPTIMISÉS PLUS ÉCONOMES EN PUISSANCE DE CALCUL



« Pour les cas agricoles, nous avons fait le choix de l'embarqué. Ceci nous a poussé à concevoir de nouvelles structures algorithmiques bien plus économes en puissance de calcul et mémoire que la littérature scientifique ne le propose habituellement, pour des résultats au moins similaires. L'apprentissage est fait dans nos locaux, sur des machines dédiées (ayant une certaine puissance de calcul). Ce choix est essentiellement motivé par la volonté de maîtriser nos données, de ne pas les transmettre outre-atlantique par exemple. Cela pourrait être un facteur déroutant pour certains de nos clients. Et puisque nos algorithmes sont moins coûteux, la puissance de calcul nécessaire aux apprentissages est elle-même réduite. » **Gérald Germain**

Cela suppose d'être capable d'associer des compétences multiples : agronomie, data sciences, informatique et systèmes d'information, électronique,... **Il y a là un enjeu fort de coopération entre les différents acteurs.** Si tout le monde peut exploiter un réseau de neurones chez lui, proposer des solutions robustes et utilisables sur le terrain reste une affaire de spécialistes...

## DISPOSER DE COMPOSANTS « HARDWARE » ADAPTÉS AUX SPÉCIFICITÉS DE L'APPRENTISSAGE PROFOND ET AUX TÂCHES D'INFÉRENCE

De nombreux acteurs de l'intelligence artificielle s'entendent sur le fait que le développement de ce secteur passe par une nécessaire accélération matérielle, que ce soit au niveau des capteurs et objets connectés qui vont collecter la donnée ou au niveau des matériels qui vont permettre de la traiter et exécuter les calculs.

Selon la société d'études Tractica, étude citée dans un article du site L'embarqué [42], « le marché des circuits intégrés pour apprentissage profond devrait très fortement progresser entre 2017 et 2025, passant de 1,6 milliard de dollars à 66,3 milliards de dollars en l'espace de huit ans ». Le secteur qui devrait se développer le plus est celui des technologies dites de « edge computing » (technologies de périphérie) qui permettent un traitement des données par le périphérique lui-même ou par un serveur local au lieu d'être transmises à un datacenter. Ce serait déjà une évolution dans ce jeune marché de l'intelligence artificielle où à l'heure actuelle, de nombreuses entreprises utilisent des services Cloud « clés en main » proposés par Microsoft (Azure), Amazon (AWS), Google Cloud et autres gros fournisseurs de services numériques.

Les approches Deep Learning devraient également évoluer de concert avec les avancées en matière de capteurs intelligents, des capteurs capables de traiter l'information en temps réel et en local.



« Le Deep Learning apporte la capacité à traiter des données brutes (pixels, spectrogrammes...). Cela fait donc complètement sens de pouvoir associer des capteurs intelligents aux réseaux de neurones. Par exemple, grâce aux capteurs intelligents, au lieu de récupérer une image, on peut ne récupérer que les informations utiles. L'image ne sort plus de la caméra. Cela permet donc également de raisonner sur le transport de l'information, avec des flux moins volumineux ». **Guillaume Infantes**

### 3.3. Peut-on avoir confiance dans des systèmes « boîtes noires » ?

#### > Le problème de l'explicabilité / interprétabilité

Nous l'avons vu, le principe du Deep Learning repose sur le fait de fournir une énorme quantité de données (quasi) brutes en entrée d'un réseau qui va les « digérer » en leur faisant subir une série de combinaisons et transformations. Au niveau de chaque neurone, chaque calcul est très simple. Mais chaque résultat de chaque neurone est transmis à la couche suivante et plus on s'enfonce dans les couches, plus le niveau de complexité et d'abstraction devient élevé. A tel point qu'en sortie du réseau, il est extrêmement difficile, voire impossible, de comprendre ce qui s'est vraiment passé. Et ceci est d'autant plus vrai que le réseau est profond.

C'est un grand changement par rapport à l'approche classique d'écriture d'algorithmes où le code décrit les étapes de raisonnement et de traitement. Et cela peut poser problème...

En effet, si l'on ne comprend pas comment cela marche, impossible d'expliquer pourquoi cela marche ou ne marche pas.

« On est parfois surpris par des détections sur des types d'objets qui n'ont rien à voir avec les données d'entraînement ». **Elodie Pagot**

« Il y a des comportements qui peuvent paraître incompréhensibles. Tout se passe très bien sur du Merlot et d'un seul coup, sur du Grenache, la reconnaissance ne marche plus. Il y a une vraie part de mystère... » **Antoine Simon**

Si l'on ne comprend pas, difficile d'agir sur les causes pour améliorer les performances... Difficile aussi de dégager les responsabilités en cas de défaillance du système. Comment prévoir un préjudice si le résultat est lui-même imprévisible ? Comment également rassurer un client sur l'efficacité du dispositif qu'on lui vend ?

La question est particulièrement prégnante lorsque l'on sait qu'il est possible de « berner » un réseau de neurones sans que la donnée initiale n'ait été altérée de façon perceptible.



Figure 22 - Effet d'une "distorsion" appliquée à une image - Source : Christian Szegedy et al. [43]  
A gauche, l'image non altérée. A droite, l'image obtenue après ajout du bruit présenté au milieu.  
L'image de gauche est correctement classée « bus scolaire ». A droite, l'image est classée « autruche ».

D'ailleurs, de nouveaux risques apparaissent avec les réseaux de type GAN: en effet, utilisés à des fins malveillantes, ces réseaux peuvent servir à produire des « fausses » données, intentionnellement bruitées, susceptibles de venir « polluer » des bases de données « collaboratives » et ainsi diminuer la qualité des apprentissages. On commence à parler également de « malicious crowd workers », c'est-à-dire d'annotateurs malveillants sur les applications utilisant l'apprentissage réparti ou « crowd working » [44].

Aussi, dans son rapport « Donner un sens à l'intelligence artificielle pour une stratégie nationale et européenne » [45], Cédric Villani s'interroge sur l'éthique de l'IA et appelle à « ouvrir la boîte noire » : « S'inspirant du programme Explainable AI de la DARPA », [Agence américaine responsable des projets en recherche pour la Défense], « il apparaît urgent de soutenir la recherche sur l'explicabilité de l'IA en investissant les mêmes trois axes de recherche : la production de modèles plus explicables, la production d'interfaces utilisateurs plus intelligibles et la compréhension des mécanismes cognitifs à l'œuvre pour produire une explication satisfaisante. »

Face à ce problème, différents points de vue sont exprimés.

Pour les uns, ce problème d'interprétabilité est majeur et doit donner lieu à une recherche active de solutions. Plusieurs voies sont actuellement explorées en recherche : mieux expliquer les modèles, mieux expliquer les résultats, concevoir de nouveaux systèmes plus transparents [46]. Cela peut passer par la simplification des réseaux de neurones jusqu'à se rapprocher de l'interprétabilité, avec le risque de réduire leur performance [47].

Pour d'autres, il s'agit surtout d'un problème d'acceptation d'un nouveau mode de fonctionnement et il faut surtout travailler sur la notion de confiance à accorder aux systèmes.



« Oui, on travaille avec une boîte noire, mais on n'est pas dupe. Au sens où dans un certain nombre de cas, on ne sait pas forcément quelle est l'architecture idéale mais on va vers ce qui marche ou vers la simplicité des choses. On est dans un certain compromis par rapport aux objectifs fixés, les temps de calcul... » indique **Emmanuel Benazera** de l'entreprise **JoliBrain**, spécialisée dans l'intégration et la conception de systèmes basés sur l'intelligence artificielle. « Il y a une nouvelle logique à intégrer car oui, on élabore des méthodes qui proposent de remplacer du code où on peut tout expliquer par des systèmes qui peuvent aboutir à des taux d'erreurs encore importants. Mais en fait il faut distinguer différents cas :

- Ceux où, avant, il n'y avait aucune méthode satisfaisante pour arriver aux résultats, c'est le cas de systèmes très complexes avec des centaines de classes attendues en sortie par exemple. Dans ces cas-là, un taux d'erreur résiduel peut-être acceptable par rapport à rien du tout...
- Ceux où on ne confiera à la machine qu'une partie du travail, selon un système de modération. Le système sera calibré pour qu'en dessous d'un certain seuil de confiance, on repasse sur l'humain ou une autre approche. »

C'est l'idée également exprimée par Yann LeCun : il n'est pas forcément nécessaire de tout comprendre mais il y a un besoin de certifier le niveau auquel cela peut fonctionner. Le système est fiable pour une « enveloppe » correspondant aux données d'apprentissage.

#### Les axes d'évolution sur cette problématique :



### PROGRESSER DANS L'ÉVALUATION DE L'INTELLIGENCE ARTIFICIELLE...

Dans son rapport, Cédric Villani proposait que le **laboratoire national de métrologie et d'essais (LNE)** devienne « l'autorité compétente en matière d'évaluation [au sens de la métrologie] dans le domaine de l'IA, et construise les méthodes d'essais nécessaires à cette fin ». [48] C'est donc ce à quoi s'emploie déjà le LNE en travaillant sur la définition des métriques, des protocoles, des bases de données et environnements de test qui vont permettre l'évaluation. A terme, c'est la constitution de référentiels normatifs qui est visée afin d'aller jusqu'à la certification.



Pour cela, le LNE s'intéresse à deux aspects :

- **L'évaluation de la performance pour une fonctionnalité donnée :**

Il s'agit de vérifier que le système est capable de réaliser correctement la tâche pour laquelle il a été conçu.



« Sur le Challenge Rose par exemple, qui s'intéresse au désherbage robotisé dans l'intra-rang en vue de la réduction des intrants, une tâche évaluée concerne la détection automatique des mauvaises herbes et des cultures, c'est-à-dire l'identification de la classe (adventice ou culture) et du positionnement des plantes présentes sur la parcelle agricole. Nous avons donc constitué un corpus d'images présentant des adventices et des cultures qui ont ensuite été annotées par des experts et qualifiées par le LNE. L'évaluation consiste à comparer les annotations des experts (appelées références) avec les sorties (appelées hypothèses) des systèmes d'IA participant au Challenge. Dans ce cas, la métrique retenue, appelée Estimated global error rate (EGER), est un taux d'erreur qui comptabilise les oublis, les fausses alarmes et les confusions. Des analyses statistiques permettent ensuite d'analyser l'influence des facteurs environnementaux (luminosité, stades phénologiques, etc.) sur la performance des systèmes mesurée grâce à cette métrique. Des qualifications inter et intra-annotateurs permettent d'éviter les biais liés aux évaluateurs en mesurant l'accord entre ces derniers pour chaque image annotée du corpus de test. » **Guillaume Avrin, LNE**

- **L'évaluation de la robustesse dans le cadre d'environnements ouverts et changeants.**

En agriculture, l'évaluation de systèmes robotisés, notamment des véhicules autonomes, est complexe car il s'agit essentiellement d'apprécier la capacité de ces systèmes à s'adapter à des environnements changeants. Enormément de facteurs peuvent entrer en compte et il faut définir « de nouvelles métriques, généralement composites et multidimensionnelles ». Aussi, pour ce type d'évaluation, le LNE utilisera des environnements de simulation, comme ceux déjà utilisés en industrie automobile.



« La difficulté pour la certification est qu'il n'existe pas encore de référentiel normatif, ni même de consensus au sein de la communauté de l'IA concernant ce que pourrait être ces référentiels. Par ailleurs, se pose la question du moment où il faut certifier : par définition, les systèmes IA sont adaptatifs puisque dotés d'une capacité d'apprentissage. Ils évoluent sans arrêt. Peut-on considérer qu'une certification donnée est toujours valable lorsque le système a évolué ? Faut-il le certifier à nouveau, tous les 10 jours, tous les mois, tous les ans ? » **Guillaume Avrin, LNE**

Autre problème à résoudre : pouvoir qualifier le niveau d'éthique d'un système IA, notion particulièrement mise en avant par Cédric Villani. Dans ce cadre, le rôle du LNE sera de traduire en éléments mesurables les règles définies par les instances compétentes (Cnil, Cerna, etc.). Il y a aujourd'hui de fortes volontés gouvernementales de progresser sur ces sujets.

## COMBINER LES APPROCHES...



Autre perspective : on entend aujourd'hui parler de travaux allant dans le sens d'une **intelligence artificielle hybride** c'est à dire capable de mixer différentes approches, d'utiliser l'apprentissage machine à partir de données et de modèles permettant d'exprimer des contraintes et d'effectuer des raisonnements logiques. C'est par exemple l'ambition du projet **ANITI (Artificial and Natural Intelligence Toulouse Institute)** déposé par un collectif d'acteurs toulousains (de la recherche, de l'entreprise, du monde associatif...) en réponse à l'appel à manifestation d'intérêt issu du rapport Villani (49). Les communiqués de presse précisent ainsi : « En favorisant l'interdisciplinarité, cet institut permettra la confrontation d'approches différentes d'un même problème, pour trouver des solutions nouvelles, grâce à des regards complémentaires ». « Cette approche permettra d'apporter de meilleures garanties en termes de fiabilité et de capacité d'expliquer et d'interpréter les résultats des algorithmes utilisés, tout en veillant à l'acceptabilité sociale et la viabilité économique ». Notons que l'entreprise **Syngenta** fait partie des partenaires de ce projet, qui annonce des ambitions en matière de Smart agriculture.

### 3.4. Le Deep Learning est-il un phénomène de mode ?

Comme évoqué dès notre introduction, l'**institut Gartner** place le Deep Learning tout en haut de sa courbe du « Hype des technologies émergentes », ce qui tendrait à laisser penser qu'il va probablement passer par une phase de désintérêt ou de désillusion... Pourtant, et avec tout le manque d'objectivité que l'on pourrait reprocher à des acteurs actuellement impliqués dans l'utilisation de ces technologies, nous n'avons pas ressenti cette réserve auprès des différents interlocuteurs interrogés au cours de notre étude.



« A priori, nous allons continuer à être de gros utilisateurs de Deep Learning car nous n'avons plus de doute sur l'intérêt de ces technologies ».

**Alexis Joly**



« On se demande de toute façon comment on pourrait s'en passer aujourd'hui. On a travaillé pendant des années à optimiser nos méthodes, à trouver comment extraire les caractéristiques des images pour définir des meilleurs classifieurs et ces outils remettent soudain tout en cause en proposant des approches bien plus performantes... »

**Christian Germain**

Pour autant, comme pour toute technologie, l'utilisation des approches Deep Learning doit résulter d'un choix éclairé et raisonné. Il y a évidemment des situations où elles pourraient ne pas être pertinentes. Outre le problème d'accès aux données déjà évoqué, elles pourraient ne pas être adaptées par exemple :

- Si la capacité d'interprétation des résultats ou l'établissement d'un mécanisme de causalité est **essentiel**.

Nous l'avons vu, à l'heure actuelle, les approches Deep Learning pêchent encore par leur côté « Boîte noire ». Même si des progrès sont attendus en la matière, mieux vaut choisir d'autres méthodes si la relation entre les données d'entrée et le résultat doit être explicable et communiquée aux utilisateurs.

- Si les conditions de temps, de budget, d'infrastructure ou de **compétences** ne sont pas réunies et le retour sur investissement non garanti.

Dans un article de blog (50), Pablo Cordero, un « hyperparamètreur » c'est-à-dire une personne qui travaille sur l'optimisation des réseaux de neurones explique : « Les réseaux profonds sont des modèles très flexibles, avec une multitude d'architectures et de types de nœuds, de stratégies de régularisation et d'optimisation. Selon l'application, votre modèle peut avoir des couches convolutives (quelle largeur ? Avec quelle opération de regroupement ?) ou une structure récurrente (avec ou sans déclenchement ?); il peut être très profond [...] ou avec seulement quelques couches cachées (avec combien d'unités ?); il peut utiliser des unités linéaires de rectification ou d'autres fonctions d'activation...[...] Ce sont beaucoup d'hyperparamètres à peaufiner et d'architectures à explorer. ». Tout cela prend du temps. La collecte des données, l'apprentissage, les tests prennent du temps. Les approches Deep Learning, même si elles progressent à grands pas, sont coûteuses à mettre en place. Il est donc nécessaire d'étudier le retour sur investissement. S'il n'est pas garanti et si des méthodes plus simples et déjà performantes existent alors il n'est pas forcément utile de s'engager sur les approches Deep Learning.

Pour autant, les approches Deep Learning semblent déjà bien implantées dans de très nombreux domaines, dont l'agriculture, et vont continuer à progresser dans les années à venir. Mais l'évolution sera peut-être moins spectaculaire du point de vue du grand public.



« Jusqu'ici, on a récolté les fruits qui pendaient de l'arbre ! Ce sont les applications évidentes qui ont été explorées. Les réseaux profonds sont des outils très génériques, de bas niveau. Il faut s'attendre à ce que cela devienne un standard. L'étape suivante sera de les utiliser dans des applications de niveau élevé, en mode presse-bouton ». **Emmanuel Benazera et Guillaume Infantes**

Pour le moment, le Deep Learning n'en est encore qu'à ses débuts...



« Certains sujets sont complexes. On avance pas à pas, on dégrossit, on lève des verrous. Chaque jour, 4 à 5 personnes de l'équipe travaillent sur les problèmes d'apprentissage. Il y a plein de façons de « titiller » les algorithmes. On ne peut vraiment parler de science exacte. L'apprentissage machine, c'est comme de la cuisine, pour tenter une métaphore. Il faut les bons ingrédients (les bonnes « data »), trouver le bon accompagnement (la bonne architecture...), les bons outils de cuisson (les bons algorithmes), les bons cuisiniers (les data scientists, les ingénieurs)... Quand on a la bonne recette, il faut encore l'exploiter, produire. Et à ce moment, des problèmes peuvent encore survenir et il faut revoir la recette... » **Colin Chaballier**

## On retient :

Le Deep Learning ouvre les horizons pour de nouveaux usages ou des gains de performances par rapport aux méthodes actuelles. Mais dans le domaine de l'agriculture, comme ailleurs, de nombreuses questions demeurent et constituent autant de sujets de recherche et d'axes d'amélioration. Par exemple, en matière de :

- Structuration, mutualisation et accès aux bases de données d'apprentissage,
- D'adaptation des systèmes d'information,
- De réglementation et de régulation,
- D'évolution des composants matériels,
- D'évaluation voire de certification des dispositifs,
- D'explicitabilité en vue d'une meilleure acceptabilité,
- De capacité à travailler de façon interdisciplinaire.



# CONCLUSION

Qu'ils sont donc prometteurs ces nouveaux outils et méthodes d'apprentissage automatique qui, depuis plusieurs années déjà, viennent enrichir le très vaste domaine de l'Intelligence Artificielle ! Grâce aux progrès matériels et à l'accès facilité à de grandes bases de données d'apprentissage, les réseaux de neurones artificiels peuvent aujourd'hui être utilisés dans des architectures profondes pour appréhender des problèmes toujours plus complexes.

En Agriculture, le Deep Learning est déjà largement exploré et promet de nouvelles réponses aux questions posées par le travail avec et pour le vivant :

- des solutions pour mieux suivre et prévoir les évolutions des facteurs de productions (rendements, apparition de maladies ou de ravageurs, suivi de l'alimentation et de l'état de santé des animaux, maintenance du matériel ...)
- des solutions pour limiter l'impact environnemental, pallier le manque de main d'œuvre ou réduire la pénibilité du travail, en association avec les objets connectés, la robotique et le machinisme agricoles ;
- des solutions d'assistance au quotidien et d'aide à la décision pour simplifier la vie des agriculteurs et de leurs conseillers...

Déjà nombreux et donnant lieu à des solutions commerciales, notamment pour ce qui concerne la vision par ordinateur, les cas d'usages devraient encore s'étendre sous l'impulsion d'une politique gouvernementale volontaire, d'une recherche active et de nouveaux progrès matériels.

**A terme, les approches Deep Learning vont probablement devenir des standards, utilisés pour des applications de niveau toujours plus élevé. Mais pour le moment, nous n'en sommes encore qu'au tout début...**

Reposant sur l'utilisation massive de données pour l'apprentissage, ces technologies posent la question de la mutualisation et de la circulation des données agricoles. C'est un nouveau système d'information qui doit se structurer, à différentes échelles.

Puissantes, ces technologies sont également mystérieuses. Il est difficile à l'heure actuelle d'en justifier les résultats. Le travail autour de l'explicabilité, de la confiance à accorder à ces systèmes, de leur réglementation constitue un enjeu majeur pour leur adoption et exigera des collaborations interdisciplinaires...

Comme pour toute innovation de rupture, le développement du Deep Learning en particulier, et de l'intelligence artificielle en général, appellent encore bien des évolutions dans différents domaines.

Parce que les technologies de l'intelligence artificielle peuvent susciter questions et craintes, leur adoption reposera en grande partie sur le bon accompagnement des agriculteurs. Il s'agit donc d'un sujet que la Chaire AgroTIC continuera à suivre...



Nathalie TOULON  
Chaire AgroTIC  
Les Etudes d'Opportunité

Contact : [nathalie.toulon@agro-bordeaux.fr](mailto:nathalie.toulon@agro-bordeaux.fr)



# RÉFÉRENCES

- 1. LECUN, Yann.** Qu'est-ce que l'intelligence artificielle ? [en ligne]. Disponible à l'adresse : [https://www.college-de-france.fr/media/yann-lecun/UPL4485925235409209505\\_Intelligence\\_Artificielle\\_\\_\\_\\_\\_Y\\_LeCun.pdf](https://www.college-de-france.fr/media/yann-lecun/UPL4485925235409209505_Intelligence_Artificielle_____Y_LeCun.pdf)
- 2. FRANCE INTE. La quête du Graal des chercheurs en intelligence artificielle.** France Inter [en ligne]. [Consulté le 31 août 2018]. Disponible à l'adresse : <https://www.franceinter.fr/emissions/c-est-deja-demain/c-est-deja-demain-24-janvier-2018>
- 3. TUAL, Morgane.** Le « deep learning », une révolution dans l'intelligence artificielle. Le Monde.fr [en ligne]. 24 juillet 2015. [Consulté le 10 octobre 2018]. Disponible à l'adresse : [https://www.lemonde.fr/pixels/article/2015/07/24/comment-le-deep-learning-revolutionne-l-intelligence-artificielle\\_4695929\\_4408996.html](https://www.lemonde.fr/pixels/article/2015/07/24/comment-le-deep-learning-revolutionne-l-intelligence-artificielle_4695929_4408996.html)
- 4. PIRON, Alexis, DUMONT, Benjamin et DESTAIN, Marie-France.** La vision artificielle est une méthode d'avenir pour la reconnaissance automatisée des plantes adventices. BASE [en ligne]. 1 janvier 2011. [Consulté le 22 octobre 2018]. Disponible à l'adresse : <https://popups.uliege.be/443/1780-4507/index.php?id=8040>
- 5. ONU DAES.** La population mondiale devrait atteindre 9,8 milliards en 2050 et 11,2 milliards en 2100, selon l'ONU. ONU DAES | Nations Unies Département des affaires économiques et sociales [en ligne]. 21 juin 2017. [Consulté le 24 octobre 2018]. Disponible à l'adresse : <https://www.un.org/development/desa/fr/news/population/world-population-prospects-2017.html>
- 6. GAGNÉ, Christian.** Perceptron multicouche - Apprentissage et reconnaissance – GIF-4101 / GIF-7005 (Support de cours) [en ligne]. novembre 2016. Université de Laval. Disponible à l'adresse : <http://vision.gel.ulaval.ca/~cgagne/enseignement/apprentissage/A2016/presentations/ar-sem12-pmc.pdf>
- 7. THELLIEZ, Thomas.** Part 5 : Réseaux de neurones : la fonction d'activation sigmoïde. Rocket Bootstrapper - L'Intelligence Artificielle pour tous pas à pas [en ligne]. 16 avril 2018. [Consulté le 7 octobre 2018]. Disponible à l'adresse : <https://rocketbootstrapper.com/fr/reseaux-de-neurones-fonction-activation-sigmoïde/>
- 8. INDESCIENCES.COM.** [Interview] Qu'est-ce que le deep learning ? par Pascal Vincent. Indesciences [en ligne]. 10 décembre 2015. [Consulté le 7 octobre 2018]. Disponible à l'adresse : [http://www.indesciences.com/interview-quest-ce-que-le-deep-learning-par-pascal-vincent/Rencontre\\_avec\\_Pascal\\_Vincent\\_enseignant-chercheur\\_à\\_l'Université\\_de\\_Montréal\\_autour\\_de\\_l'Intelligence\\_Artificielle\\_et\\_du\\_deep\\_learning](http://www.indesciences.com/interview-quest-ce-que-le-deep-learning-par-pascal-vincent/Rencontre_avec_Pascal_Vincent_enseignant-chercheur_à_l'Université_de_Montréal_autour_de_l'Intelligence_Artificielle_et_du_deep_learning)
- 9. BESSE, Philippe.** Réseaux de neurones [en ligne]. [Consulté le 8 octobre 2018]. Disponible à l'adresse : <https://www.math.univ-toulouse.fr/~besse/Wikistat/pdf/st-m-app-rn.pdf>
- 10. RANÇON, Florian.** Le projet Advantage : des solutions pour gérer les maladies du bois de la vigne - Présentation #EsaConnect. Les RDV de l'Agriculture Connectée #EsaConnect. 21 novembre 2018.
- 11. LECUN, Yann.** L'apprentissage profond (Cours). [en ligne]. [Consulté le 24 octobre 2018]. Disponible à l'adresse : <https://www.college-de-france.fr/site/yann-lecun/course-2015-2016.htm>
- 12. OLAH, Christopher.** Understanding LSTM Networks -- colah's blog. Colah's blog [en ligne]. [Consulté le 17 octobre 2018]. Disponible à l'adresse : <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- 13. CROUSPEYRE, Charles.** Comment les Réseaux de neurones récurrents et Long Short-Term Memory fonctionnent. Medium [en ligne]. 10 octobre 2017. [Consulté le 27 août 2018]. Disponible à l'adresse : <https://medium.com/@CharlesCrouspeyre/comment-les-r%C3%A9seaux-de-neurones-%C3%A0-convolution-fonctionnent-c25041d45921>
- 14. ANDREJ, Karpathy.** The Unreasonable Effectiveness of Recurrent Neural Networks. Andrej Karpathy Blog [en ligne]. 21 mai 2015. [Consulté le 17 octobre 2018]. Disponible à l'adresse : <http://karpathy.github.io/2015/05/21/rnn-effectiveness/>
- 15. BUSINESS WIRE.** AI in Agriculture Market 2017-2025 - Focus on Precision Farming, Drone Analytics, Agriculture Robots & Livestock Monitoring - Research and Markets. [en ligne]. 21 décembre 2017. [Consulté le 6 juillet 2018]. Disponible à l'adresse : <https://www.businesswire.com/news/home/20171221005505/en/AI-Agriculture-Market-2017-2025---Focus-PrecisionThe>
- 16. LIAKOS, Konstantinos G., BUSATO, Patrizia, PEARSON, Simon, BOCHTIS, Dionysis et MOSHOU, Dimitrios.** Machine learning in Agriculture : a review. Sensors. août 2018.
- 17. ZHU, Nanyang, LIU, Xu, LIU, Ziqian, HU, Kai, WANG, Yingkuan, TAN, Jinglu, HUANG, Min, ZHU, Qibing, JI, Xunsheng, JIANG, Yongnian et GUO, Ya.** Deep learning for smart agriculture: Concepts, tools, applications, and opportunities. International Journal of Agricultural and Biological Engineering. 8 août 2018. Vol. 11, n° 4, pp. 32-44. DOI 10.25165/ijabe.v11i4.4475.
- 18. TANG, JingLei, WANG, Dong, ZHANG, ZhiGuang, HE, LiJun, XIN, Jing et XU, Yang.** Weed identification based on K-means feature learning combined with convolutional neural network. Computers and Electronics in Agriculture. 1 avril 2017. Vol. 135, pp. 63-70. DOI 10.1016/j.compag.2017.01.001.
- 19. KAMILARIS, Andreas et PRENAFETA-BOLDÚ, Francesc X.** Deep learning in agriculture: A survey. Computers and Electronics in Agriculture. 2018. Vol. 147, pp. 70-90. DOI 10.1016/j.compag.2018.02.016.
- 20. JABR, Ferris.** Fowl Language: AI Decodes the Nuances of Chicken « Speech ». Scientific American [en ligne]. [Consulté le 2 novembre 2018]. Disponible à l'adresse : <https://www.scientificamerican.com/article/fowl-language-ai-decodes-the-nuances-of-chicken-ldquo-speech-rdquo/How-machine-learning-can-translate-chicken-chatter-and-improve-farming>
- 21. DEMMERS, Theo, CAO, Yi, J PARSONS, David, GAUSS, Sophie et M WATHES, Christopher.** Simultaneous Monitoring and Control of Pig Growth and Ammonia Emissions. In : ASABE - 9th International Livestock Environment Symposium 2012, ILES 2012. [en ligne]. 2012. [Consulté le 2 novembre 2018]. Disponible à l'adresse : [https://www.researchgate.net/publication/271428577\\_Simultaneous\\_Monitoring\\_and\\_Control\\_of\\_Pig\\_Growth\\_and\\_Ammonia\\_Emissions](https://www.researchgate.net/publication/271428577_Simultaneous_Monitoring_and_Control_of_Pig_Growth_and_Ammonia_Emissions)
- 22. RIVAS, Alberto, CHAMOSO, Pablo, GONZÁLEZ-BRIONES, Alfonso et CORCHADO, Juan Manuel.** Detection of Cattle Using Drones and Convolutional Neural Networks. Sensors (Basel, Switzerland) [en ligne]. 27 juin 2018. Vol. 18, n° 7. [Consulté le 3 novembre 2018]. DOI 10.3390/s18072048. Disponible à l'adresse : <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6068661/>
- 23. KUMAR, Santosh (et al.).** Deep Learning Framework for Recognition of Cattle using Muzzle Point Image Pattern. [en ligne]. octobre 2017. [Consulté le 3 novembre 2018]. DOI 10.1016/j.measurement.2017.10.064. Disponible à l'adresse : [https://www.researchgate.net/publication/320686855\\_Deep\\_Learning\\_Framework\\_for\\_Recognition\\_of\\_Cattle\\_using\\_Muzzle\\_Point\\_Image\\_Pattern](https://www.researchgate.net/publication/320686855_Deep_Learning_Framework_for_Recognition_of_Cattle_using_Muzzle_Point_Image_Pattern)
- 24. FUTURA.** L'intelligence artificielle au secours des éleveurs de cochons chinois. Futura [en ligne]. [Consulté le 3 novembre 2018]. Disponible à l'adresse : <https://www.futura-sciences.com/tech/actualites/intelligence-artificielle-intelligence-artificielle-secours-eleveurs-cochons-chinois-70226/>
- 25. TOMAZ, Carolina.** Comment Alibaba veut mettre l'agriculture à l'heure de l'intelligence artificielle. FrenchWeb.fr [en ligne]. 7 juin 2018. [Consulté le 12 juin 2018]. Disponible à l'adresse : <https://www.frenchweb.fr/comment-alibaba-veut-mettre-lagriculture-a-lheure-de-lintelligence-artificielle/327497>
- 26. RÉUSSIRPORC.** L'intelligence artificielle entre dans les élevages. RéussirPorc n°261 - Septembre 2018. septembre 2018. pp. P64-65.
- 27. NAKASHIMA, Ryan.** L'intelligence artificielle se porte au secours des éleveurs de bovins. HuffPost Québec [en ligne]. 20 avril 2018. [Consulté le 3 novembre 2018]. Disponible à l'adresse : [https://quebec.huffingtonpost.ca/2018/04/20/lintelligence-artificielle-se-porte-au-secours-des-eleveurs-de-bovins\\_a\\_23416641/](https://quebec.huffingtonpost.ca/2018/04/20/lintelligence-artificielle-se-porte-au-secours-des-eleveurs-de-bovins_a_23416641/)



- 28. FOUQUET, Claude.** En Corée, l'intelligence artificielle débarque dans les poulaillers. lesechos.fr [en ligne]. 23 mai 2018. [Consulté le 3 novembre 2018]. Disponible à l'adresse : <https://www.lesechos.fr/tech-medias/hightech/0301710102086-en-coree-lintelligence-artificielle-debarque-dans-les-poulaillers-2177972.php#Xtor=AD-6000>
- 29. KNAPP, Alex.** This Startup Is Raising \$3.5 Million To Add Machine Learning To Fish Farms. Forbes [en ligne]. [Consulté le 3 novembre 2018]. Disponible à l'adresse : <https://www.forbes.com/sites/alexknapp/2018/01/30/this-startup-is-raising-3-5-million-to-add-machine-learning-to-fish-farms/>
- 30. HENNO, Jacques.** Bilberry crée des algorithmes capables de cibler le désherbage. lesechos.fr [en ligne]. 5 septembre 2018. [Consulté le 7 novembre 2018]. Disponible à l'adresse : <https://www.lesechos.fr/pme-regions/innovateurs/0302180553620-bilberry-cree-des-algorithmes-capables-de-cibler-le-desherbage-2202597.php#Xtor=AD-6000>
- 31. JULIEN, Cécile (Terre-Net).** Robot de désherbage Débuts prometteurs en grandes cultures pour Ecorobotix. Terre-net [en ligne]. [Consulté le 10 novembre 2018]. Disponible à l'adresse : <https://www.terre-net.fr/partenaire/innovation-et-technologie/article/debuts-prometteurs-en-grandes-cultures-pour-ecorobotix-2894-133739.html>
- 32. FRESHPLAZA.** AI is already changing agricultural landscape. [en ligne]. [Consulté le 5 novembre 2018]. Disponible à l'adresse : [www.freshplaza.com/article/9038874/ai-is-already-changing-agricultural-landscape/](http://www.freshplaza.com/article/9038874/ai-is-already-changing-agricultural-landscape/)
- 33. MADEC, Simon, JIN, Xiuliang, LU, Hao, DE SOLAN, Benoit, DUyme, Florent, HERITIER, Emmanuelle et BARET, Frédéric.** Ear density estimation from high resolution RGB imagery using deep learning technique. *Agricultural and Forest Meteorology* 264:225-234 [en ligne]. janvier 2019. [Consulté le 1 novembre 2018]. DOI DOI: 10.1016/j.agrformet.2018.10.013. Disponible à l'adresse : [https://www.researchgate.net/publication/328512173\\_Ear\\_density\\_estimation\\_from\\_high\\_resolution\\_RGB\\_imagery\\_using\\_deep\\_learning\\_technique](https://www.researchgate.net/publication/328512173_Ear_density_estimation_from_high_resolution_RGB_imagery_using_deep_learning_technique)
- 34. KUSSUL, Nataliia, LAVRENIUK, Mykola, SKAKUN, Sergii et SHELESTOV, Andrii.** Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data. *IEEE Geoscience and Remote Sensing Letters* PP(99):1-5 [en ligne]. mars 2017. [Consulté le 4 novembre 2018]. DOI 10.1109/LGRS.2017.2681128. Disponible à l'adresse : [https://www.researchgate.net/publication/315939269\\_Deep\\_Learning\\_Classification\\_of\\_Land\\_Cover\\_and\\_Crop\\_Types\\_Using\\_Remote\\_Sensing\\_Data](https://www.researchgate.net/publication/315939269_Deep_Learning_Classification_of_Land_Cover_and_Crop_Types_Using_Remote_Sensing_Data)
- 35. INCE, T., KIRANYAZ, S., EREN, L., ASKAR, M. et GABBOUJ, M.** Real-Time Motor Fault Detection by 1-D Convolutional Neural Networks. *IEEE Transactions on Industrial Electronics*. novembre 2016. Vol. 63, n° 11, pp. 7067-7075. DOI 10.1109/TIE.2016.2582729.
- 36. VIMOND, Ludovic.** New Holland décline son tracteur autonome pour la vigne. Réussir Machinisme [en ligne]. février 2018. [Consulté le 10 novembre 2018]. Disponible à l'adresse : <http://machinisme.reussir.fr/le-new-holland-nhdrive-decline-en-tracteur-specialise>
- 37. DUQUEF, Sébastien (Terre-Net Media).** Tracteur autonome Case IH Enfin des essais grandeur nature ! Terre-net [en ligne]. [Consulté le 10 novembre 2018]. Disponible à l'adresse : <https://www.terre-net.fr/materiel-agricole/tracteur-quad/article/en-route-pour-des-essais-grandeur-nature-207-136392.html>
- 38. ZHANG, Zhiqiang, ZHAO, Yi, LIAO, Xiangke, SHI, Wenqiang, Li, Kenli, ZOU, Quan et PENG, Shaoliang.** Deep learning in omics: a survey and guideline. *Briefings in Functional Genomics* [en ligne]. [Consulté le 19 novembre 2018]. DOI 10.1093/bfgp/ely030. Disponible à l'adresse : <https://academic.oup.com/bfgp/advance-article/doi/10.1093/bfgp/ely030/5107348>
- 39. RAJ, Bharath.** Data Augmentation | How to use Deep Learning when you have Limited Data – Part 2. Medium [en ligne]. 11 avril 2018. [Consulté le 31 octobre 2018]. Disponible à l'adresse : <https://medium.com/nanonets/how-to-use-deep-learning-when-you-have-limited-data-part-2-data-augmentation-c26971dc8ced>
- 40. ANTONIOU, Antreas, STORKEY, Amos et EDWARDS, Harrison.** Data Augmentation Generative Adversarial Networks. arXiv:1711.04340 [cs, stat] [en ligne]. 12 novembre 2017. [Consulté le 31 octobre 2018]. Disponible à l'adresse : <http://arxiv.org/abs/1711.04340arXiv: 1711.04340>
- 41. LOUKIL, Ridha (L'Usine Nouvelle).** La filière des systèmes embarqués face à la révolution de l'intelligence artificielle - Systèmes embarqués. [en ligne]. 27 novembre 2017. [Consulté le 5 novembre 2018]. Disponible à l'adresse : <https://www.usinenouvelle.com/article/la-filiere-des-systemes-embarques-face-a-la-revolution-de-l-intelligence-artificielle.N619118>
- 42. ARLLOT, Pierrick (L'embarqué).** Intelligence artificielle : le marché des circuits pour « deep learning » multiplié par 40 d'ici à 2025 ? [en ligne]. mai 2018. [Consulté le 5 novembre 2018]. Disponible à l'adresse : [http://www.l'embarque.com/intelligence-artificielle-le-marche-des-circuits-pour-deep-learning-multiplie-par-40-dici-a-2025\\_007578](http://www.l'embarque.com/intelligence-artificielle-le-marche-des-circuits-pour-deep-learning-multiplie-par-40-dici-a-2025_007578)
- 43. SZEGEDY, Christian, ZAREMBA, Wojciech, SUTSKEVER, Ilya, BRUNA, Joan, ERHAN, Dumitru, GOODFELLOW, Ian et FERGUS, Rob.** Intriguing properties of neural networks. arXiv:1312.6199 [cs] [en ligne]. 20 décembre 2013. [Consulté le 19 novembre 2018]. Disponible à l'adresse : <http://arxiv.org/abs/1312.6199>
- 44. ROLI, Fabio et BIGGIO, Battista.** Wild Patterns : Half-day Tutorial on Adversarial Machine Learning. ECCV 2018, European Conference on Computer Vision, Sept. 8, Munich, Germany [en ligne]. septembre 2018. [Consulté le 13 novembre 2018]. Disponible à l'adresse : <https://www.pluribus-one.it/sec-ml/wild-patterns>
- 45. VILLANI, Cédric.** Donner un sens à l'intelligence artificielle pour une stratégie nationale et européenne [en ligne]. 2018. ISBN 978-2-11-145708-9. Disponible à l'adresse : [https://www.aiforhumanity.fr/pdfs/9782111457089\\_Rapport\\_Villani\\_accessible.pdf](https://www.aiforhumanity.fr/pdfs/9782111457089_Rapport_Villani_accessible.pdf)
- 46. BHATIA, Richa.** Deep Learning Is Not So Much A Black Box Anymore, And That's A Great Development. *Analytics India Magazine* [en ligne]. 23 août 2018. [Consulté le 22 octobre 2018]. Disponible à l'adresse : <https://www.analyticsindiamag.com/deep-learning-is-not-so-much-a-black-box-anymore-and-thats-a-great-development/>
- 47. BELLIN, Isabelle.** L'explicabilité des algos : une affaire de compromis. *Data Analytics Post* [en ligne]. 29 mars 2018. [Consulté le 13 novembre 2018]. Disponible à l'adresse : <https://dataanalyticspost.com/lexplicabilite-des-algos-une-affaire-de-compromis/>
- 48. AVRIN, Guillaume, DELABORDE, Agnès et GALIBERT, Olivier.** Évaluer les intelligences artificielles. *Data Analytics Post* [en ligne]. 13 septembre 2018. [Consulté le 13 novembre 2018]. Disponible à l'adresse : [https://dataanalyticspost.com/evaluer-les-intelligences-artificielles/11minAuteurs : Guillaume Avrin, Agnès Delaborde, Olivier Galibert \(Evaluation des systèmes d'intelligence artificielle, LNE\) Contact : guillaume.avrin@lne.fr Le Laboratoire national de métrologie et d'essais \(LNE\) a été proposé comme organisme de référence pour évaluer les systèmes d'intelligence artificielle \(IA\) en ...](https://dataanalyticspost.com/evaluer-les-intelligences-artificielles/11minAuteurs : Guillaume Avrin, Agnès Delaborde, Olivier Galibert (Evaluation des systèmes d'intelligence artificielle, LNE) Contact : guillaume.avrin@lne.fr Le Laboratoire national de métrologie et d'essais (LNE) a été proposé comme organisme de référence pour évaluer les systèmes d'intelligence artificielle (IA) en ...)
- 49. MONDEDESGRANDESECOLES.FR.** Toulouse au coeur de l'IA en France. Monde des grandes écoles et universités [en ligne]. 11 octobre 2018. [Consulté le 13 novembre 2018]. Disponible à l'adresse : <http://www.monde-des-grandes-ecoles.fr/aniti-toulouse-au-coeur-de-lintelligence-artificielle-en-france/>
- 50. CORDERO, Pablo.** When not to use deep learning. [en ligne]. juillet 2017. [Consulté le 14 novembre 2018]. Disponible à l'adresse : <https://www.kdnuggets.com/2017/07/when-not-use-deep-learning.html/2>, <https://www.kdnuggets.com/2017/07/when-not-use-deep-learning.html>
- 51. TSANG, S. H.** Review: AlexNet, CaffeNet — Winner of ILSVRC 2012 (Image Classification). Medium [en ligne]. 9 août 2018. [Consulté le 10 octobre 2018]. Disponible à l'adresse : <https://medium.com/coinmonks/paper-review-of-alexnet-caffenet-winner-in-ilsvrc-2012-image-classification-b93598314160>



## Les Études d'Opportunité

Contact : **Nathalie Toulon**,

[nathalie.toulon@agro-bordeaux.fr](mailto:nathalie.toulon@agro-bordeaux.fr)



Retrouvez toute l'actualité  
de la Chaire AgroTIC sur :

[www.agrotic.org](http://www.agrotic.org)