

Utilisation de l'IA en agriculture : opportunité, réalités et limites

Préparé par Samuel Foucher; présenté par Yacine Bouroubi

Université de Sherbrooke
Département de Géomatique appliquée

Contributeurs: Étienne Lord, Yacine Bouroubi, Mickael Germain, Ramata Magagi

Samuel Foucher, Professeur

Département de géomatique appliquée



- Chercheur membre du CARTEL (Centre d'applications et de recherches en télédétection)
- Chercheur associé au CRIM (Centre de recherche informatique de Montréal)



<https://cartel.recherche.usherbrooke.ca/samuel-foucher/>



samuel.foucher@usherbrooke.ca

• Formation:

- Maîtrise en physique
- Ingénieur en télécommunications (France) - Spécialisation traitement d'images
- Doctorat en télédétection (UdS) - Traitement d'images SAR

• Parcours:

- Chercheur senior au CRIM
- Directeur de l'équipe Vision et imagerie au CRIM (2013-2019)

Science des données géospatiales



- **Expertises:**
 - Télédétection, SAR, forage des données, apprentissage automatique, traitement d'image, plateformes, fusion de données
- **Intérêts de recherche:**
 - Applications de l'apprentissage profond en observation de la terre et aux sciences de l'environnement:
 - Recensement faunique
 - Agriculture de précision
 - Application des réseaux de neurones sur des graphes en géomatique
 - *Quantum Machine Learning*
 - Apprentissage machine basé sur la physique (*Physics-informed Machine Learning*)
- **Infrastructure géospatiale:**
 - Manipulation des mégadonnées en infonuagique
 - Plateforme pour l'annotation des données

Département de géomatique appliquée

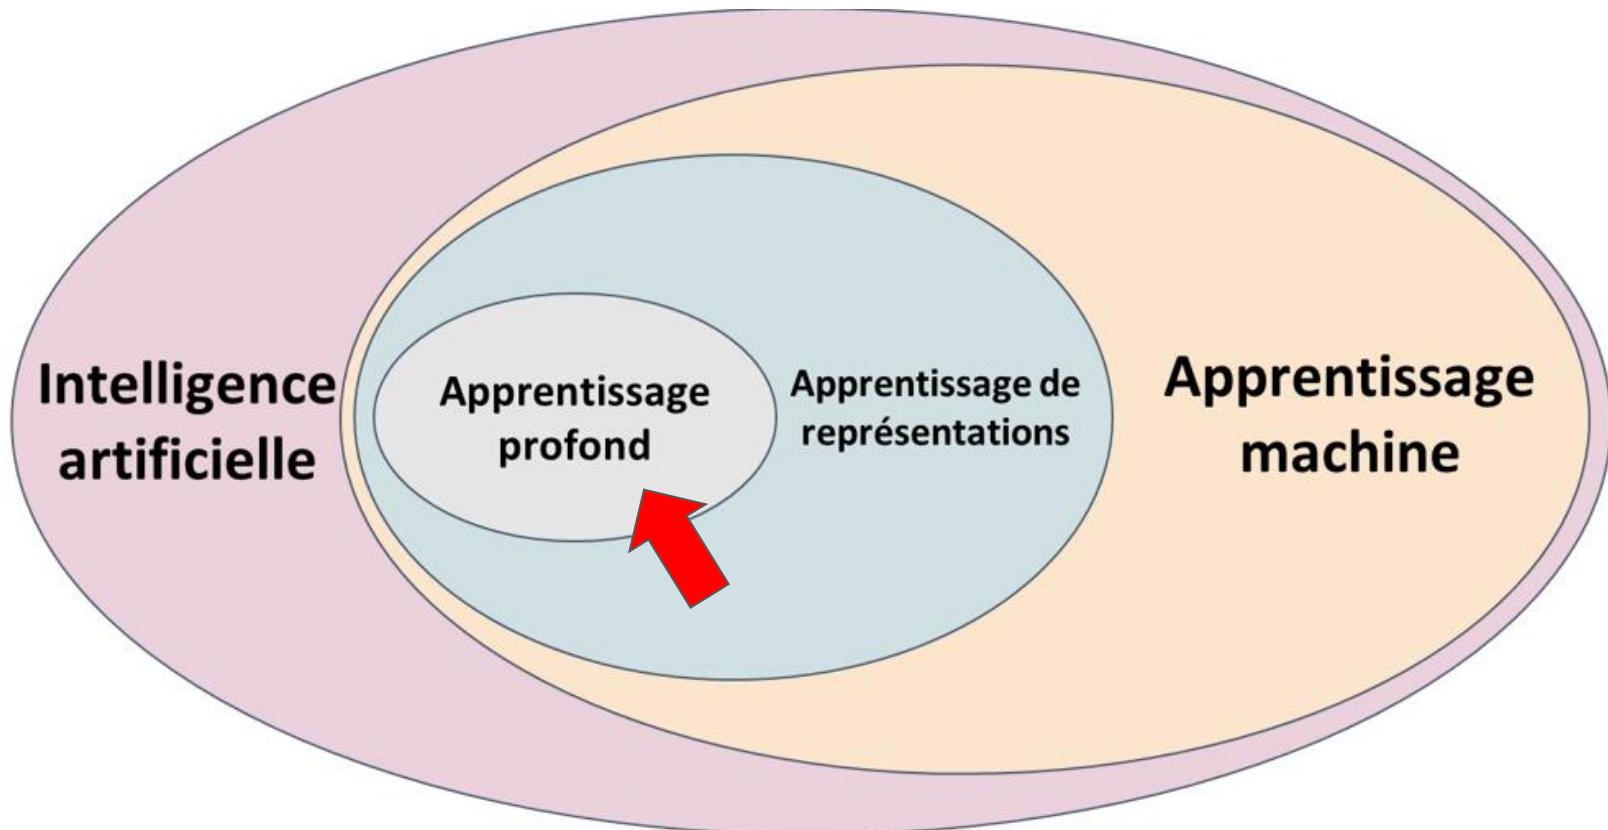
- 12 professeurs
- 100+ étudiants aux 3 cycles
- <https://www.usherbrooke.ca/geomatique/>
- Trois axes:
 - *Physique de la télédétection*
 - *Traitement de la données*
 - *Applications thématiques*
- Thématisques:
 - Agriculture de précision
 - Milieux nordiques
 - Foresterie
 - Biodiversité
 - Cartographie



Partie I

Introduction aux principes généraux de l'IA

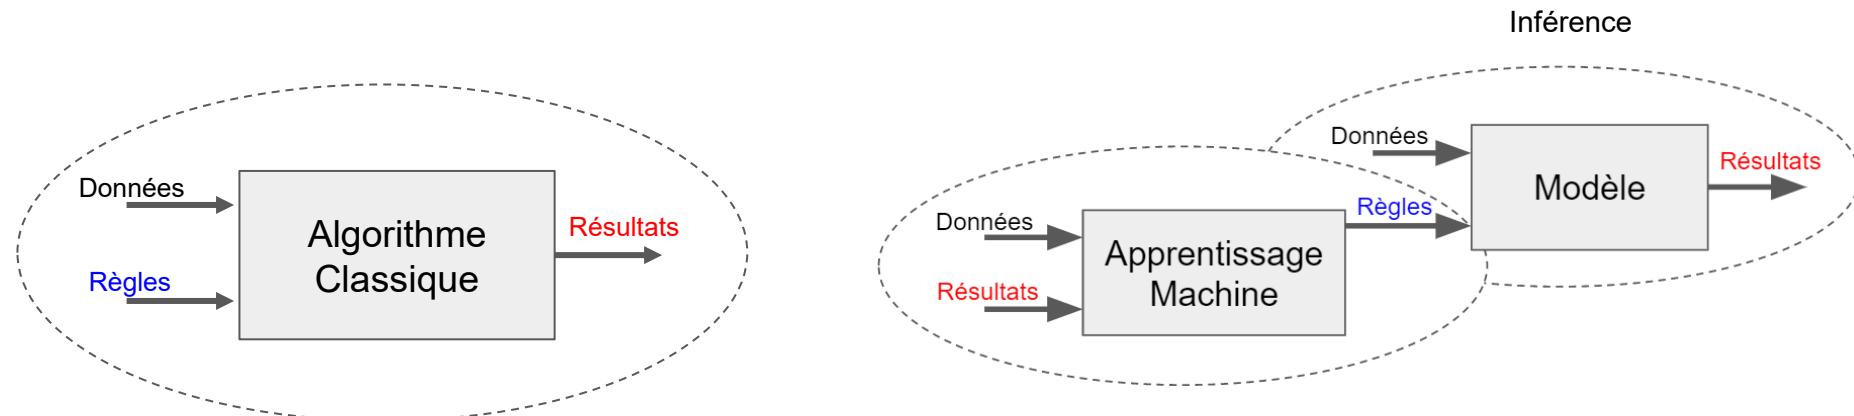
L'intelligence artificielle : un domaine très vaste



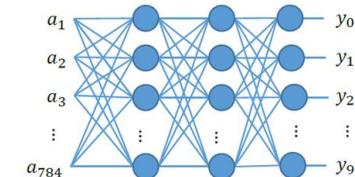
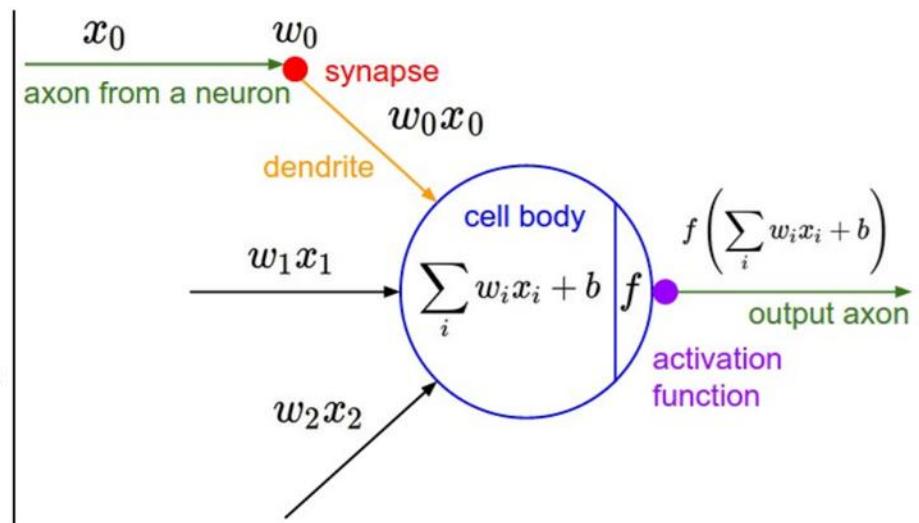
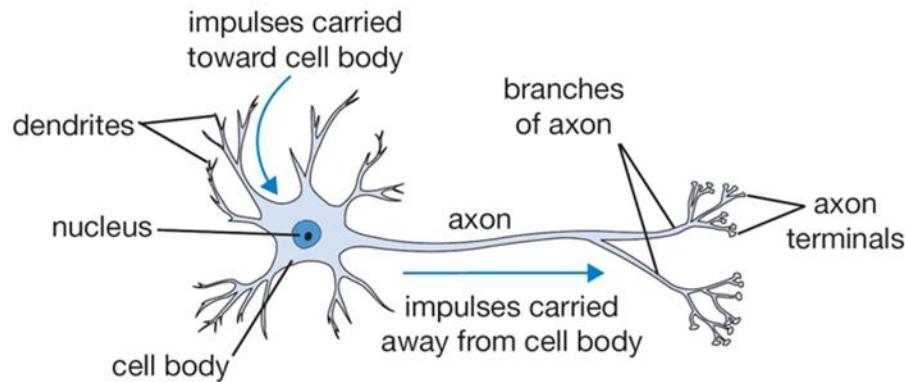
Depuis 2012, l'apprentissage profond a révolutionné le domaine

L'apprentissage automatique (*machine learning*)

- Approche traditionnelle : on trouve des règles (exemple : systèmes experts)
- Apprentissage automatique : on dérive les règles des données (**data driven**)
- L'ensemble des règles = **un modèle**



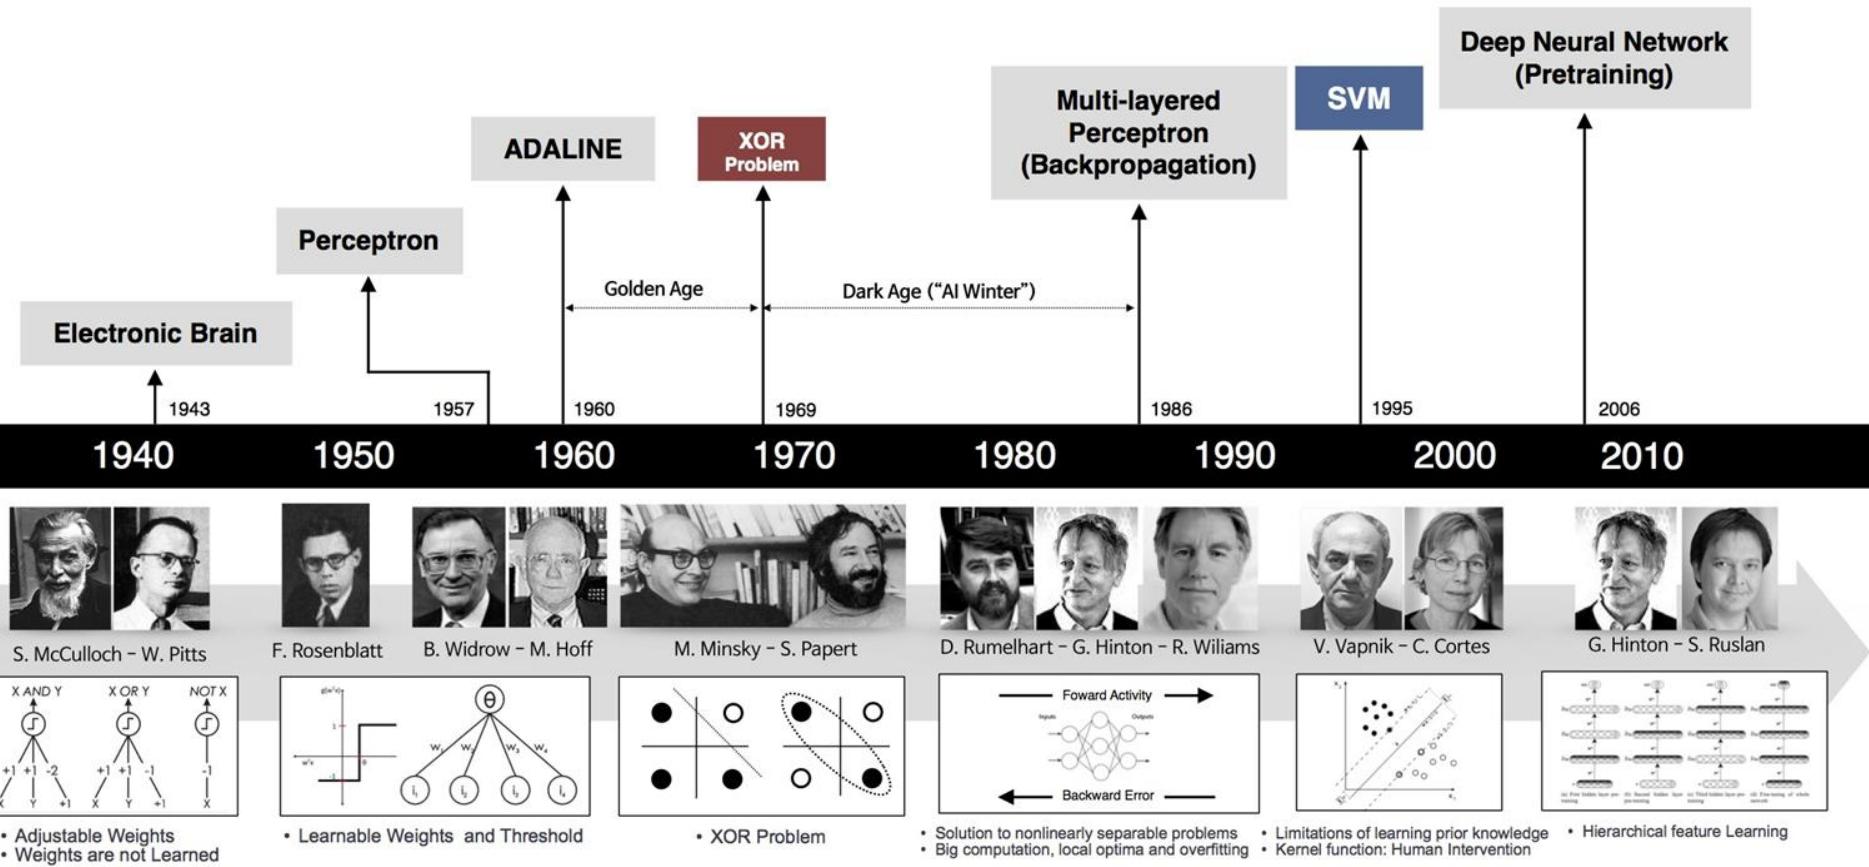
Les neurones artificiels: une inspiration biologique



Réseau neuronal artificiel

Lettvin, J.Y., Maturana, H.R., McCulloch, W.S., & Pitts, W.H. ; What the Frog's Eye Tells the Frog's Brain, (PDF, 14 pages) (1959) ; Proceedings of the IRE, Vol. 47, No. 11, pp. 1940-51.

Bref historique



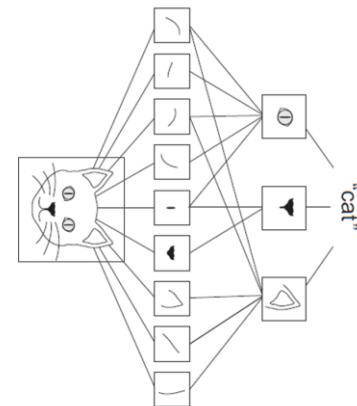
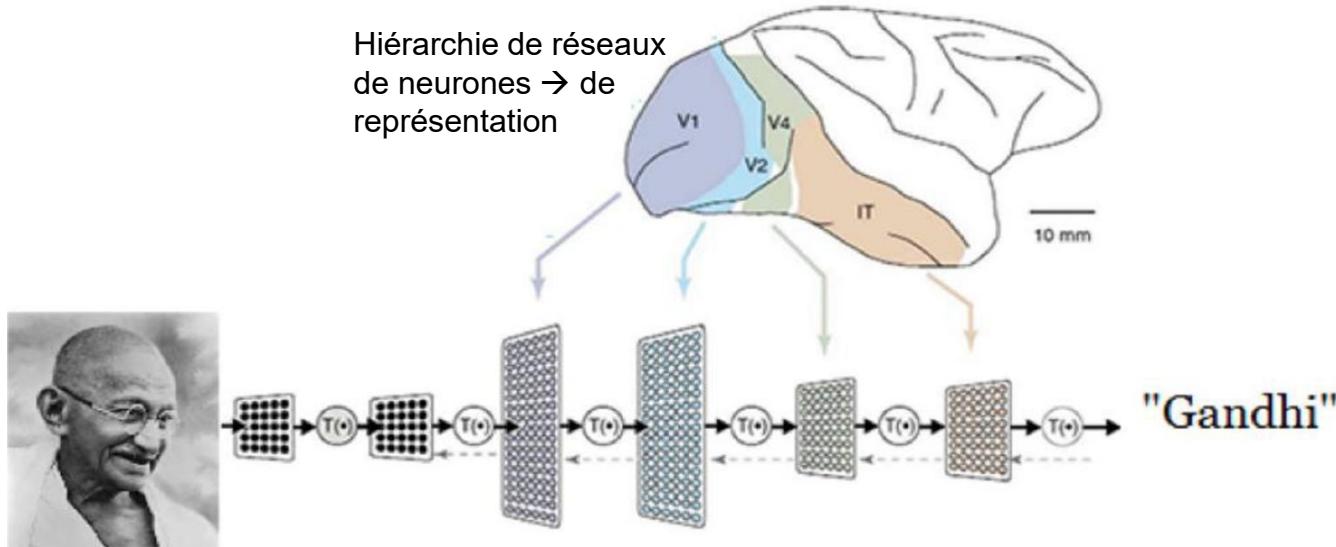
La vision par ordinateur : L'exploitation de la donnée image est un problème difficile

- Pas juste extraire des couleurs mais aussi comprendre l'image (**sémantique**)



Étude du système visuel humain

- Étude du cerveau humain (neuroscience)
- Le système visuel est une **hiérarchie** de couches de neurones



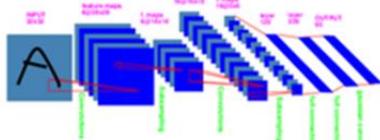
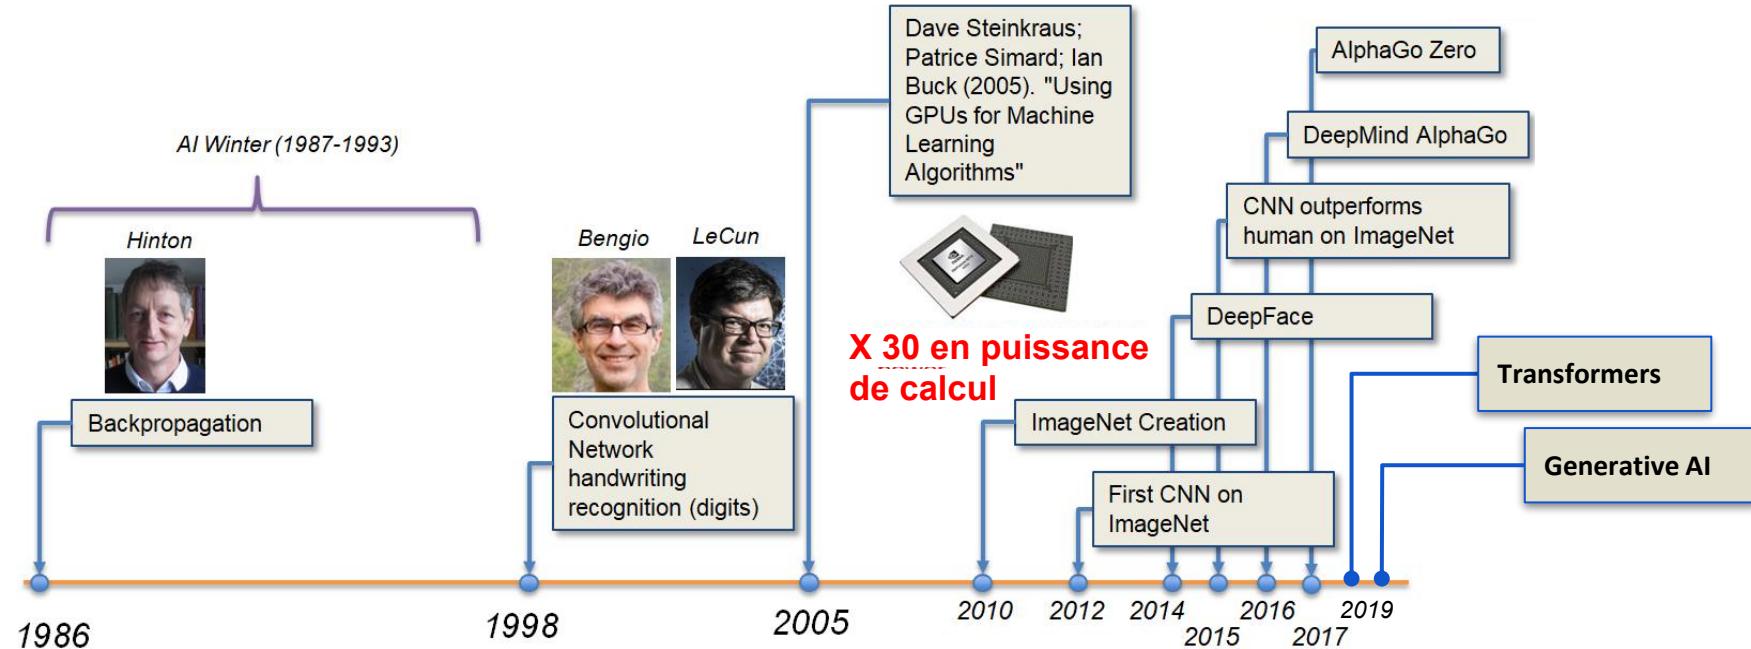
From: Large-Scale Deep Learning for Intelligent Computer Systems, Jeff Dean, WSDM 2016, adapted from Untangling invariant object recognition, J DiCarlo et D Cox, 2007

Les données sont organisées de manière hiérarchique

Une information complexe est très souvent une **hiérarchie** de blocs élémentaires

- **Texte:**
 - Lettre ⇒ mot ⇒ phrase ⇒ paragraphe ⇒ chapitre ⇒ histoire ⇒
- **Image:**
 - Pixel ⇒ Contours ⇒ Texture ⇒ Motif ⇒ Partie ⇒ Objet ⇒ Scène ⇒
- **Parole:**
 - Son ⇒ Phonème ⇒ Morphème ⇒

Développements récents



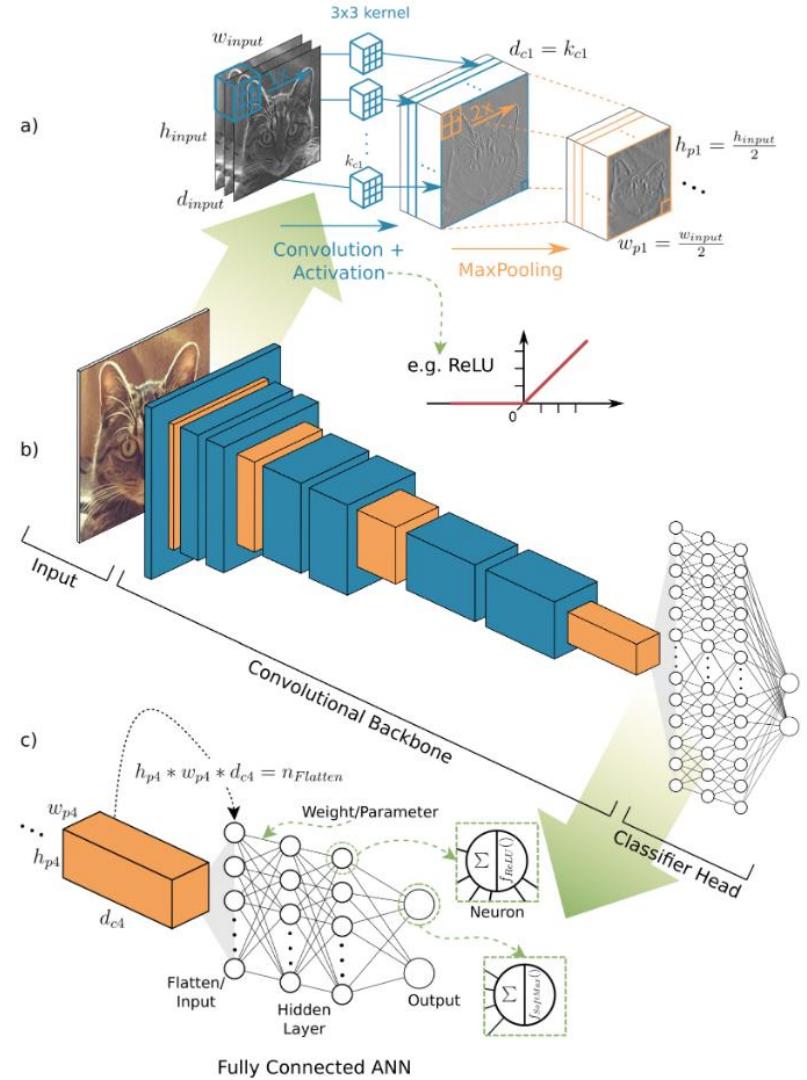
Réseau de neurone convolutionnel



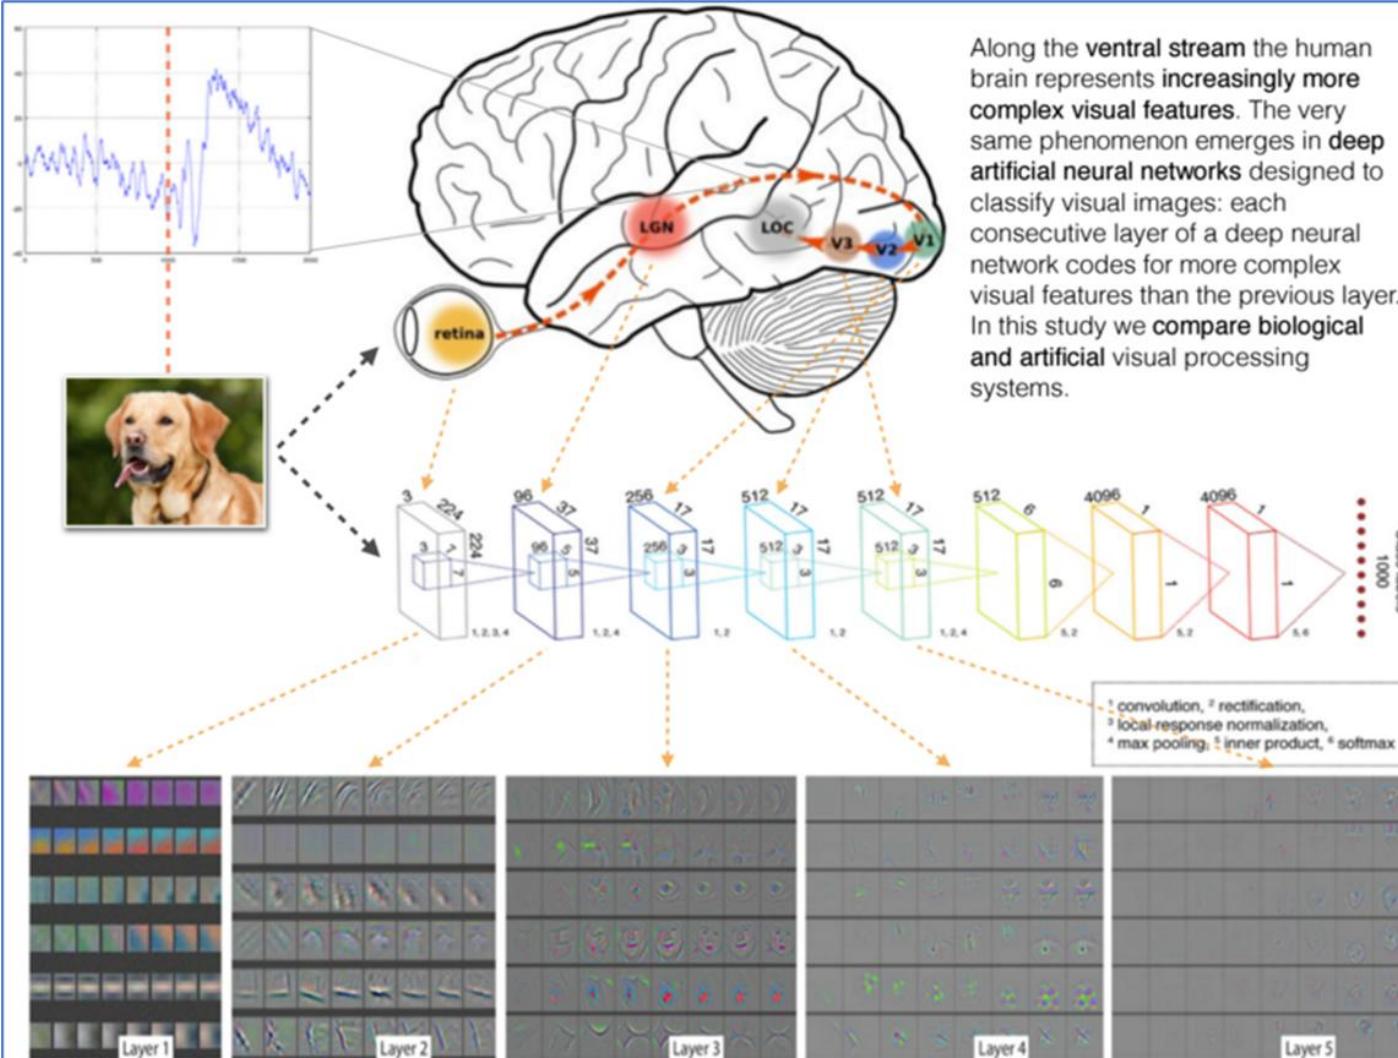
Base de données ImageNet

L'IA perceptif : les réseaux à convolutions (CNN)

- Hiérarchie de caractéristiques visuelles
- Permet d'**encoder** une image
- Très proche du système visuel humain
- Dizaines de millions de paramètres
- Nécessite plusieurs millions d'images
- A révolutionné le domaine



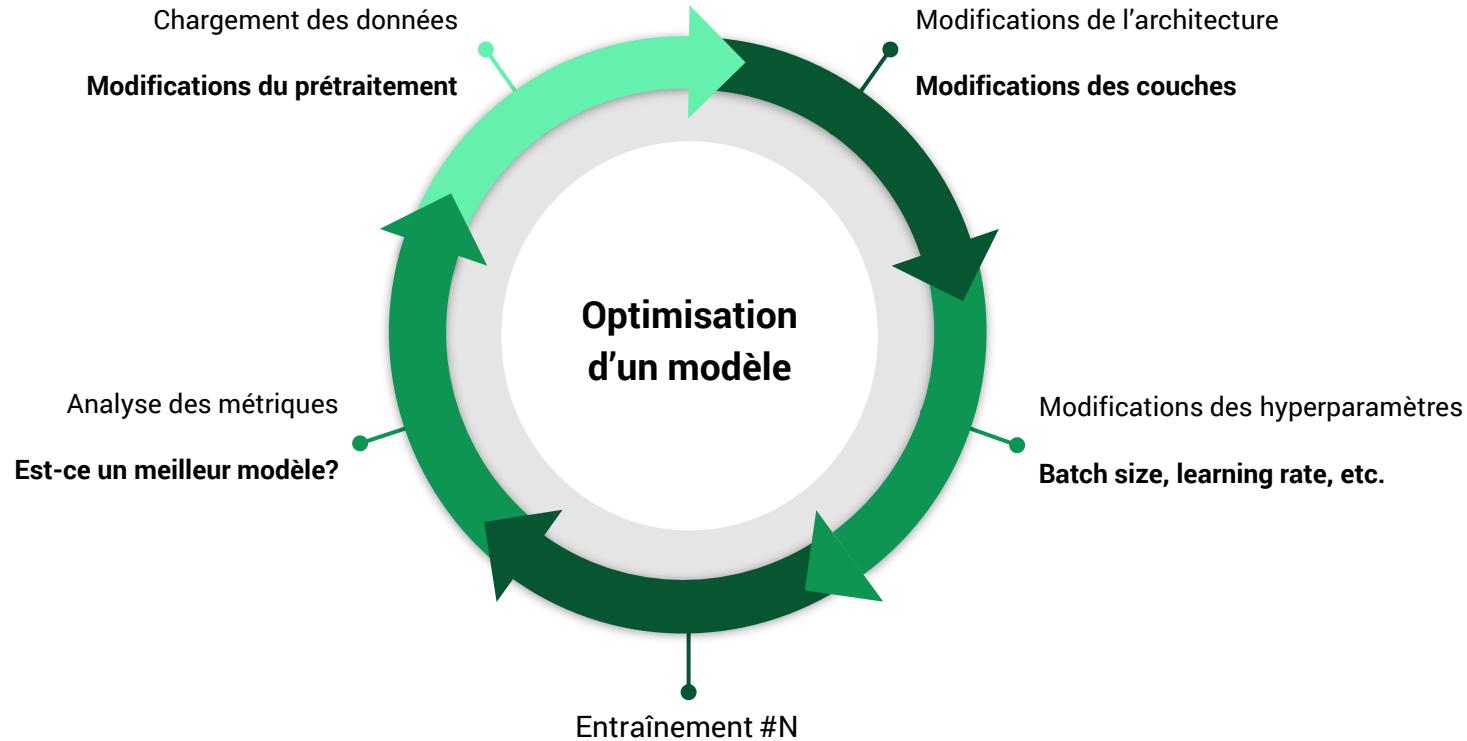
Hoeser, T.; Kuenzer, C. Object Detection and Image Segmentation with Deep Learning on Earth Observation Data: A Review-Part I: Evolution and Recent Trends. *Remote Sens.* **2020**, *12*, 1667.
<https://doi.org/10.3390/rs12101667>



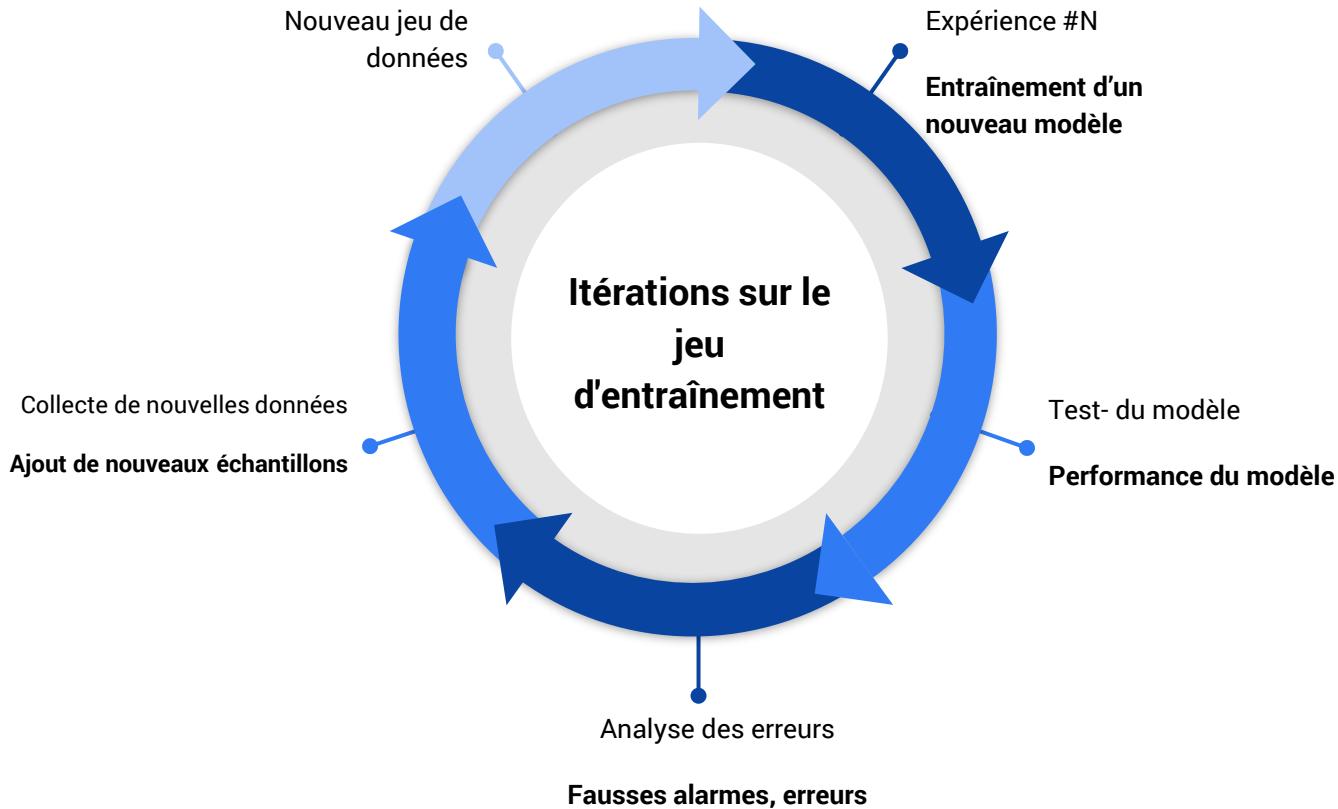
Along the **ventral stream** the human brain represents increasingly more complex visual features. The very same phenomenon emerges in **deep artificial neural networks** designed to classify visual images: each consecutive layer of a deep neural network codes for more complex visual features than the previous layer. In this study we **compare biological and artificial visual processing systems**.

Hiérarchie des features visuels dans le cerveau et dans les RNA

L'entraînement d'un modèle est itératif



La construction du jeu de données est aussi itérative



Ce qu'il faut retenir

- Le réseau de neurone profond est une technique d'apprentissage automatique qui est un sous-domaine de l'IA (IA perceptif)
- Les réseaux de neurones profonds construisent des règles hiérarchiques à partir des données (**profondeur = hiérarchie**)
- Il n'y a pas de raisonnements
- Les données produisent des règles (**intelligence des données**)
- Demande un grand volume de données annotées
- Certains **modèles pré-entraînés** peuvent être adaptés
- Applications en reconnaissance, classification, détection et régression
- Produire des modèles est un **processus itératif** expérimental

Partie II

Exemples de projets en agriculture de précision

Détection de la maladie dans la vigne



Diversité dans le feuillage
et de la prise de vue



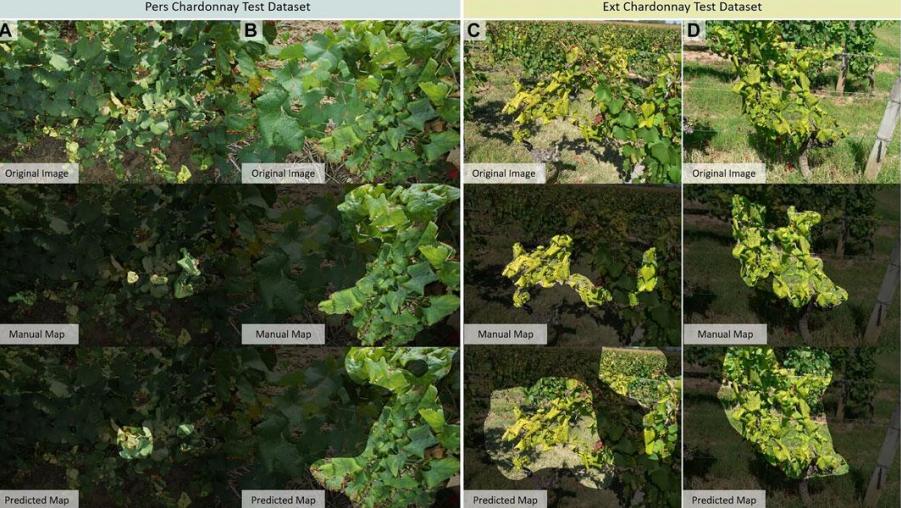
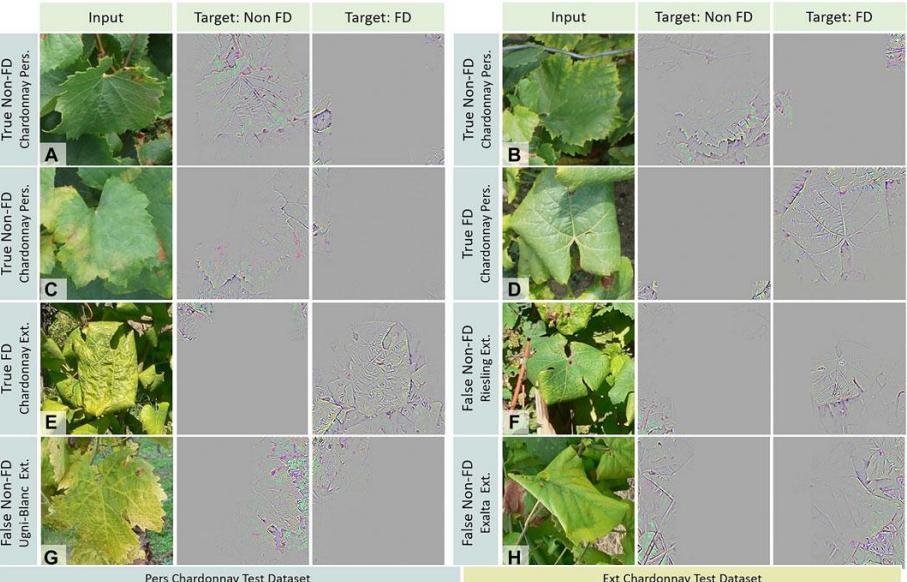
Complexité du diagnostique
Symptômes très variés



Diversité des cépages

Détection de la maladie dans la vigne

- Application de l'apprentissage profond (classification et segmentation) en agriculture de précision
- Détection du Mildiou
- Détection de la flavescence dorée et du Mildiou
- Annotation de plusieurs milliers d'images
- Adaptation de réseaux pré-entraînés



Classification des mauvaises herbes

- Reconnaissance des mauvaises herbes à des **stades précoce**s de croissance
- Adaptation de **réseaux pré-entraînés**
- Techniques d'apprentissage avec peu de données

BBCH 09



BBCH 10



BBCH 11



BBCH 12



BBCH 13



BBCH 14



BBCH 15



CHEAL



Agriculture and
Agri-Food Canada

Agriculture et
Agroalimentaire Canada

UDS

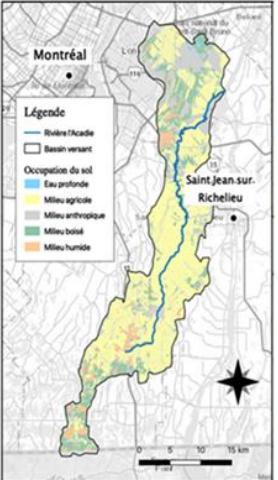
Université de
Sherbrooke

Caractérisation des bandes riveraines

- Réseaux de neurones + Images très haute résolution (50 cm)

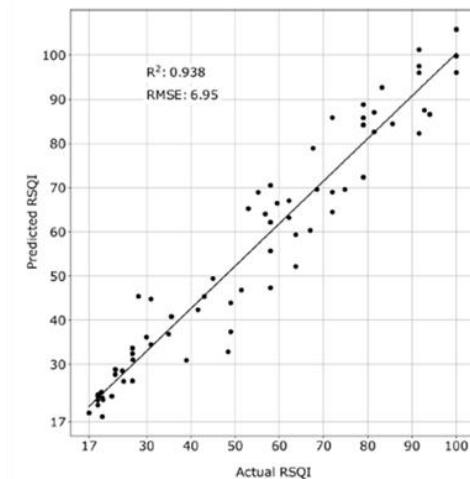
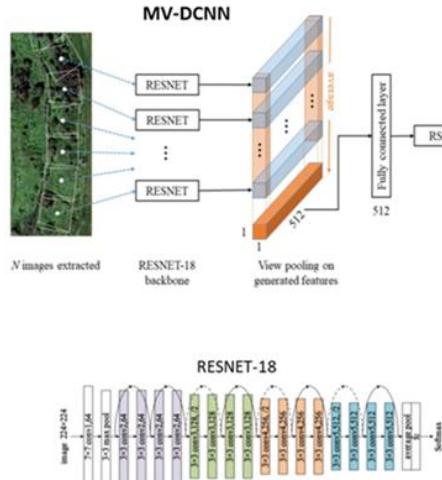
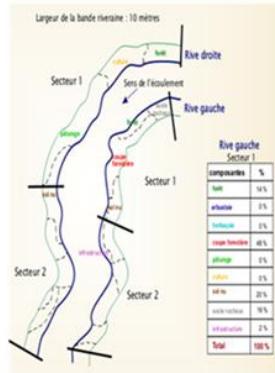
IQBR en milieu agricole : DCNN multi-vues
(MSc Samuel De La Sablonnière, 2019-2021)

Site d'étude



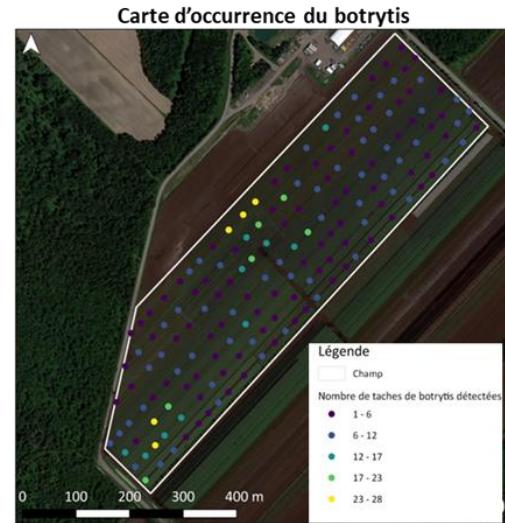
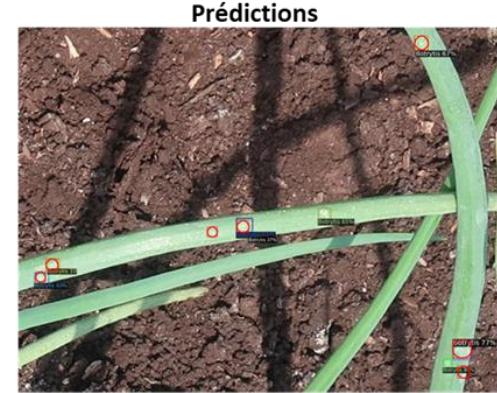
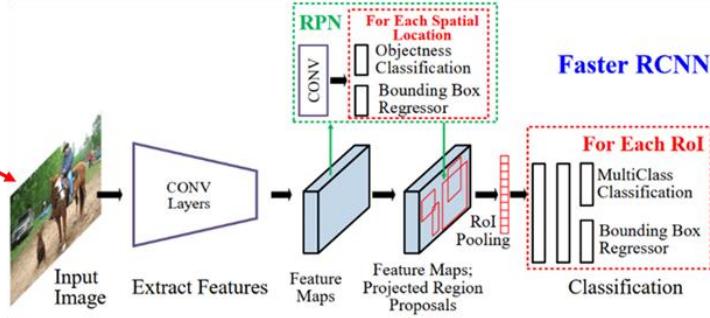
Méthode traditionnelle (MELCC)
• Application à l'aide d'une classification OO

$$IQBR = \frac{\sum(\%_l \times p)}{10}$$



Dépistage du botrytis de d'oignon

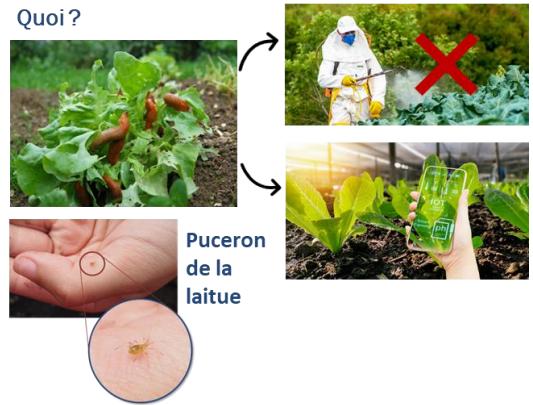
Dépistage du botrytis de l'oignons sur des images UHR
(MSc Mathieu St-Laurent, 2019-2021 – AAC et Phytodata)



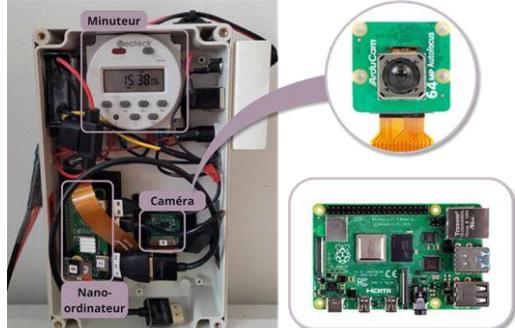
Dépistage du puceron de la laitue

Doctorat d'Emma Dubrûle (Projet RQRAD, Marc Bélisle)

Quoi ?



Comment ?



Yolo en mode « edge computing » : détection d'objets en temps réel, rapidité et précision

IA en périphérie pour la détection en temps réel du puceron de la laitue

PhD Emma Dubrûle

YOLO : plus rapide



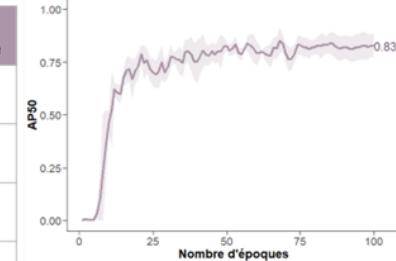
Détection en une étape

Entrainements

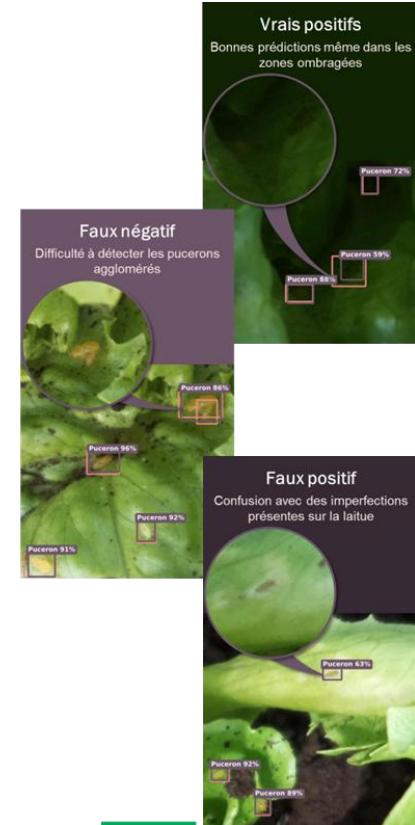
Comparaison des performances des modèles YOLO

Modèle	Précision	Rappel	AP50	F1 score
Yolov8n	1	0.81	0.90	0.90
Yolov9t	1	0.70	0.89	0.82
Yolov10n	0.87	0.70	0.78	0.78
Yolo11n	0.94	0.78	0.90	0.85

Performance moyenne de 5 entraînements de YOLOv8 n



Prédictions



Stades phénologiques du maïs et du soya (Agrisoft et Databio)

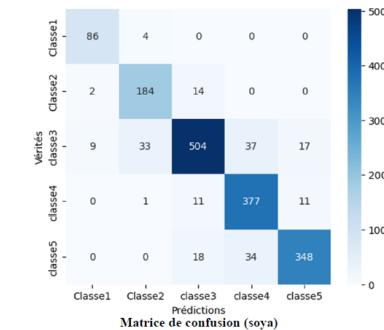
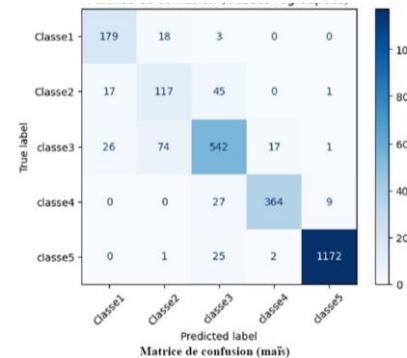
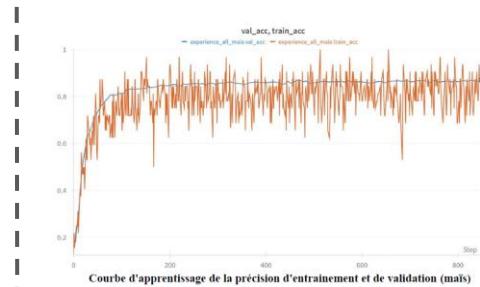
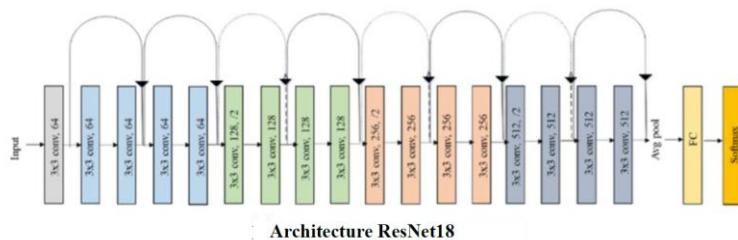
Reconnaitre les stades phénologiques du maïs/soya sur des images de drone



Exemples de stades phénologiques soya

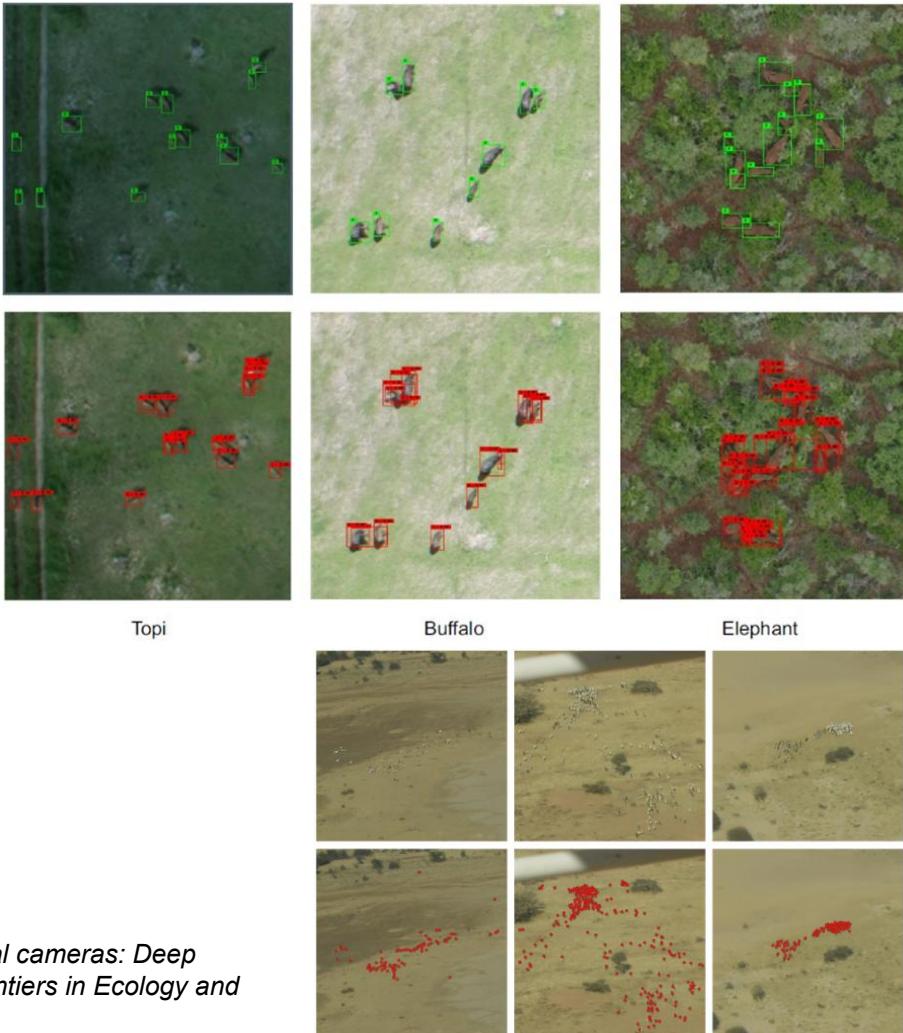


Exemples de stades phénologiques maïs



Recensement faunique

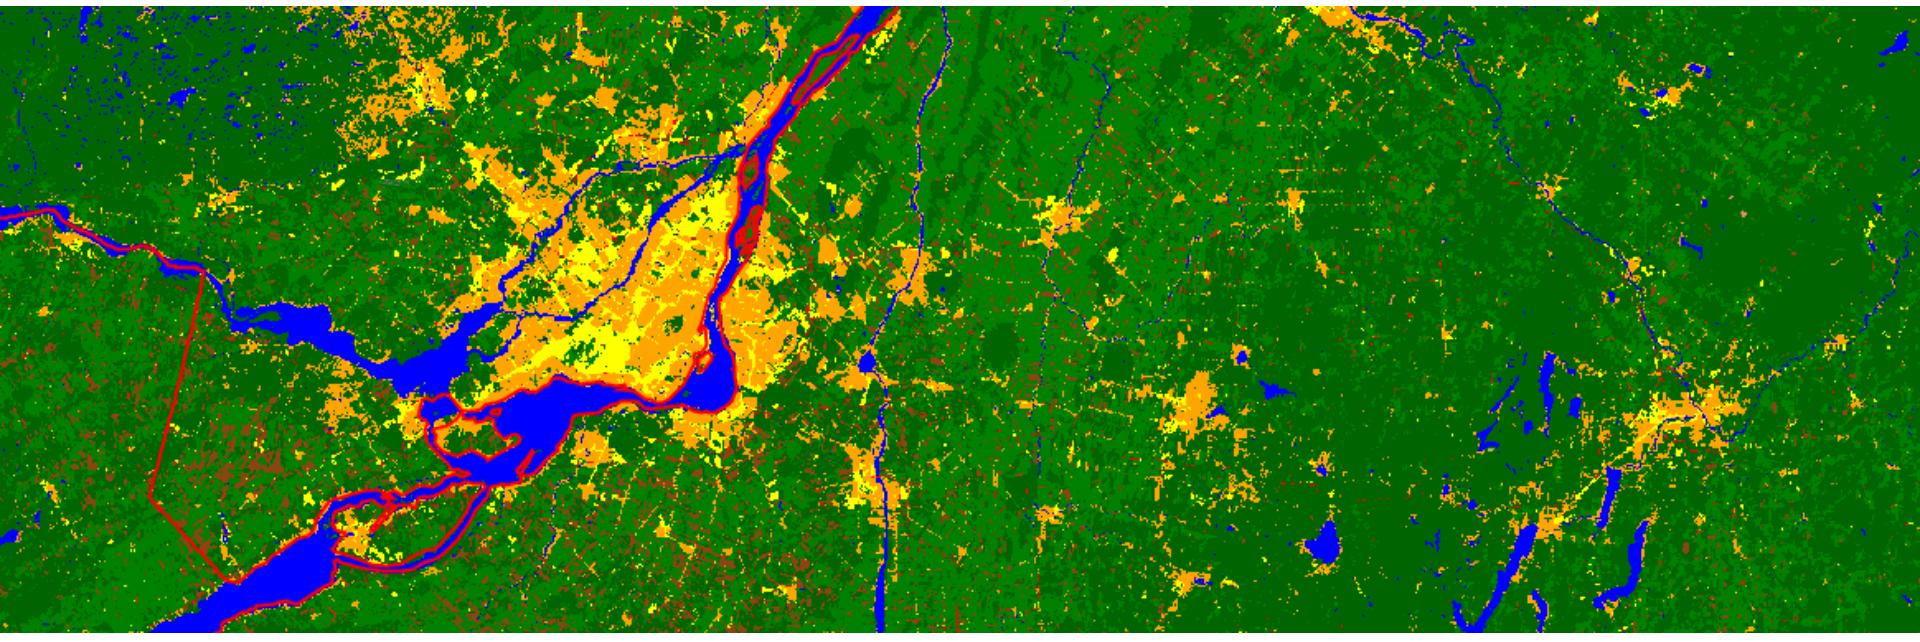
- Comptage d'animaux sur de l'imagerie drone ou aéroportée
- Milliers d'image collectées sur des centaines de km²
- Comptage de troupeaux denses
- Réduction du temps d'analyse par un facteur 10



Delplanque, et al. (2023). Surveying wildlife and livestock in Uganda with aerial cameras: Deep Learning reduces the workload of human interpretation by over 70%. *Frontiers in Ecology and Evolution*, 11. <https://doi.org/10.3389/fevo.2023.1270857>

Carte de la couverture des sols

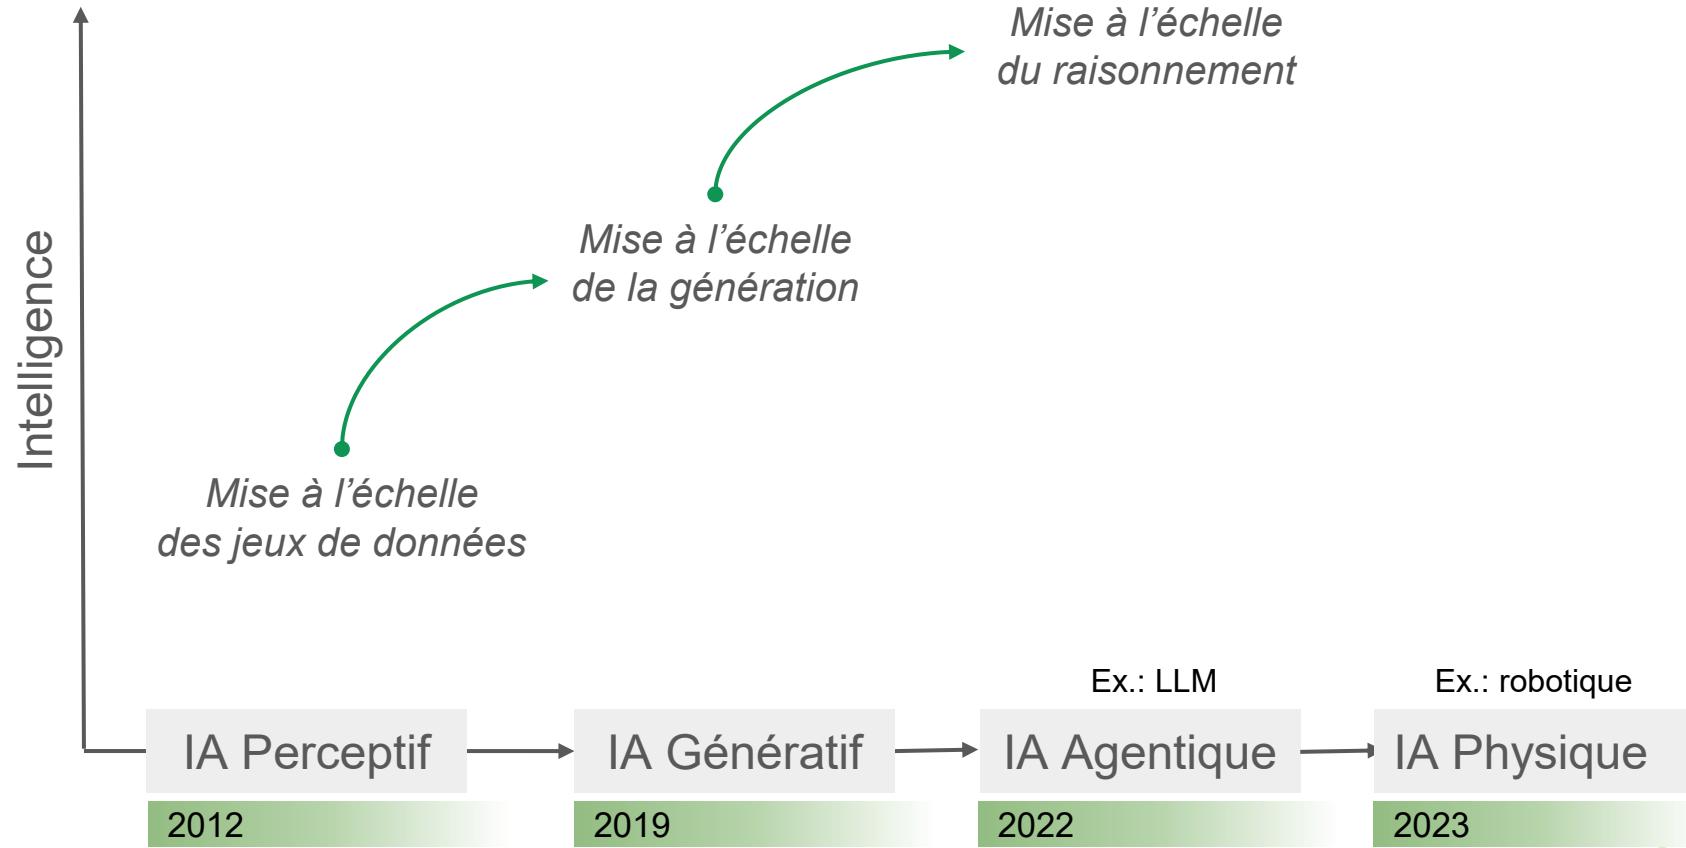
- Première carte d'occupation des terres du Québec basée sur de l'IA
- 10 m de résolution, 12 classes, 2022-2025
- <https://mrnf.gouv.qc.ca/repertoire-geographique/occupation-terres/>



Partie III

Perspectives et tendances

Toujours plus de calculs... plus d'intelligence?



Approches génératives

- Une deuxième révolution (depuis 2019)
- Les IA génératives s'**auto-entraînent** à générer la donnée d'entrée:
 - Images : DALL-E (open AI)
 - Texte : ChatGPT
 - Vidéos : SORA (Open AI)
 - Voix
 - Le geste
 - **Multimodal** : vidéo + texte + image + voix + ...
- Très gros modèles (plusieurs milliards de paramètres!)
- Ces modèles capturent la structure du langage mais pas forcément le sens
- Génèrent toujours un résultats (bon ou mauvais!)

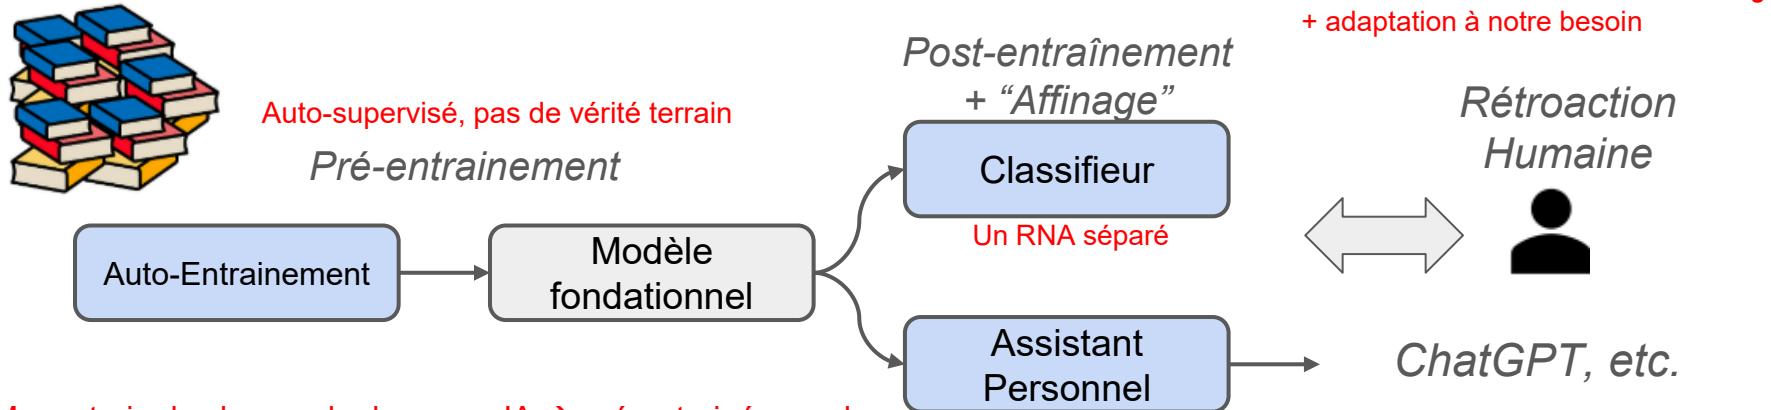
Exemples d'approche générative en super-résolution

- IA génératif
- Amélioration de la résolution d'un facteur 4 à 8
- On passe de 10 mètres à 1,25 mètres!
- **On génère les pixels manquants**



Les modèles de langues (LLM)

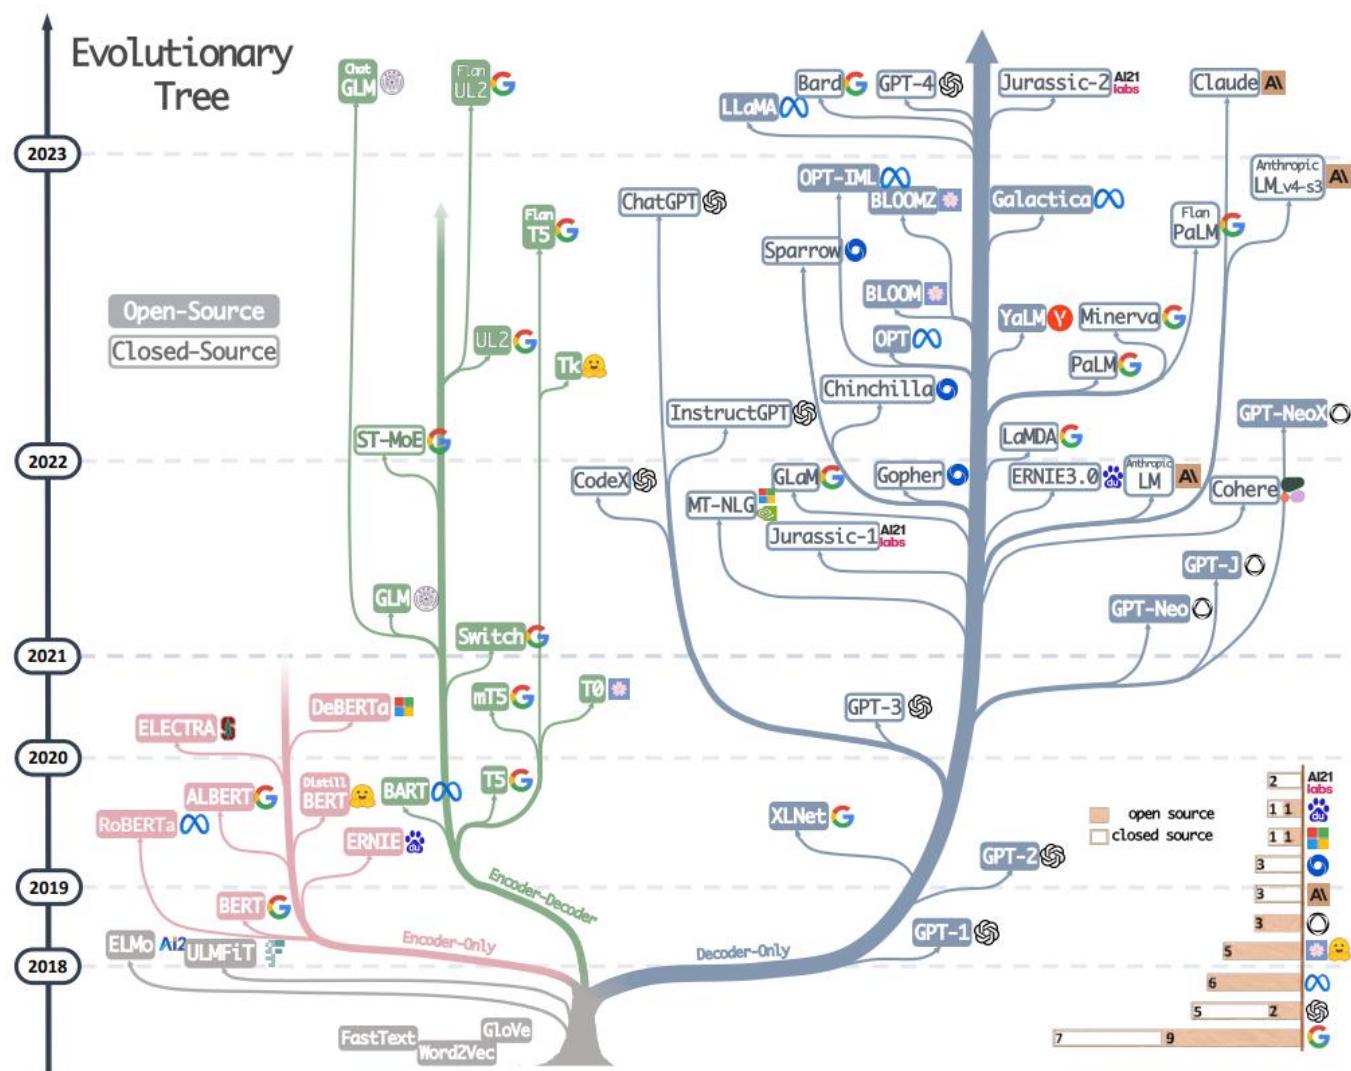
- Modèles dits **fondationnels** : entraînement sur tout ce qui a été écrit! → 10s de TB de documents texte ... de bonne qualité
- Ces modèles sont entraînés à prédire le prochain mot dans une phrase
- Entraînement sur l'internet au complet + plusieurs librairies (plusieurs millions d'ouvrage!)
- Investissement de plusieurs centaines de millions de dollars!



LLM : en train de changer la donne en IA → pré-entraînés sur de très larges datasets ("tout l'Internet"; il suffit de "peu" de données (milliers) ou de règles en langage humain pour les *finetuner*

Explosions de modèles!

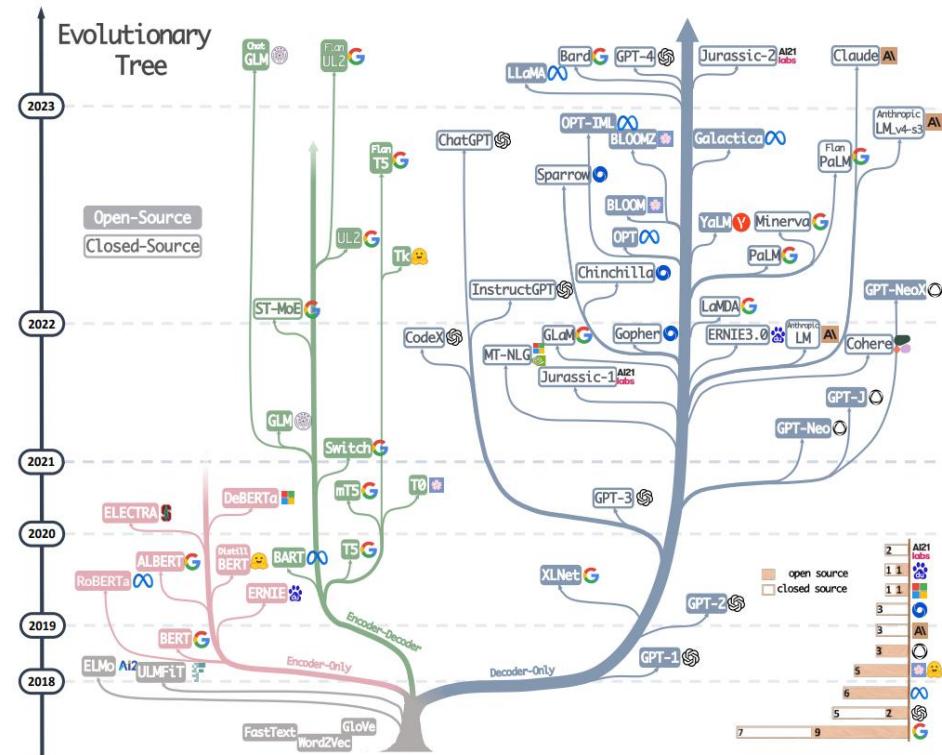
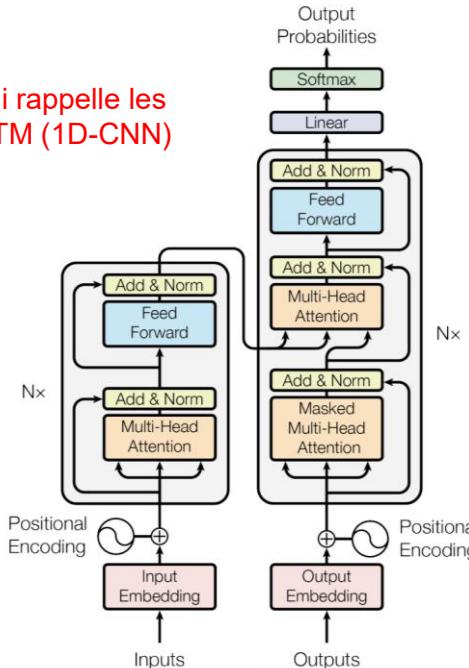
- Course à la taille:
 - Milliards de paramètres
 - Trillion!
- Très coûteux en infrastructure
- Compétition et investissements → plus grande BDs d'entraînement (pré et post); plus longue séquence (nb de tokens); précision la plus élevée
- Open source (open weights) v.s. propriétaires



Explosions de modèles!

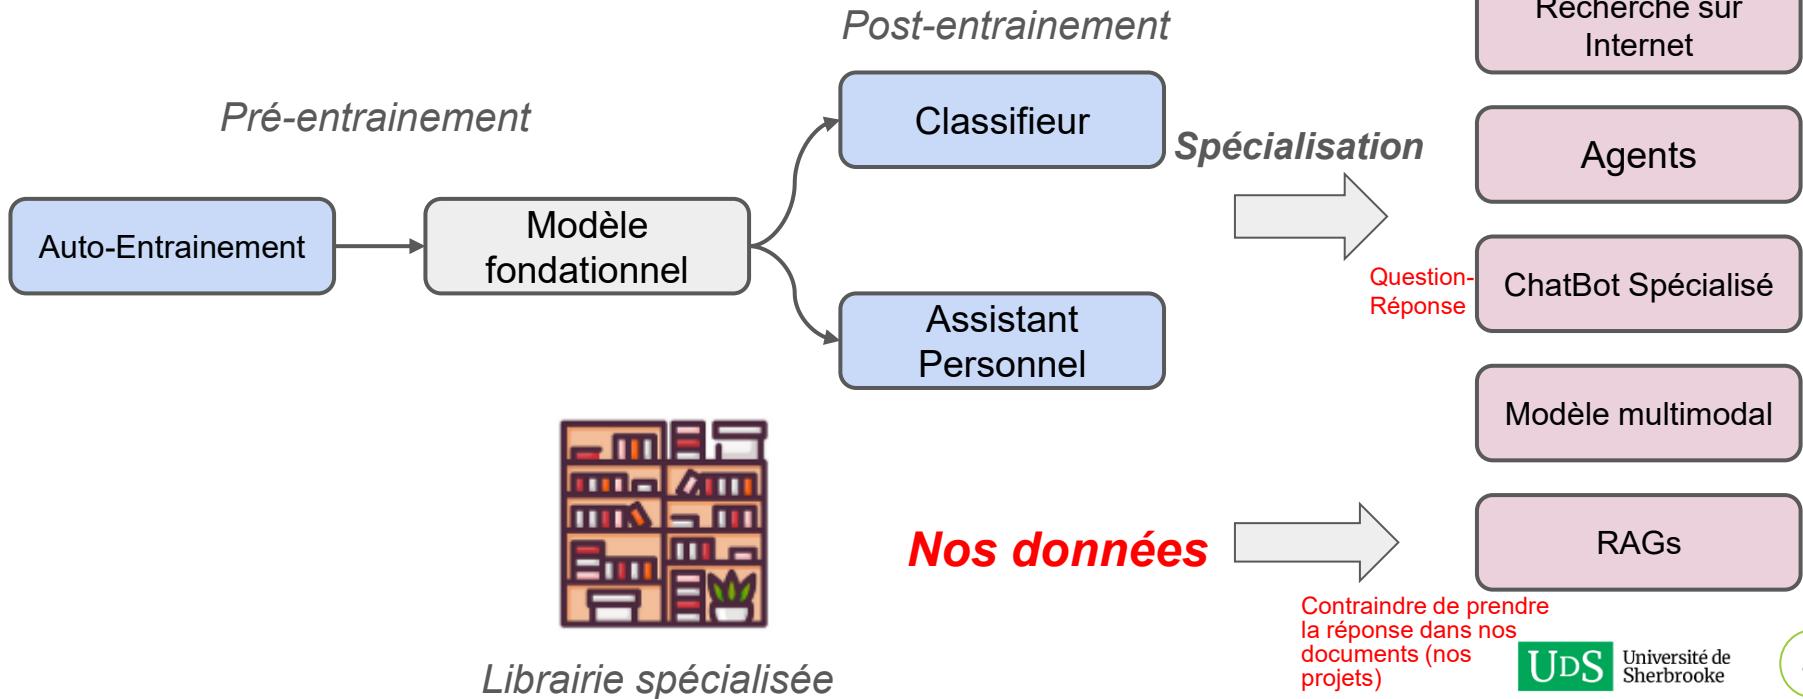
- Architecture de base : Transformers (milliards de paramètres; ça reste un réseau de neurones profond)
- GPT = Generative Pretrained Transformer
- Pour entraîner: des mois, des K GPU et des M\$

Architecture qui rappelle les RNN et les LSTM (1D-CNN)



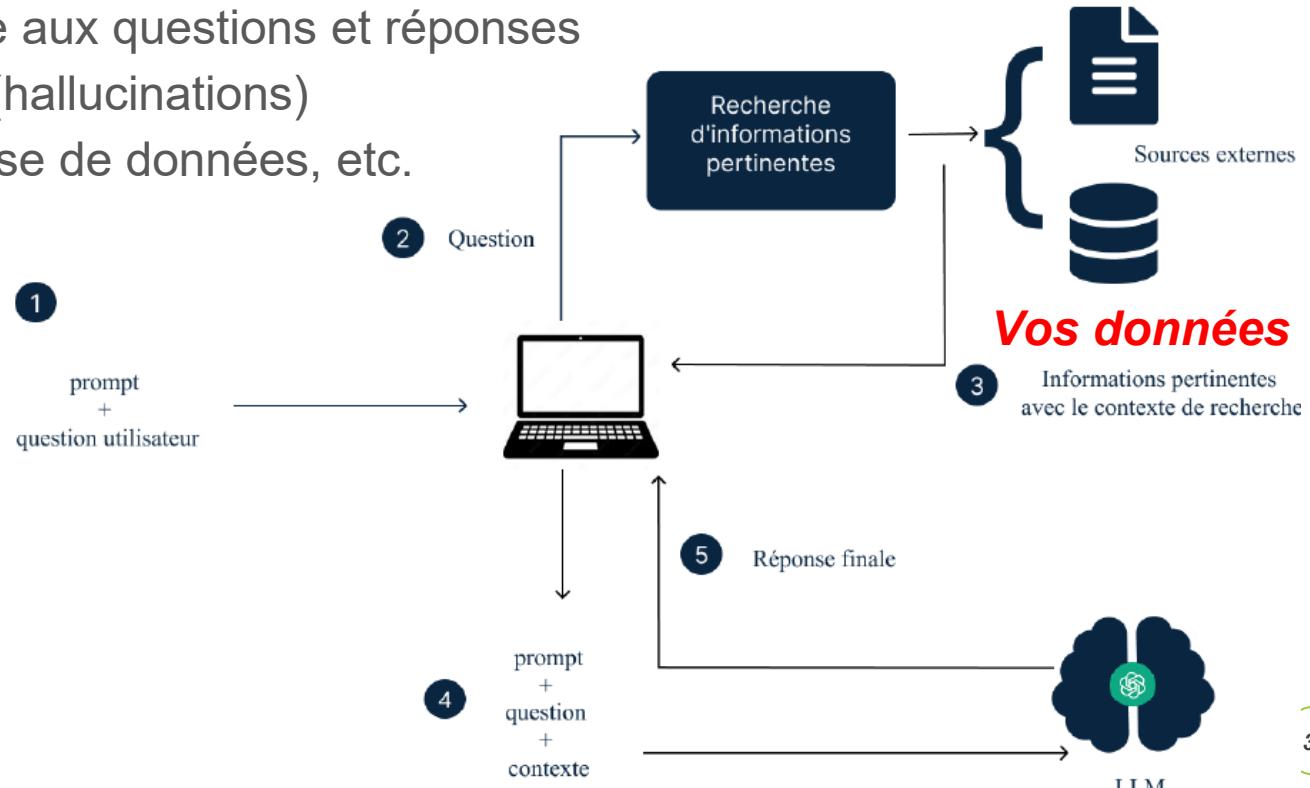
Spécialisation des modèles de langues (LLM)

- Ces modèles peuvent être spécialisés avec vos données



La génération augmentée de récupération (RAG)

- Permet au modèle de se concentrer uniquement sur les données fournies
- Donne un contexte aux questions et réponses
- Limite les erreurs (hallucinations)
- Données texte, base de données, etc.



Modèles avec “raisonnement”

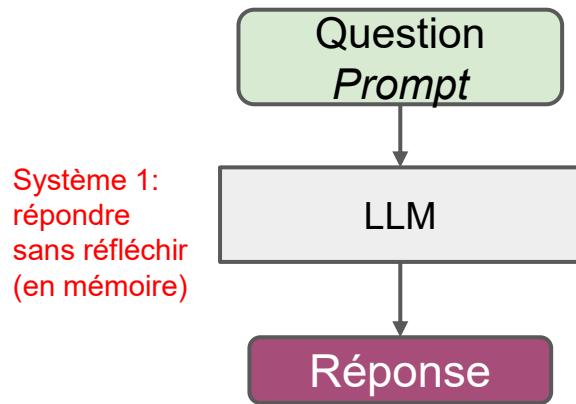
Chaine de pensée: forcer un raisonnement par rapport à la réponse du modèle en inférence

- Certains modèles semblent être capables de raisonner
- Précurseurs de l’Intelligence Artificielle Générale (AGI) ?
- Encore très controversés (mémorisation versus raisonnement)
- Les nouveaux modèles : ChatGPT-o1, DeepSeek-R1, ChatGPT 5.1, Gemini 3
“raisonnent” en boucle (*test time inference*)
- Plus adaptés pour des problèmes complexes (décomposition en étapes)
- Plus coûteux à l’utilisation à cause des itérations

Modèles avec “raisonnement”

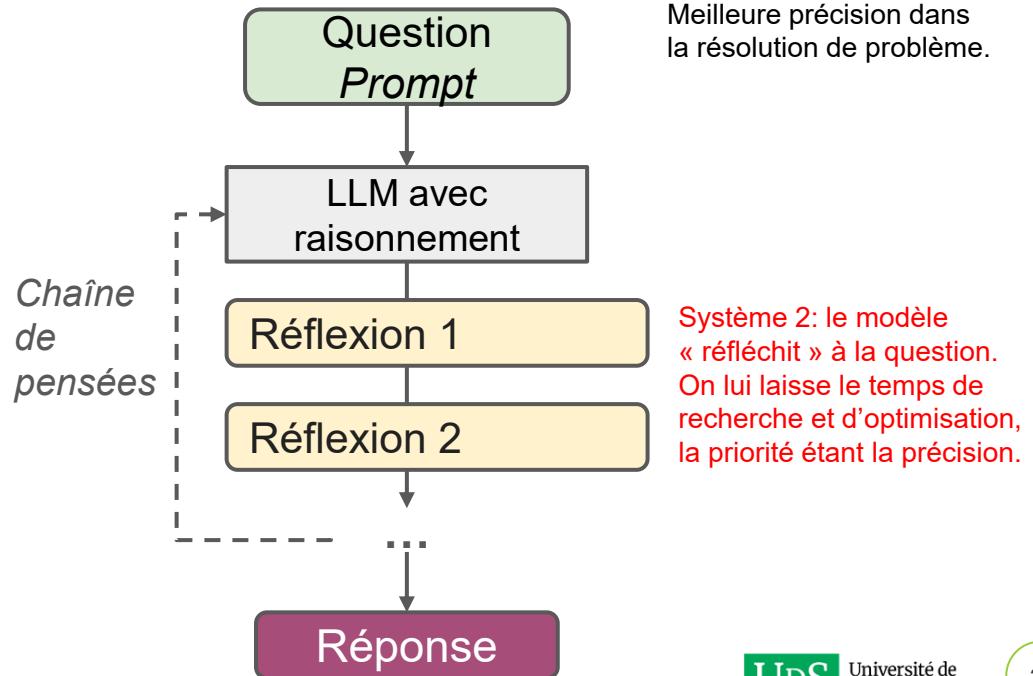
- Le modèle semble “réfléchir” avant de donner une réponse

ChatBot traditionnel



Système 1 vs 2 : théorie en psychologie (Daniel Kahneman)

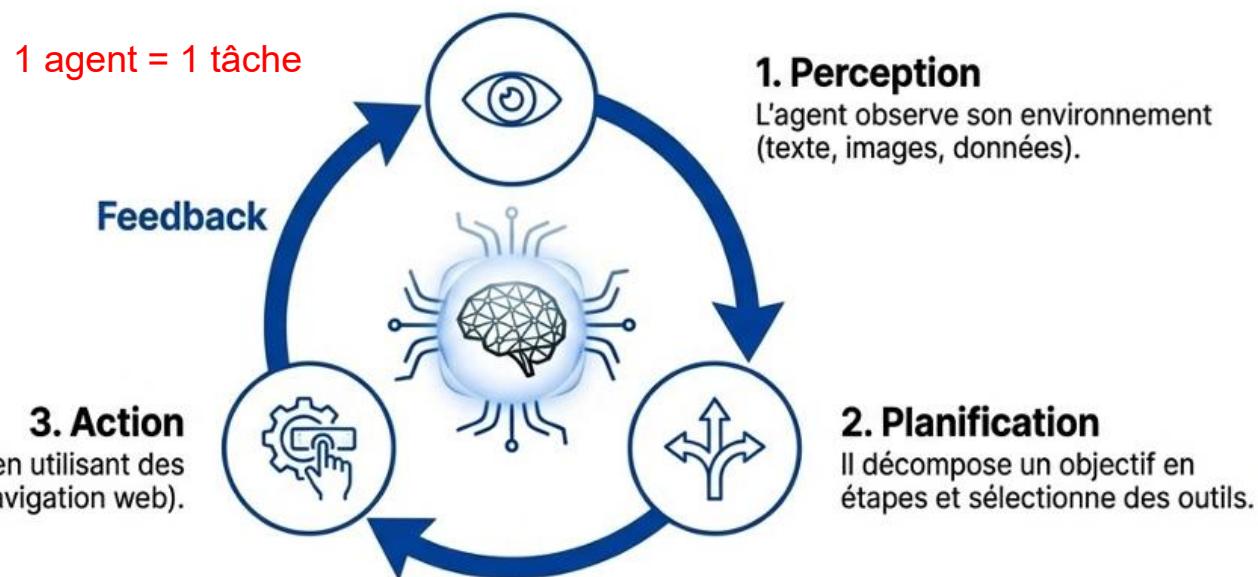
ChatBot avec raisonnement



Les agents conversationnels

- Un agent :
 - un modèle de langue (LLM)
 - + une série d'outils exécutant diverses tâches, avec une spécialisation (recherche sur internet, base de données, ...)
 - + une interface texte avec l'utilisateur

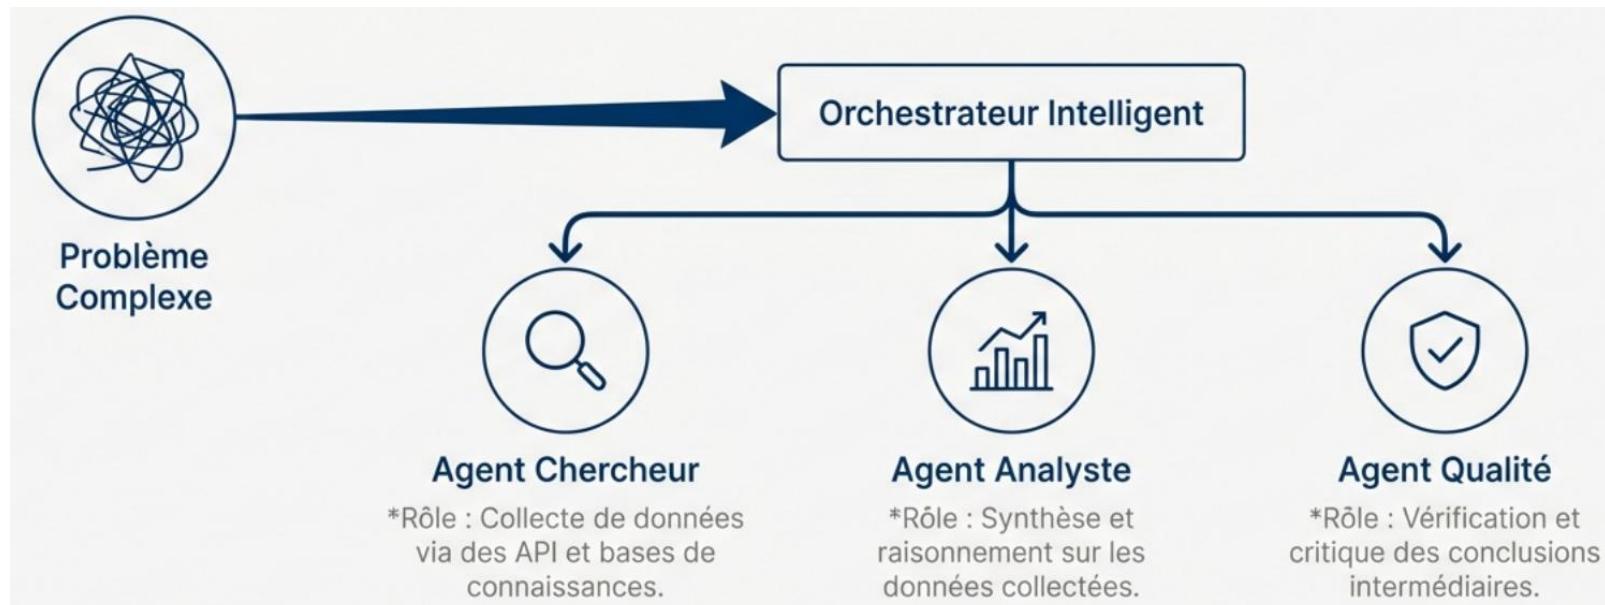
- Problème complexe → divisé en tâches avec spécialisation
- On parle d'approche agentique



Approches Agentiques

- Un agent = un modèle de langue (LLM)
- Plusieurs agents peuvent interagir
- Exemple en médecine (Med-Gemini)

Voir le projet RQRAD
de Ramata Magagi



Émergence de petits modèles

- Les petits modèles peuvent être aussi performants que les plus gros
- Ces modèles peuvent fonctionner localement
- Ces modèles peuvent être embarqués sur des nano ordinateurs ou des drones
- Également des modèles multimodaux
- Exemple: Moondream
 - 0,5 - 1.0 GB
 - Texte + Image
 - Tâches de détection d'objet,
description d'image



MOONDREAM

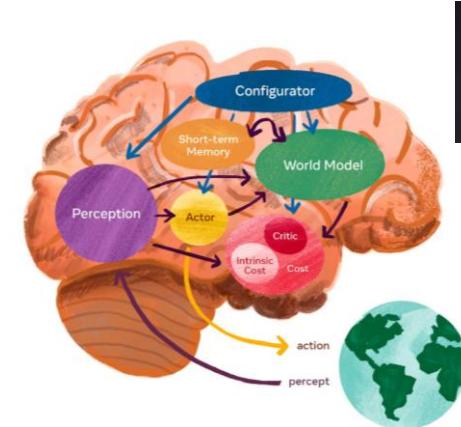
Jumeaux numériques

- Modélisation complète (virtuelle) de l'exploitation ... pour entraîner un modèle
- Générer un nombre important de données synthétiques
- La donnée est déjà annotée par construction
- Important pour l'IA physique
- Applications:
 - Véhicules autonomes
 - Robotique
- Exemple: TomatoSynth



Joint Embedding Predicting Architecture (JEPA)

- World model / modèle du monde
- Proposée par LeCun (>800 articles déjà)
- **Le futur de l'IA (?)**
- Principe :
 - Connaitre le “Monde” au temps t , t-1, t-2, ..., t-n
 - Prédire le “Monde” au temps t+1, t+2, ...
- On peut donc planifier une séquence d'actions pour arriver à un objectif particulier
 - Dans notre cas, des pratiques agricoles pour atteindre un but économique et écologique ...



Ajout d'un « *prior* » : connaissance *a priori* du monde (la physique du monde courant) issue du bon sens, ce que les LLM n'ont pas et peuvent donc fabuler

Spatial Intelligence

- 3D World model (ou 4D avec t) → focus sur la vision
(vs LLMs qui sont des 1D-CNN)
- Proposé par Fei-Fei Li, initiatrice d'ImageNet (2009)
- Le monde qu'on voit est plus compliqué que le langage
→ problème de perception (sensing ...) et non de
génération
- Adapté à la robotique, la conduite autonome, ...
- **Autre futur de l'IA (?)**



Ce qu'il faut retenir

- ✓ Les approches génératives utilisent des gros modèles pré-entraînés
- ✓ Les modèles intègrent des modalités multiples (images, texte, code, etc.)
- ⚠ Les modèles de langue ne font pas vraiment de raisonnement mais peuvent donner l'apparence d'en faire
- ⚠ Ne pas utiliser ces modèles comme une base de connaissance
- ⚠ Les modèles génératifs hallucinent facilement (10-20%) et vont toujours générer une réponse
- ✓ Les approches agentiques ont la possibilité de faciliter l'exploitation des données complexes

Partie IV

Applications de ces nouveaux modèles en
agriculture de précision : RQRAD-UdeS

Projet RQRAD UdeS Ramata Magagi – Samuel Foucher – Mickaël Germain

Inspiration : l'aide à la décision en médecine

Le système est capable de combiner des expertises contradictoires pour converger vers la conclusion la plus probable, imitant ainsi un raisonnement clinique avancé → nécessité d'une intelligence collective

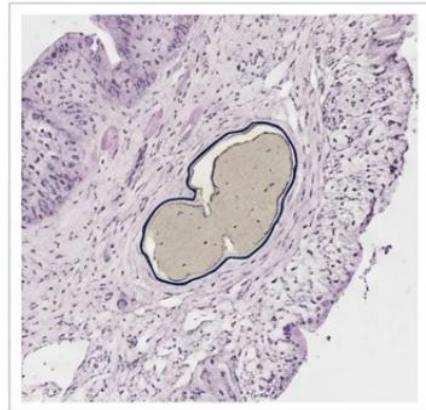
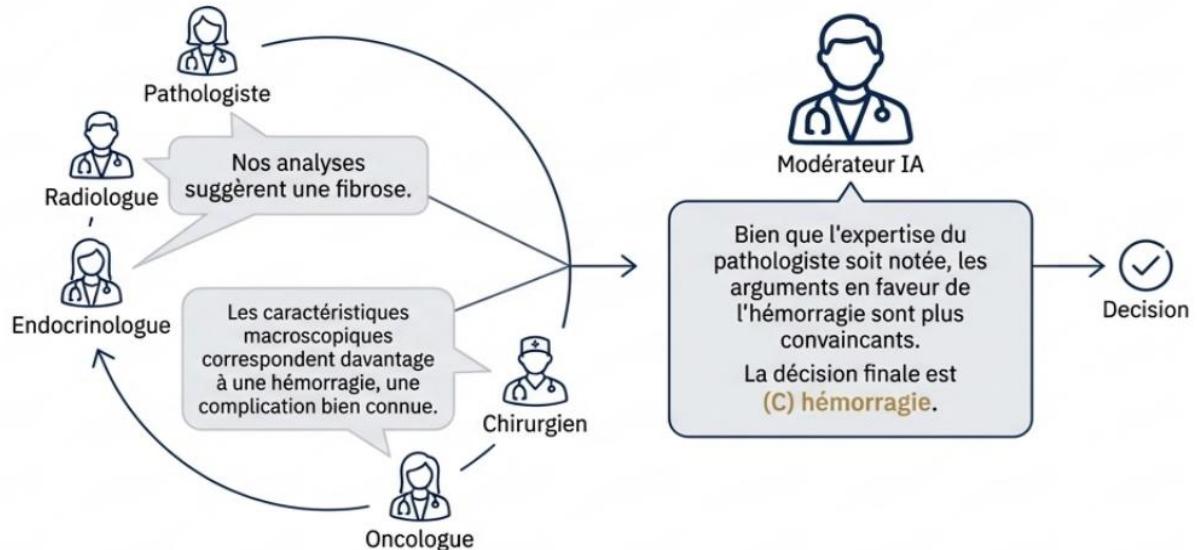


Image médicale du cas
(PMC-VQA)

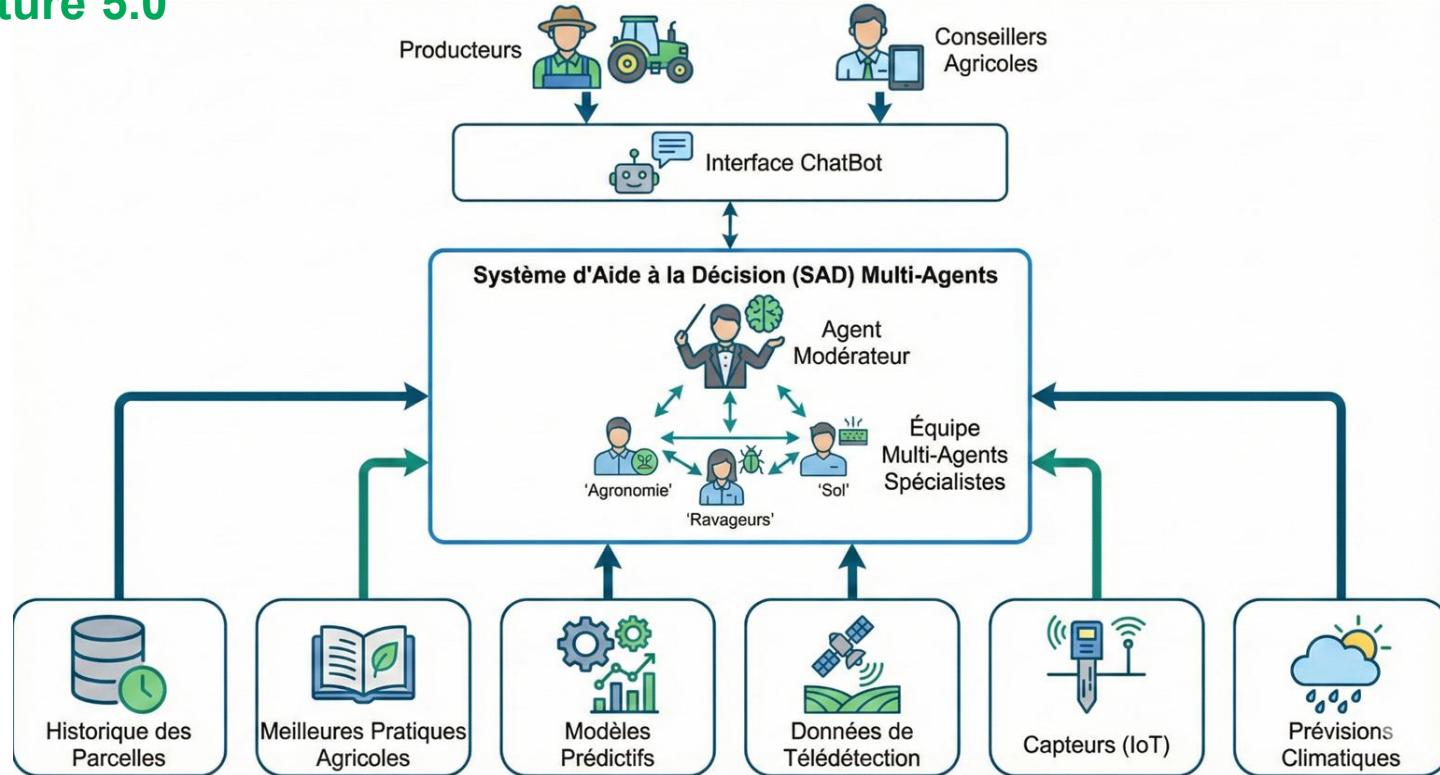


Source: C. Park, et al. "MDAgents: An Adaptive Collaboration of LLMs for Medical Decision-Making." NeurIPS, 2024.

Projet RQRAD UdeS

Ramata Magagi – Samuel Foucher – Mickaël Germain

Agriculture 5.0

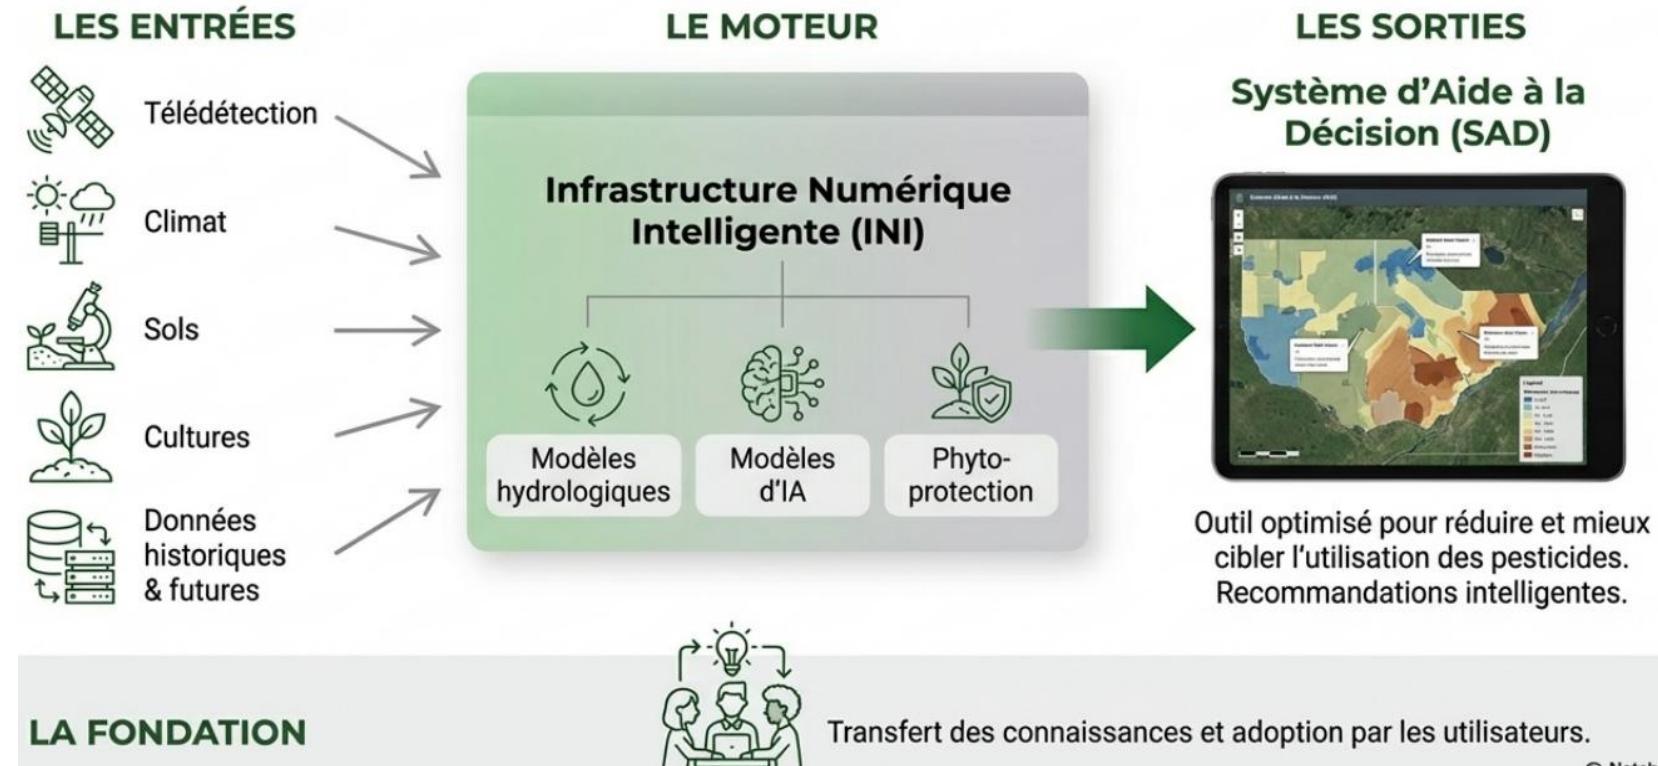


Projet RQRAD UdeS

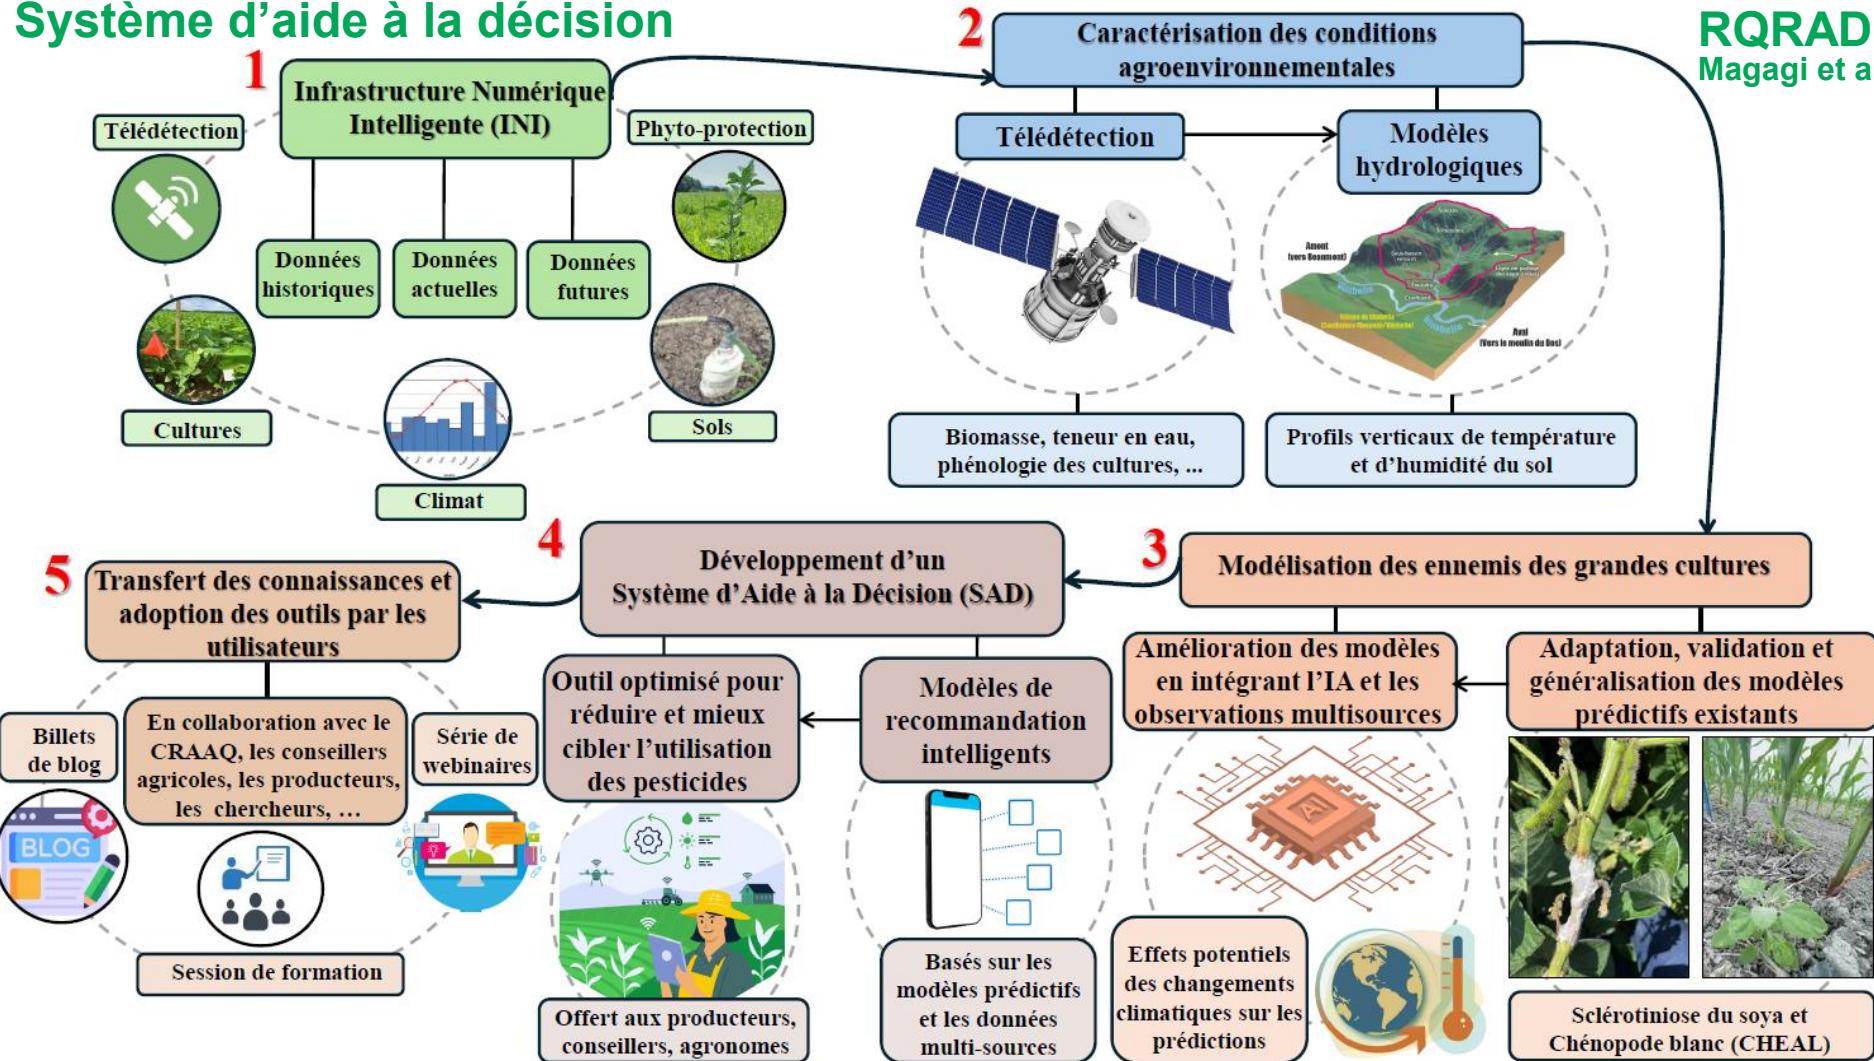
Ramata Magagi – Samuel Foucher – Mickaël Germain

Agriculture 5.0

Un peu plus concrètement

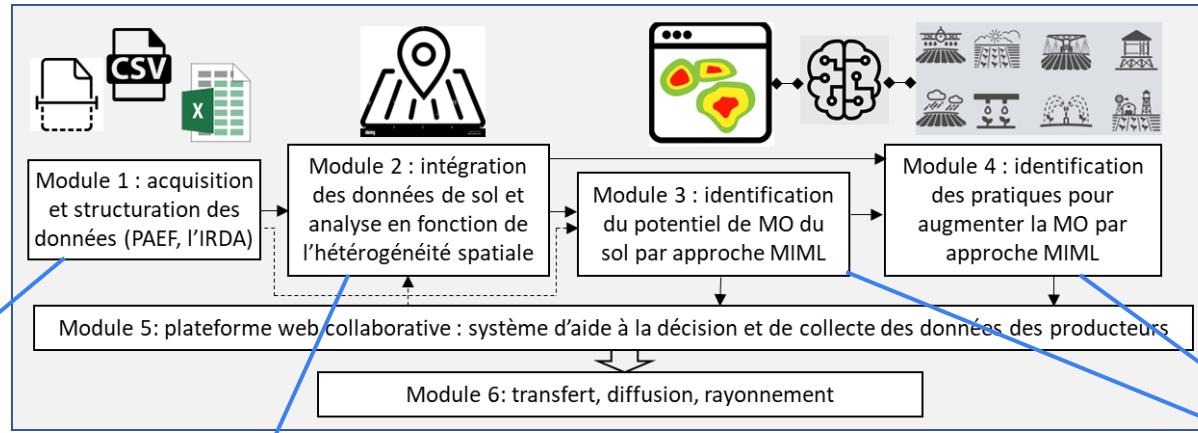


Système d'aide à la décision



Projet RQRAD UdeS Y. Bouroubi – M. Leduc - S. Foucher – M.-O. Gasser – M.-É. Samson

Matière organique des sols : potentiel et meilleures pratiques à l'échelle de la parcelle

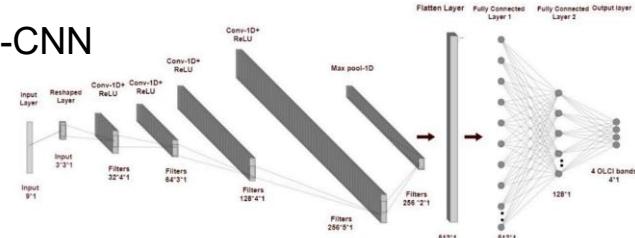


Lecture de PAD par IA
: Maxime Leduc s'est occupé de ce volet

Spatialisation de la MOS à partir de la texture, la topographie, les images
Sentinel-2, la météo : doctorant dirigé par Slava Adamchuk → 3 articles,
méthodes basées sur les RNA

Simulations DNDC + IA pour répondre aux 2 questions

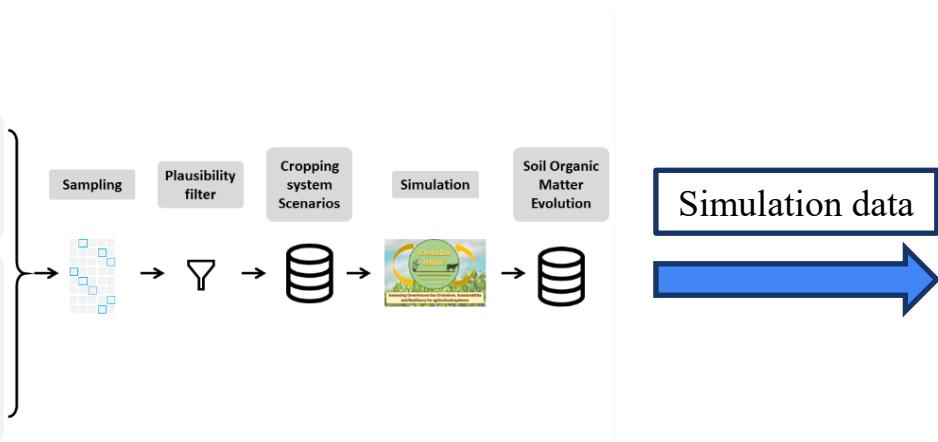
1D-CNN



Projet RQRAD UdeS Y. Bouroubi – M. Leduc - S. Foucher – M.-O. Gasser – M.-É. Samson

Matière organique des sols : potentiel et meilleures pratiques à l'échelle de la parcelle

Simulations DNDC + IA → potentiel de MOS et pratiques agricoles

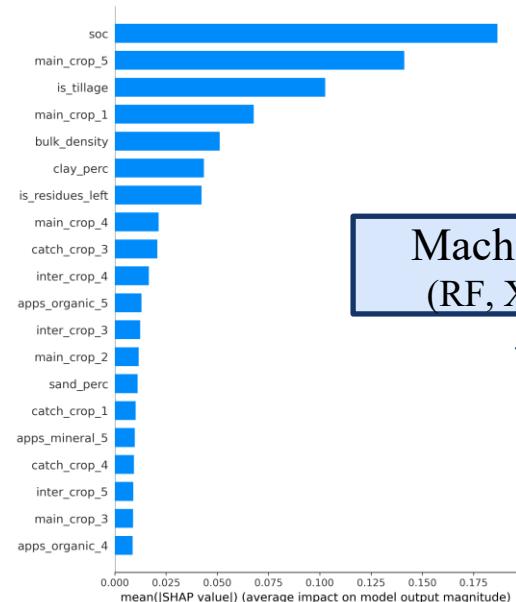


```
  "drain_depth": 0.5,
  "drain_spacing": 20.0,
  "sand_perc": 6.28,
  "clay_perc": 69.85,
  "bulk_density": 1.35,
  "ph": 6,
  "soc": 0.0696,
  "cropping_systems": [
    {
      "crops": [
        {
          "crop": "Spring_wheat",
          "crop_tdd": 2065,
          "max_biomass_c": 8055,
          "sowing_date": {
            "month": 4,
            "day": 27
          },
          "harvest_date": {
            "month": 8,
            "day": 10
          },
          "fraction_residues": 1.0
        },
        {
          "crop": "Annual_grass",
          "crop_tdd": 2581,
          "max_biomass_c": 4589,
          "sowing_date": {
            "month": 4,
            "day": 27
          },
          "harvest_date": {
            "month": 8,
            "day": 10
          },
          "fraction_residues": 1
        },
        {
          "crop": "Radish",
          ...
        }
      ]
    }
  ]
```

Projet RQRAD UdeS Y. Bouroubi – M. Leduc - S. Foucher – M.-O. Gasser – M.-É. Samson

Matière organique des sols : potentiel et meilleures pratiques à l'échelle de la parcelle

Simulations DNDC + IA → potentiel de MOS et pratiques agricoles



scenario_id	id_site	latitude	sand_perc	clay_perc	bulk_density	ph	soc	drain_depth	drain_spacing	ghg_scenario	...	inter_crop_3	inter_crop_4	inter_crop_5	is_resi
3	11	45.41	19.19	46.07	1.35	7.0	0.0696	1.0	10.0	rcp45	...	NaN	Cover_crop	NaN	
4	3	48.30	44.93	21.21	1.20	7.0	0.0348	1.0	10.0	rcp45	...	NaN	NaN	NaN	
7	10	46.36	16.27	24.38	1.35	6.0	0.0348	1.0	10.0	rcp45	...	Cover_crop	NaN	NaN	
9	10	46.36	16.27	24.38	1.35	6.0	0.0058	1.0	10.0	rcp45	...	NaN	NaN	NaN	
13	4	47.50	73.51	9.76	1.35	7.0	0.0348	1.0	10.0	rcp45	...	NaN	NaN	NaN	
16	5	45.66	6.28	69.85	1.50	7.0	0.0522	1.0	10.0	rcp45	...	NaN	NaN	Cover_crop	
18	1	48.44	19.19	46.07	1.35	6.0	0.0522	1.0	10.0	rcp45	...	Cover_crop	NaN	Cover_crop	
20	6	45.13	44.93	21.21	1.20	5.0	0.0348	1.0	10.0	rcp45	...	NaN	NaN	NaN	
25	10	46.36	73.51	9.76	1.50	5.0	0.0696	1.0	10.0	rcp45	...	NaN	NaN	NaN	
27	6	45.13	16.27	24.38	1.20	6.0	0.0522	1.0	10.0	rcp45	...	Cover_crop	Annual_grass	NaN	

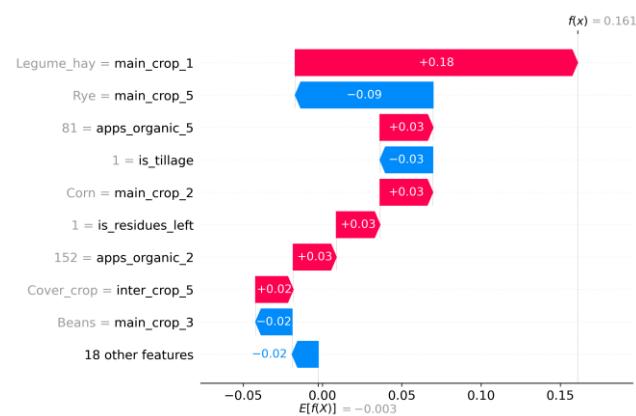
10 rows × 53 columns

Machine Learning model
(RF, XG-Boost, ExtraTrees)

Metrics	R2	RMSE	MAE
	0,7115	0,2695	0,1910



XG-Boost (best prediction model)



Projet RQRAD UdeS Y. Bouroubi – M. Leduc - S. Foucher – M.-O. Gasser – M.-É. Samson

Matière organique des sols : potentiel et meilleures pratiques à l'échelle de la parcelle

Simulations DNDC + IA → potentiel de MOS et pratiques agricoles

The LLM provides feature embeddings that serve as extracted features for classical regression models like RF and XGBoost

LLM → servira à lire les données et à répondre aux 2 questions

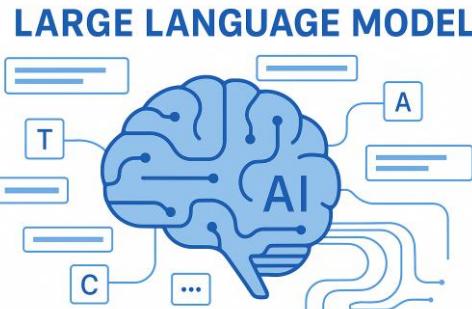
Fine-tuning adapts the LLM to a specific task by training it on domain-relevant data, allowing the model to produce more specialized and accurate prediction.

Tang, E., Yang, B., & Song, X. (2024). Understanding llm embeddings for regression. *arXiv preprint arXiv:2411.14708*.

Song, X., Li, O., Lee, C., Yang, B., Peng, D., Perel, S., & Chen, Y. (2024). *Omnipred: Language models as universal regressors*. *arXiv preprint arXiv:2402.14547*.



The input dataset can include any structured file format such as : .txt, .json, .ndjson, or Markdown.





Merci de votre
attention



Samuel Foucher



Samuel.Foucher@USherbrooke.ca

