



La Révolution des Datas et de l'Intelligence Artificielle en Agriculture

Winter School 2021 Digital Bioeconomy
9 février 2021

Angelo Steffanel

Laboratoire d'Informatique en Calcul Intensif et Image pour la Simulation

URCA, Reims

angelo.steffanel@univ-reims.fr

09/02/2021



Big Data et Intelligence Artificielle : une combinaison gagnante



- L'Apprentissage Automatique définit un grand ensemble de méthodes statistiques
 - Méthodes de classement, de prédiction, de clustering
 - Méthodes guidés (supervisés) ou pas
 - Méthodes simples (régression) ou complexes (réseaux neuronaux)
- En règle générale, plus de données, mieux c'est
 - Possibilité d'extraction de "motifs"
 - Possibilité de valider les modèles avec des nouvelles données
- Mais pour cela, il faut connaître suffisamment l'objet d'études
 - Sinon, risque de la "malédiction de la dimensionnalité"
 - Problème : l'agriculture (et toute science du vivant) n'est pas simple à saisir



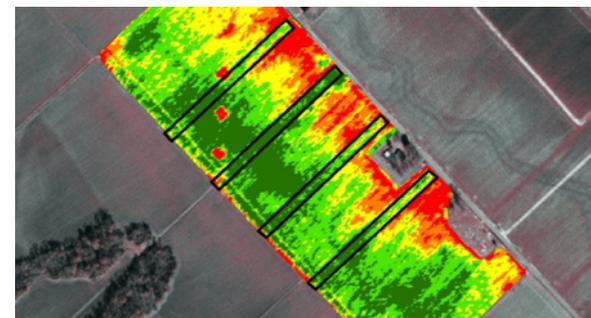
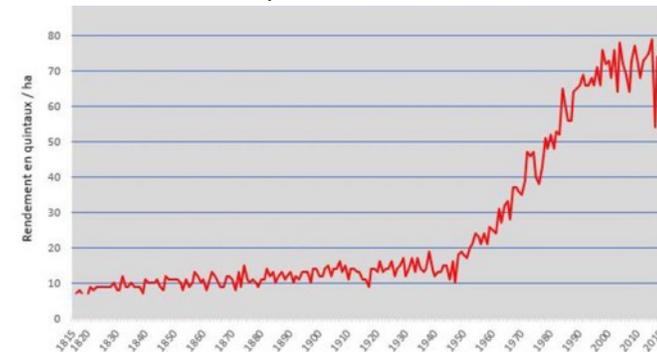


Agriculture de Précision : un contraste d'échelles



- Potentiel de données important
 - Chaque parcelle est une source potentielle
- Séries temporelles courtes et souvent bruitées
 - Respect des cycles végétatifs
 - Énormément de facteurs corrélés (météorologie, progrès techniques)
- Profusion de données "spatiales"
 - Courbes de niveau guidées par GPS
 - Images satellite, avion, drones
 - NDVI, multispectrale
- Manque de données "sur place"
 - Peu d'images et analyses au pied des plantes
 - L'agriculture ne se résume pas à un champ de blé

rendement moyen annuel du blé 1815-2018



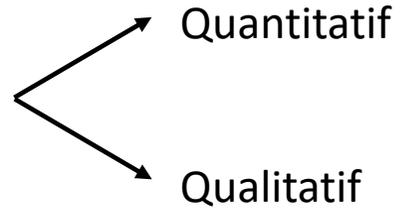


Problématiques de l'Agriculture de Précision



1

Évaluation Rendement



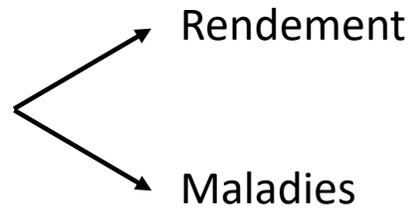
Problématiques économiques et culturelles

Récolte, transport, transformation



2

Prédictions



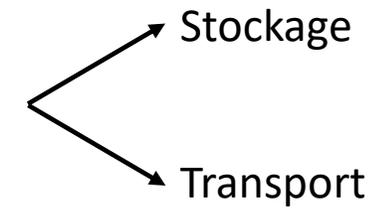
Modèles intégrant données historiques (rendement, météo, ...), données mesurées et observations

Modèles intégrant données historiques (date du début d'infection, lieux, météo ...) et observations



3

Suivi qualité



Besoins :

- **Données historiques (séries temporelles)**
- **Données sur les champs/parcelles**
- **Données sur les plantes**



Artificial Intelligence for Digitizing Industry (H2020 AI4DI)

- Plus de 40 partenaires
- **Intégration de l'IA dans les chaînes de production**
- Preuve de concept
 - Systèmes mis en œuvre
 - Difficultés rencontrées
 - ...

- **A Reims:**

- Viticulture de précision

- Partenaires: Maison de Champagne Vranken-Pommery, STMicroelectronics, Technext, CEA





Notre équipe et nos outils



Projet multidisciplinaire porté par les laboratoires :

- LICIS (Informatique)
- RIBP (Biologie)



Utilisation des ressources de calculs disponibles à l'URCA :

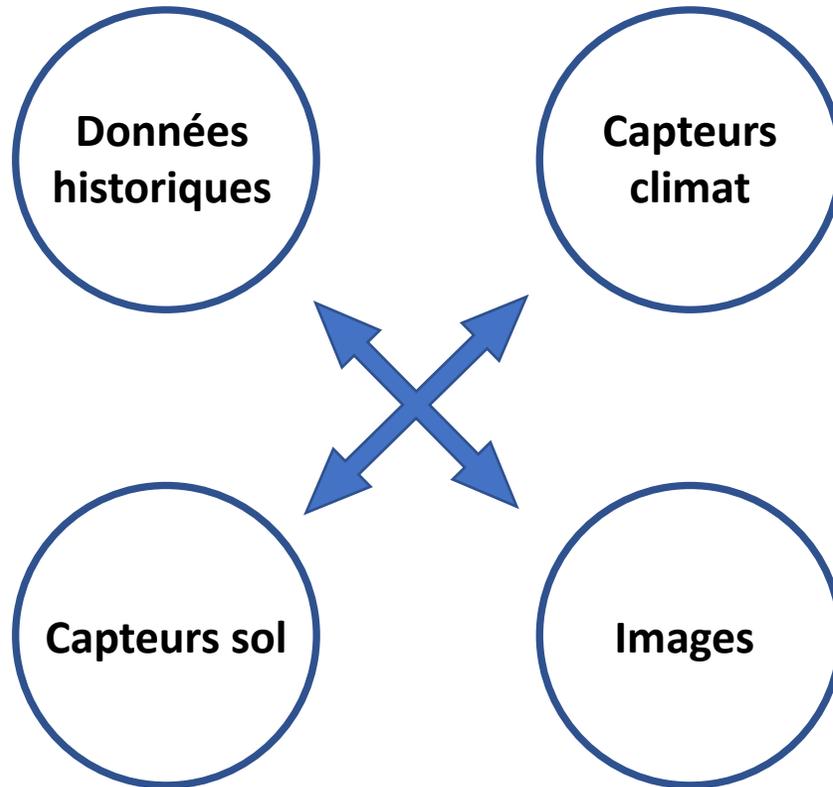
- Supercalculateur ROMEO
- Station Nvidia DGX-1 dédiée à l'apprentissage profond
- Accélération GPU (indispensable pour l'apprentissage)



09/02/2021



Capteurs dans le vignoble et dans les pressoirs



Prédictions

Rendement
Maladies / carences
Qualité du raisin



Estimation du rendement de la vigne

- Estimer le rendement de la vigne le plus tôt possible pour :
 - Prendre les bonnes décisions pour préserver la qualité des fruits
 - Préparer les vendanges
 - Respecter les normes (rendement limité, 8000 kg/ha en 2020 pour le Champagne)
- L'estimation du rendement en pratique :
 - Prélèvements aléatoires des fruits
 - Comptage et pesée
- Équation du rendement :

$$\text{Rendement} = \text{Nb ceps} \times \text{Nb grappes(ou baies)} \times \text{Masse moyenne grappe (ou baie)}$$

- Approche limitée:
 - Erreur très variable selon la parcelle
 - Nombre d'échantillons limité car prélèvement destructeur

Au vignoble : Evaluer le rendement



Difficultés :

- Organes verts
- Luminosité changeante
- Env. 5% de l'image
- Grappes cachées par les feuilles
- Distance caméra-rang peut varier

Evaluation du rendement : Détection par caméra

- Nombre de grappes
- Nombre de baies
- Volume des baies
- Si possible : nombre de fleurs



Détection automatique des grappes

- Détection et comptage automatique possible
 - Permet la détection à grande échelle en un temps limité
- Le traitement des images peut être difficile pour plusieurs raisons :
 - Images naturelles: variations de l'éclairage, du fond, de la distance etc.
 - Spécifique à la vigne: fleur/fruit de petite taille, couleur proche du feuillage



Inflorescences



Baies avant la véraison



Cas « facile » (raisin noir)

Segmentation par seuillage

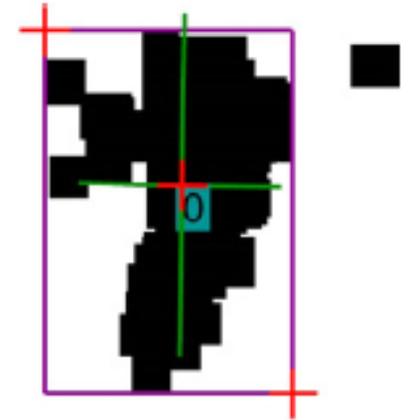
- Détection des grappes avec des seuillages appliqués sur les pixels
 - Seuils choisis manuellement
- Conditions contrôlées: éclairage la nuit
 - Permet de supprimer le fond de l'image (sol, ciel, etc.)
- Temps d'exécution rapide

Mais :

- Difficilement reproductible
- Applicable seulement la nuit



(a)



(b)

Fig. 3. Example of identification final result: (a) original image; (b) identification result.

Détection basée sur la forme ou la réflexion de la lumière

- Une autre approche : détecter les raisins
- Forme sphérique et réflexion de la lumière sur la surface des baies
- Filtrage nécessaire pour retirer les faux positifs
- Applicable la nuit ou la journée avec un flash
- Limitée aux objets sphériques



Figure 1: single berry

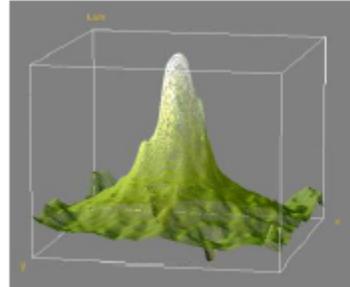
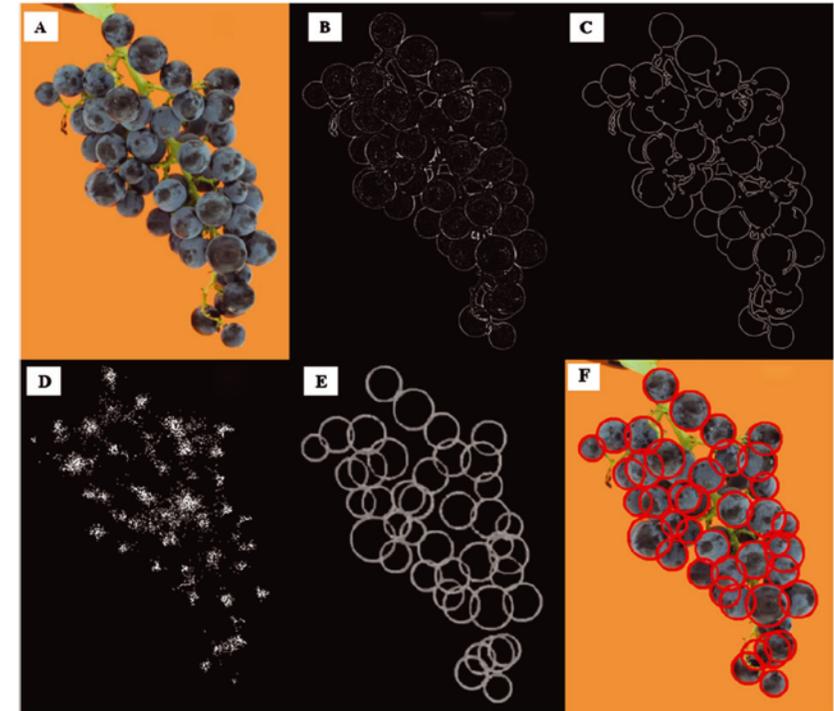


Figure 1b: light reflection of a single berry

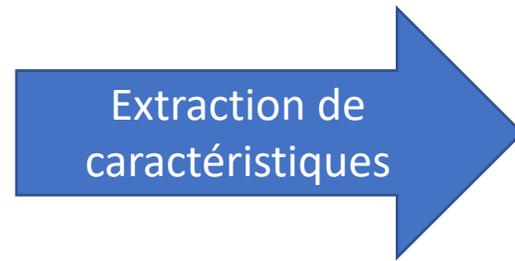




Classification par patch



- Entraîner un classifieur (SVM, régression logistique, etc.) sur des voisinages de pixels
- Extraction de caractéristiques nécessaires
 - Réduction de la dimension
 - Méthodes sélectionnées manuellement selon le type d'images



Moyenne de couleur RGB
(41, 217, 65)



Raisin



Beaucoup de méthodes d'extraction de caractéristiques ont été étudiées

- Zernike moments
- Local structure tensor
- Histogram of Oriented Gradients
- Moyenne/écart-type





Limites de la classification par patch

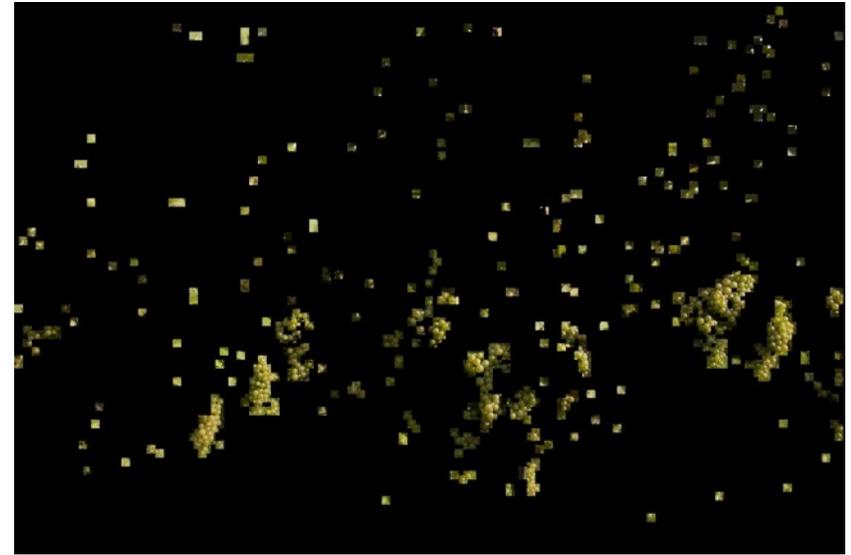
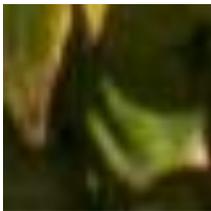
- Temps d'exécution potentiellement très long selon les méthodes utilisées
- Le modèle n'exploite que des propriétés locales de l'image (patch de taille limitée)
- Résultat fortement bruité et taux de détection limité



Baie:



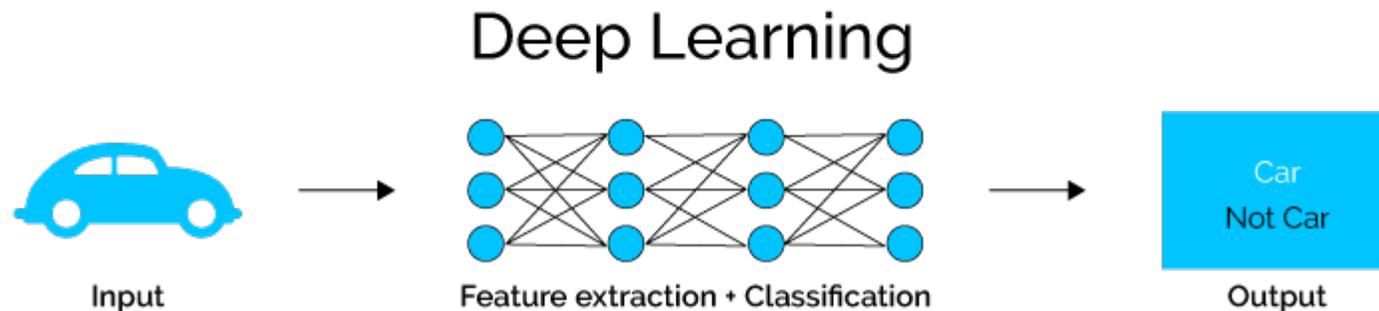
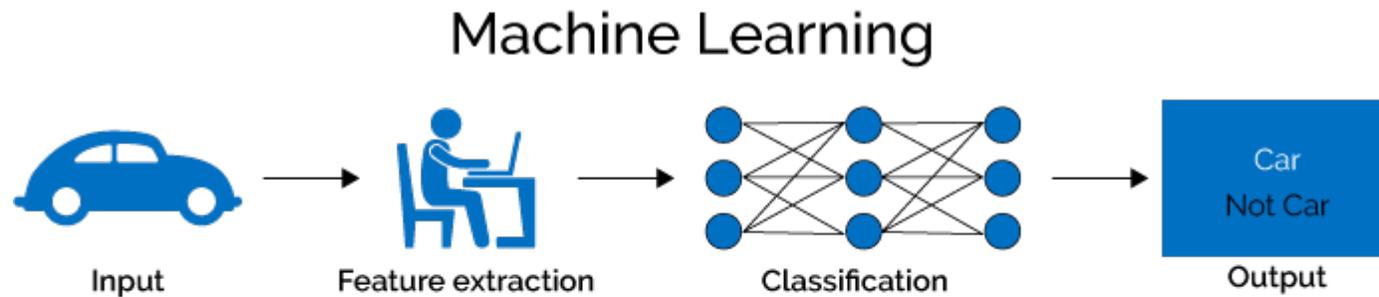
Fond:



Reproduction des travaux de [9]

Apprentissage profond pour les images

- L'apprentissage profond désigne les réseaux de neurones modernes
 - « Profond » car le réseau contient plusieurs couches de traitement successives
- Pour les images: réseau de neurones convolutifs (CNN)
- Le modèle apprend les bonnes représentations à partir des données



Modèle encodeur-décodeur pour la segmentation sémantique



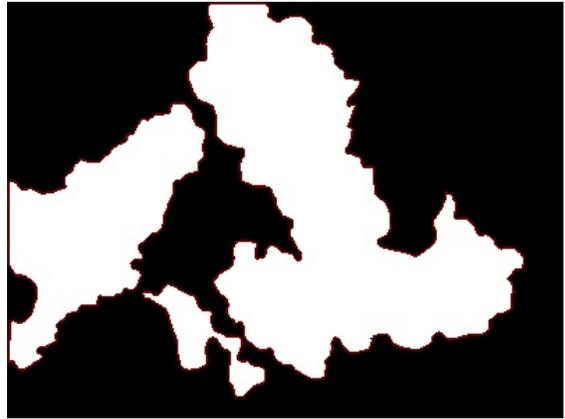
Encodeur



Cartes de caractéristiques



Décodeur



Réduction de la dimension et extraction de caractéristiques

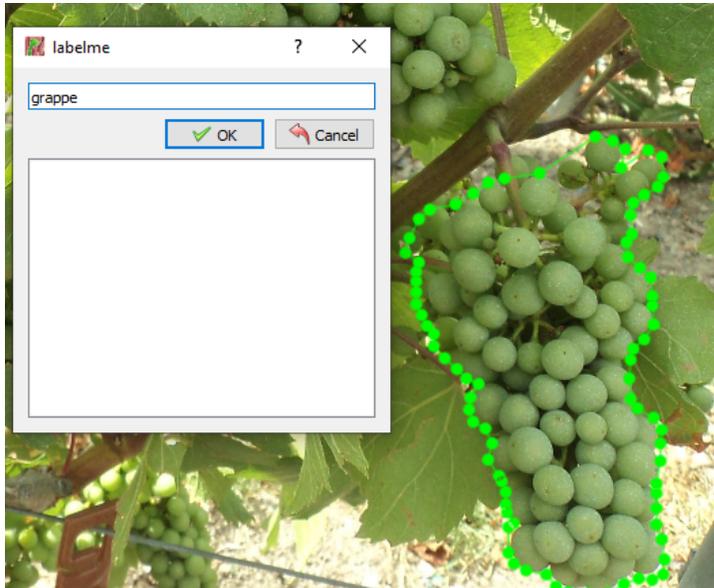
Création du masque de prédiction



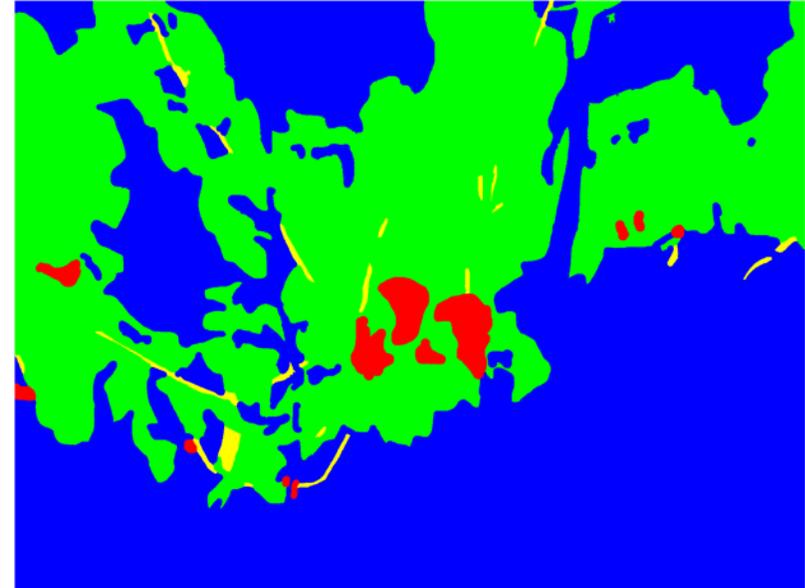
Base de données et étiquetage

- Les modèles utilisés sont supervisés
- Ils ont besoin d'une base d'exemples étiquetés (le résultat attendu est connu)
- Environ 350 images prises sur le terrain pour l'apprentissage (+200 pour l'évaluation)
- Images prises en juillet 2019 avant la véraison
- Très chronophage

Cas binaire, entourage avec un polygone (LabelMe)

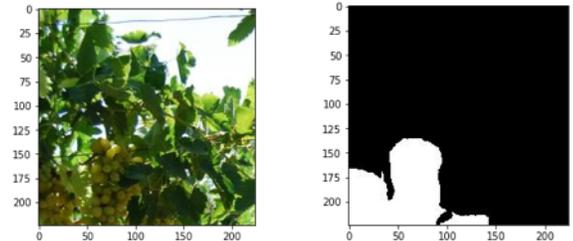


Multi-classe avec Pixel-Annotation-Tool

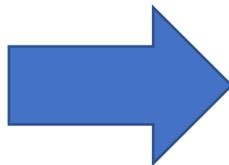
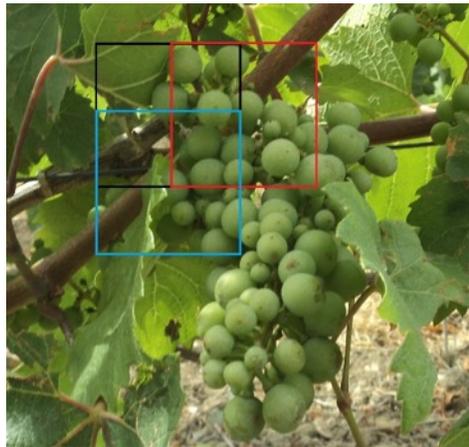


Préparation des données et apprentissage

- Ce type de modèle nécessite beaucoup de mémoire
- L'apprentissage est donc réalisé sur des patches extraits des images



Exemple avec des patches de 512 x 512 pixels:
10 Go de RAM nécessaires sur le GPU
Avec 16 patches par mini-batch



Plusieurs problématiques de performance:

- Les patches doivent tenir en mémoire
- Il faut qu'ils soient suffisamment grands pour traiter des images de grande taille
- L'utilisation de plusieurs GPU est recommandée

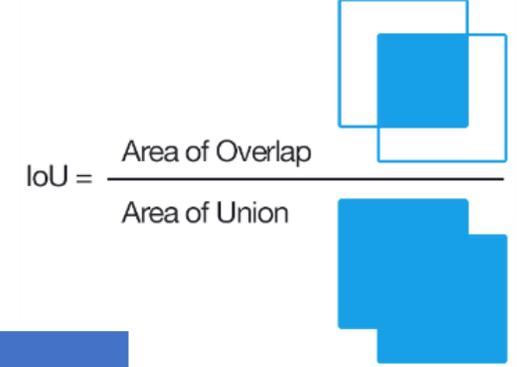
Exemple:

Apprentissage avec 20k patches de 512 x 512
13 min / epoch sur un seul GPU Nvidia Tesla V100



Évaluation

- Performances évaluées pixel par pixel
 - Intersection over Union (IoU)
 - Rappel / Précision / F1
- Évaluation sur 2 bases de données et comparaison avec d'autres méthodes



Base de données	Modèles	F1	IoU
Berenstein2010	CNN*	0,72	0,56
Berenstein2010	Unet	0,86	0,76
URCA	CNN*	0,39	0,27
URCA	Unet	0,8	0,69

*Classification par bloc avec un CNN

Berenstein et al 2010 :
Conditions naturelles
avec ombrage important

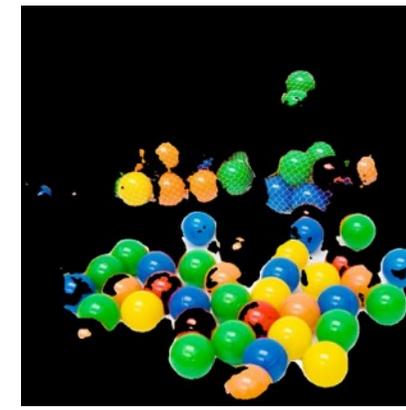


Exemple de résultats

- IoU limité par le manque de précision de l'étiquetage
- Détection proche de 100%
- Faux positifs proche de 0%



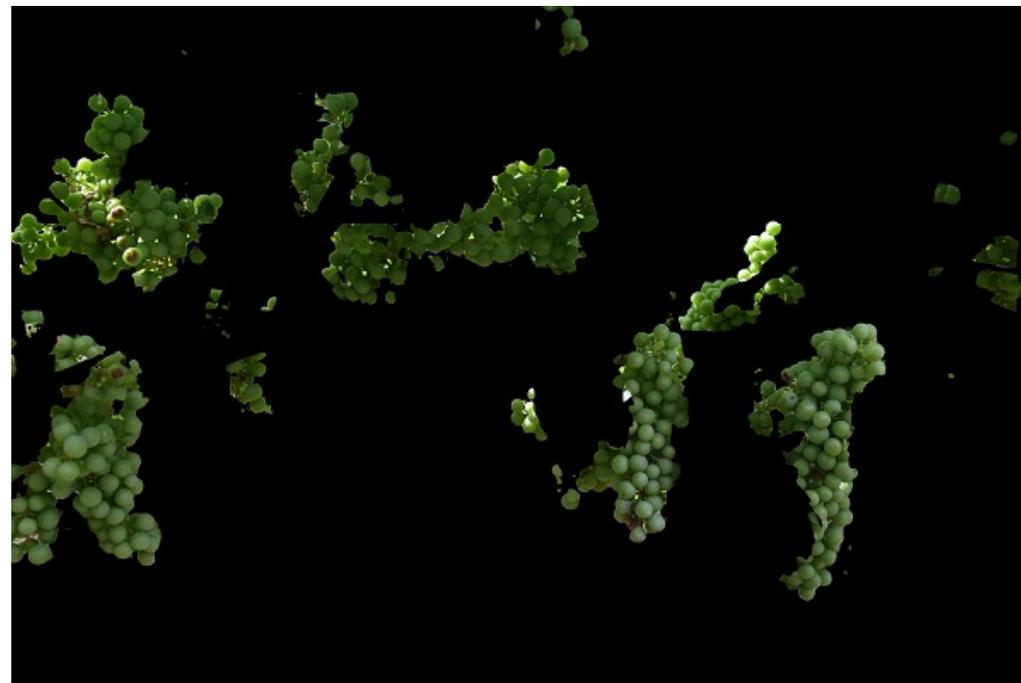
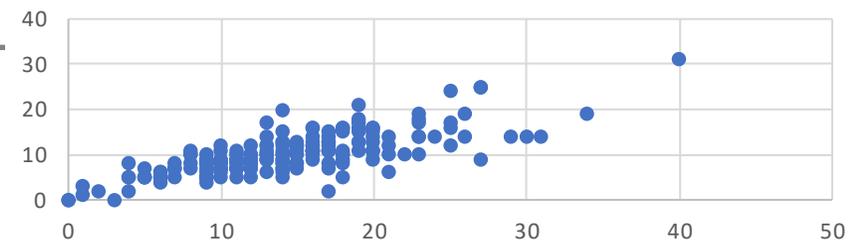
Le modèle semble avoir appris à détecter les groupes de sphères brillantes:



La problématique du comptage

- Le modèle ne détecte que les grappes visibles
- Il faut estimer le nombre total de grappes
 - Certaines grappes sont cachées
 - D'autres grappes sont collées ou « coupées » par les feuilles
 - Comment distinguer les grappes au second plan? (n'appartenant pas à la même rangée)

Nombre de grappes totales selon le nombre de grappes visibles



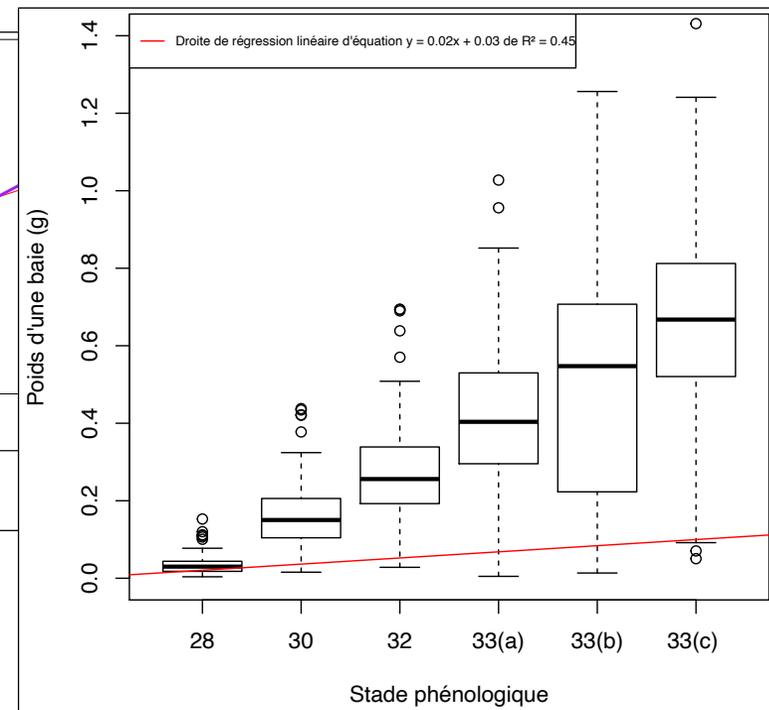
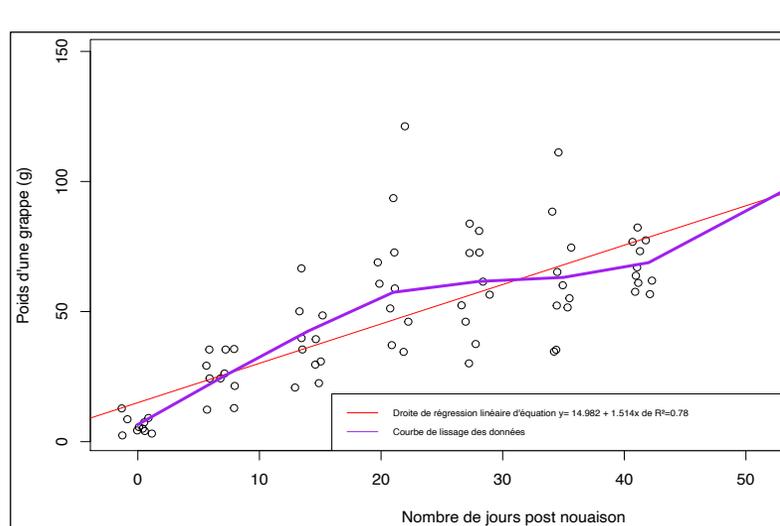


Évaluation du comptage

- Évaluation sur 4 rangs de vignes (200 pieds)
 - Les pieds sont pris en photo pour appliquer le modèle de segmentation
 - Nettoyage du masque de prédiction avec morphologie
 - Les grappes visibles et totales sont comptées
- Le nombre total de grappes est prédit avec une régression linéaire
 - Un modèle par rang
 - Évaluation croisée du modèle sur les 3 autres rangs
- Erreur allant de **0% à 31%** selon le rang et le modèle utilisé
 - Erreur moyenne: **12%**
- **Améliorations possibles:**
 - **modèle non linéaire**
 - **correction du comptage**

Limites de la prédiction des rendements

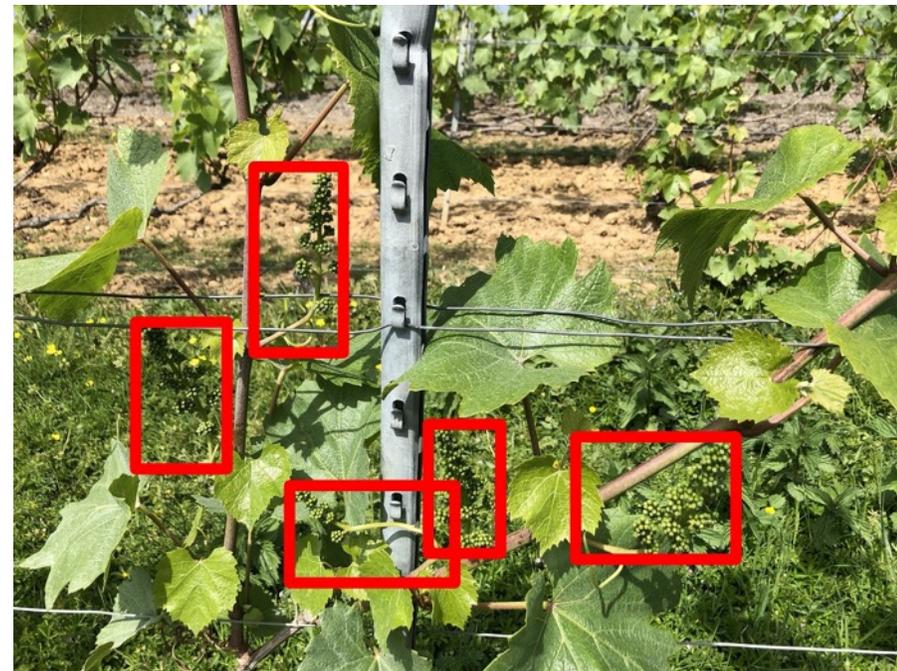
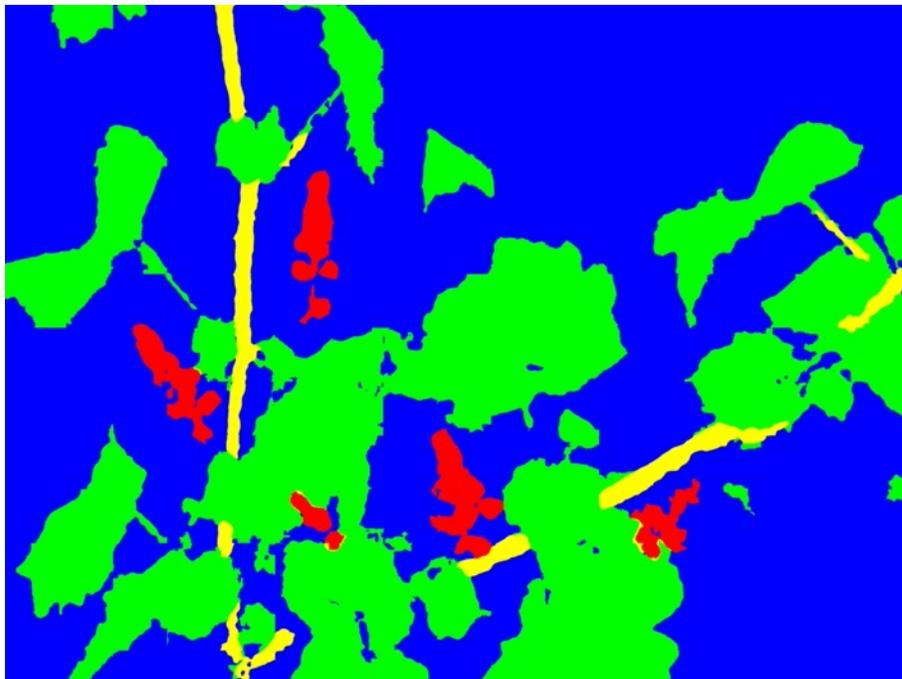
- En complément de nos images, un comptage/pesage des grappes a été fait par une stagiaire, de Juin à Août
 - comptage du nombre de grappes sur 100 pieds ; pesée de 10 grappes
 - dénombrement des baies des 10 grappes ; pesée des baies



Le poids des grappes varie beaucoup selon la pluviométrie

Amélioration de la segmentation

- Segmentation sémantique en plusieurs classes
- Modèle PSPNet (plus efficace qu'Unet utilisé actuellement)
- Fonctionne sur les inflorescences et les grappes
 - Précision ~80%, pas de faux positifs





Travaux en cours

- Segmentation sémantique: base robuste pour d'autres applications
 - Détection des maladies à partir des feuilles
 - Application pendant la phase de tri des vendanges
- Intégration des modèles dans des systèmes embarqués
 - Capture des données à grande échelle
 - Traitement et rendu sur place (edge computing)





Enfin...

- Beaucoup d'opportunités à explorer
 - Toute la chaîne de production et transformation
- Evolution rapide des technologies
 - Créer et entraîner un modèle IA peut prendre du temps
 - Mais très facile de déployer et utiliser un modèle
- Besoin de collaboration entre les informaticiens/data scientists et les experts du terrain
 - Saisir les spécificités des cultures
 - Sortir des pièges du "pur data"
- Plus d'informations : angelo.steffenel@univ-reims.fr