

# Sélection d'images satellites pour inversion bathymétrique par réseau de neurones convolutif

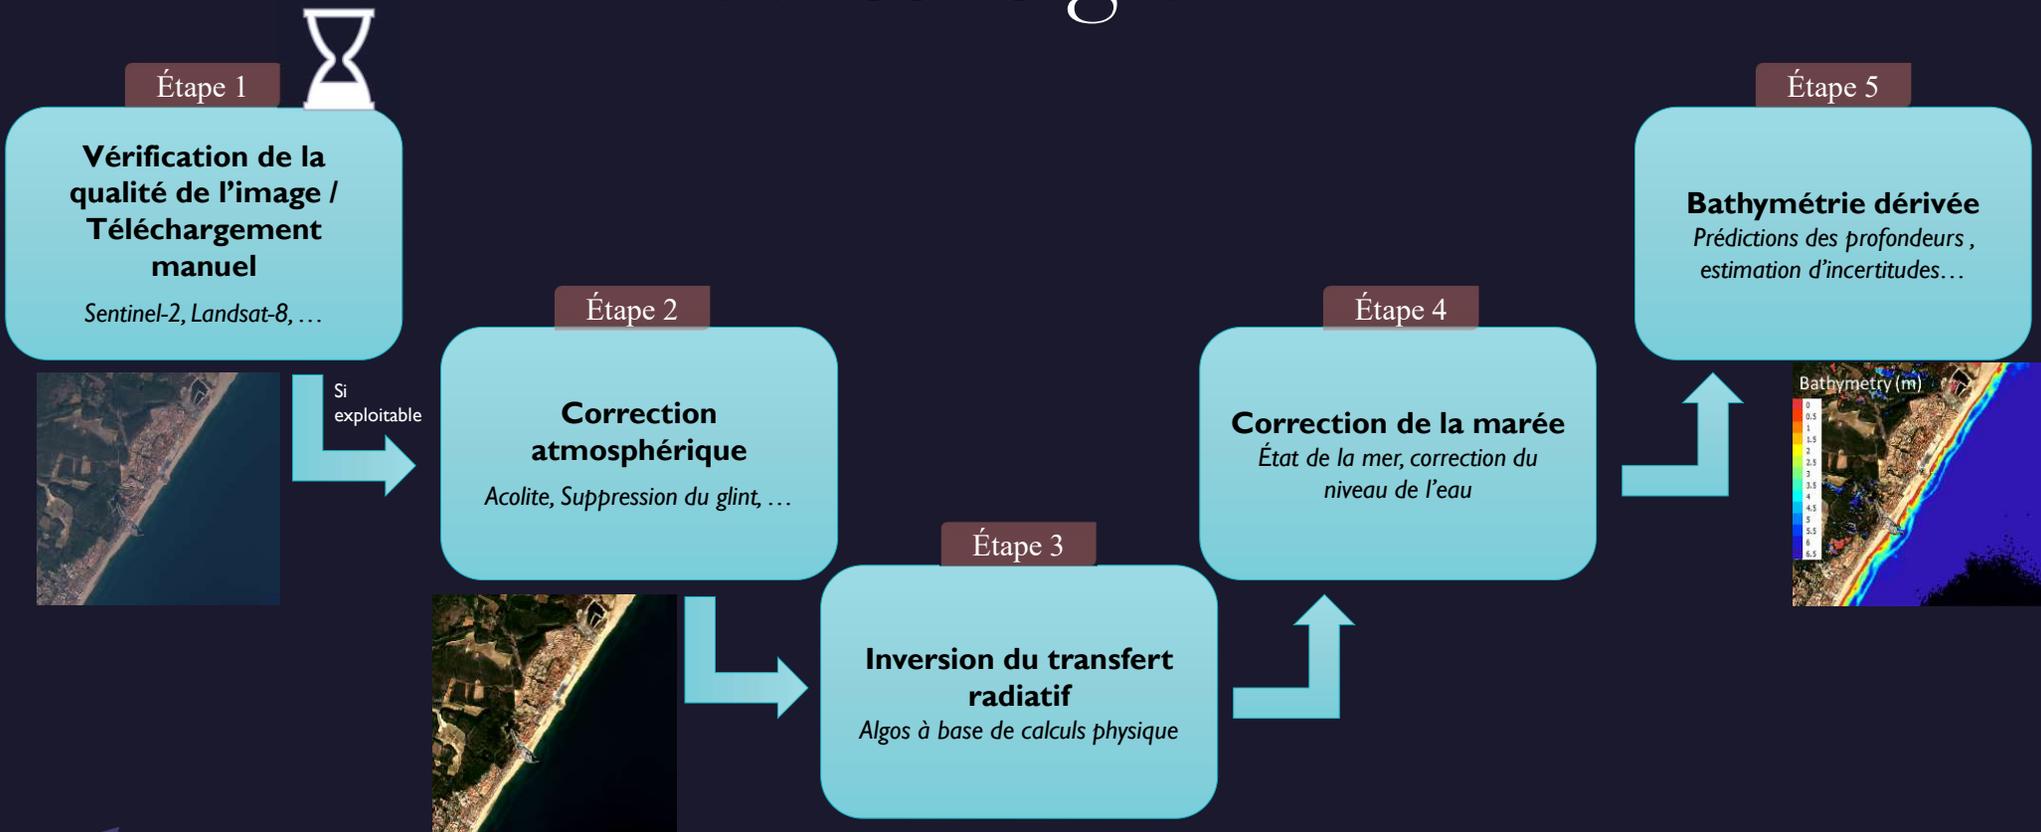
Amine Chemchem<sup>1,2</sup>, Guillaume Jubelin<sup>1</sup>, Gregory Cazanave<sup>1</sup>  
<sup>1</sup> IRT Saint Exupéry, Toulouse, France  
<sup>2</sup> Atos, Pole Data Driven Intelligence, Montpellier, France

# Plan

- Contexte
- Acolite et labélisation
- Apprentissage et validation
- Explicabilité et interprétabilité
- Conclusion et perspectives

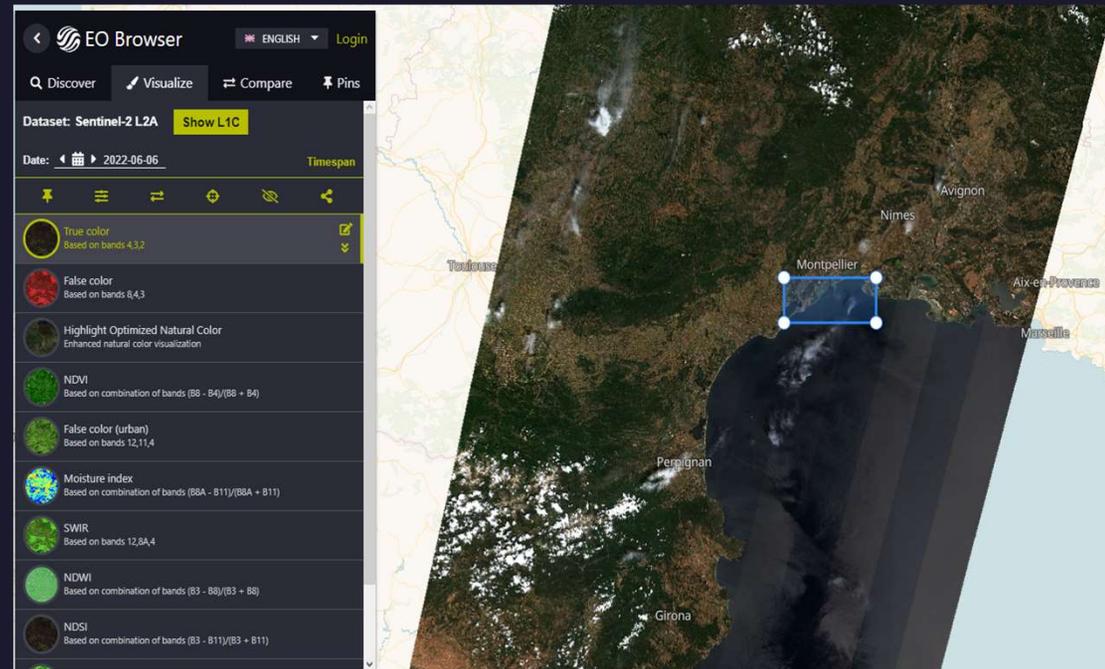


# Processus global



# Contexte

- La sélection des images est une tâche :
  - Manuelle
  - Nécessite un expert,
- Cette tâche est complexe car nécessite de prendre en compte plusieurs paramètres :
  - Contenu atmosphérique (couverture nuageuse, aérosols)
  - Etat de surface de la masse d'eau (déferlante, sillage, réflexion spéculaire)
  - Sa composition (turbidité, panaches turbides, remise en suspension, efflorescence algale)
  - Substrats du fond (herbier, sable, roches..)



Comment peut on automatiser cette tâche ? Comment réaliser cette sélection de façon précise et rapide à chaque nouvelle disponibilité d'images satellite ?

# Processus global

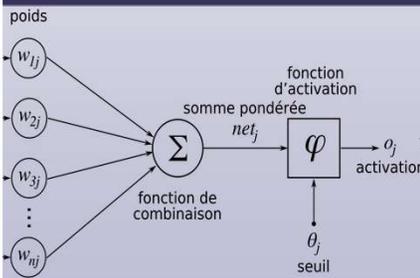
Étape 1



Étape 1

Automatiser la sélection d'images avec un CNN

Étape 5



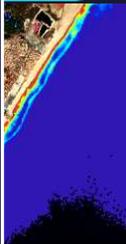
si classe =  
exploitable

télécharger l'image  
et lancer le process  
de calcul  
bathymétrique

si classe =  
Non exploitable

Rejeter l'image

ivée  
eurs,  
es...



# Idée : Utiliser Acolite

- Un processeur générique développé à l'IRSNB pour la correction atmosphérique et le traitement pour les applications côtières et intérieures.
- Il prend actuellement en charge de nombreux capteurs :  
Landsat (5/7/8) / Sentinel-2 (A/B), Sentinel-3 (A/B) /  
PlanetScope, Pléiades, WorldView.
- Dans notre cas d'usage on s'intéresse à 3 des paramètres qu'il permet de produire :
  - Matière en suspension ,
  - Turbidité ,
  - Chlorophylle

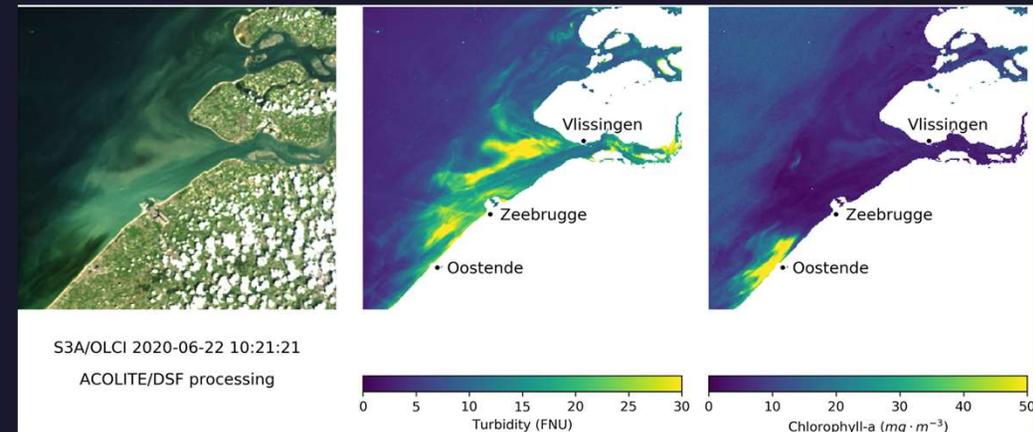
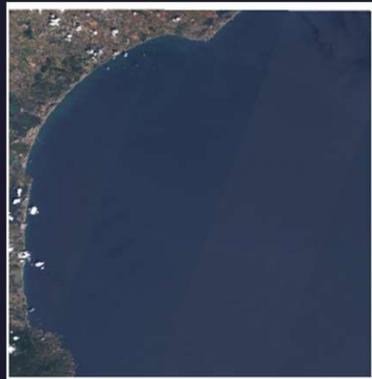


Figure : Exemple de cas d'utilisation d'Acolite

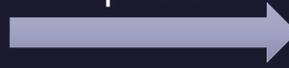
Source [1] <https://www.sciencedirect.com/science/article/pii/S003442572100002X>

Source [2] <https://odnature.naturalsciences.be/remsem/software-and-data/acolite>

# L'approche de labélisation proposée basée sur Acolite:



Découpage  
en patches



Sélection uniquement des  
patches de la bande littoral  
(15 km de la cote)  
Cote occitane

Pour chaque tuile dans mes\_tuiles :

Si  $0 < \text{Moyenne (matière en suspension)} < 10 \text{ NFU}$

et  $0 < \text{moyenne (turbidité)} < 20 \text{ g/m}^3$

et  $0 < \text{moyenne (Chlorophylle)} < 1.6 \mu\text{g/l}$  alors :

Tuile ← exploitable

Sinon

Tuile ← non\_exploitable



Patch768\_2560 (exploitable)



Patch768\_2816 (exploitable)

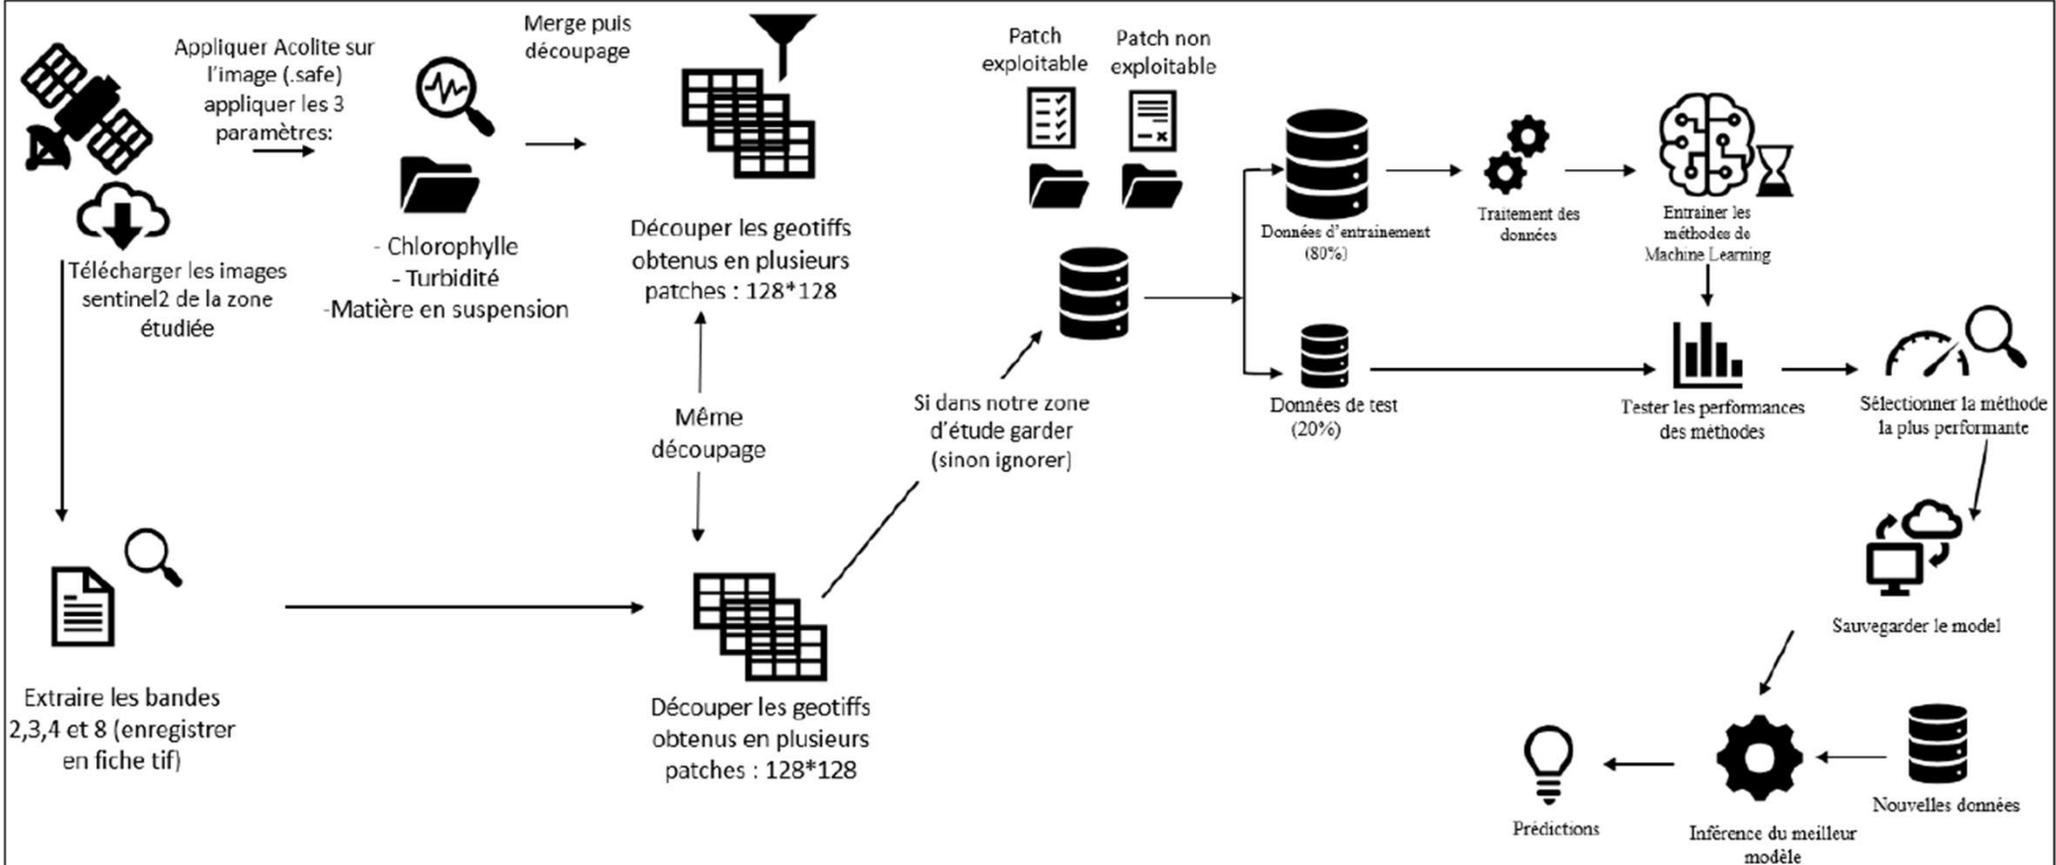


Patch1536\_1536 (non exploitable)

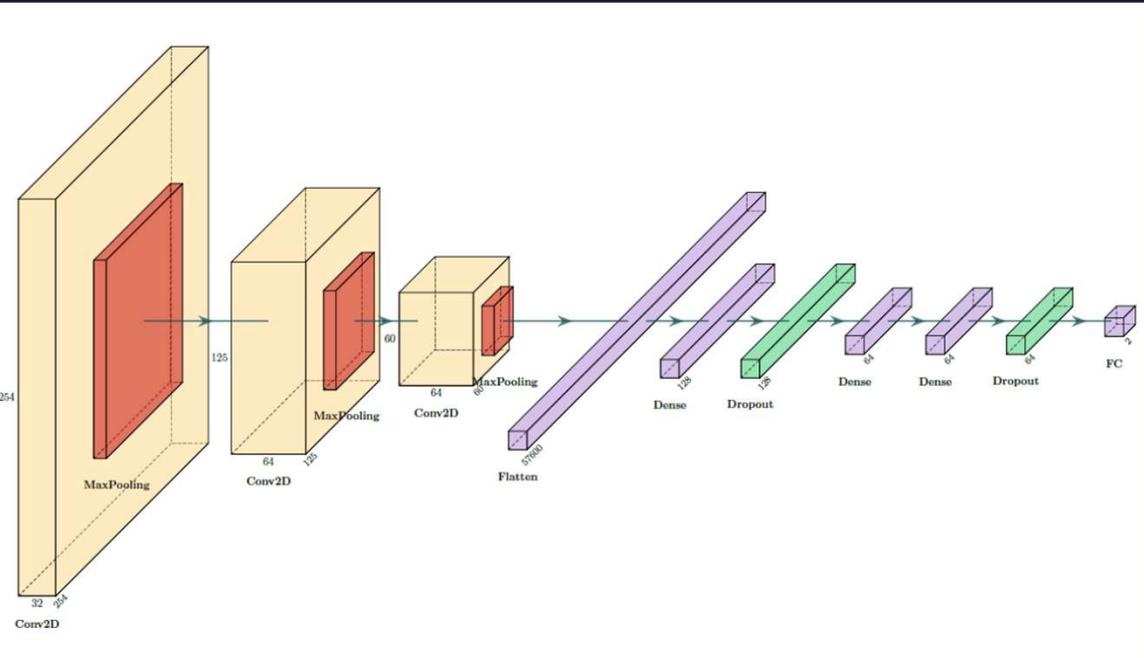


Patch1792\_1536 (non exploitable)

# Schéma du workflow global



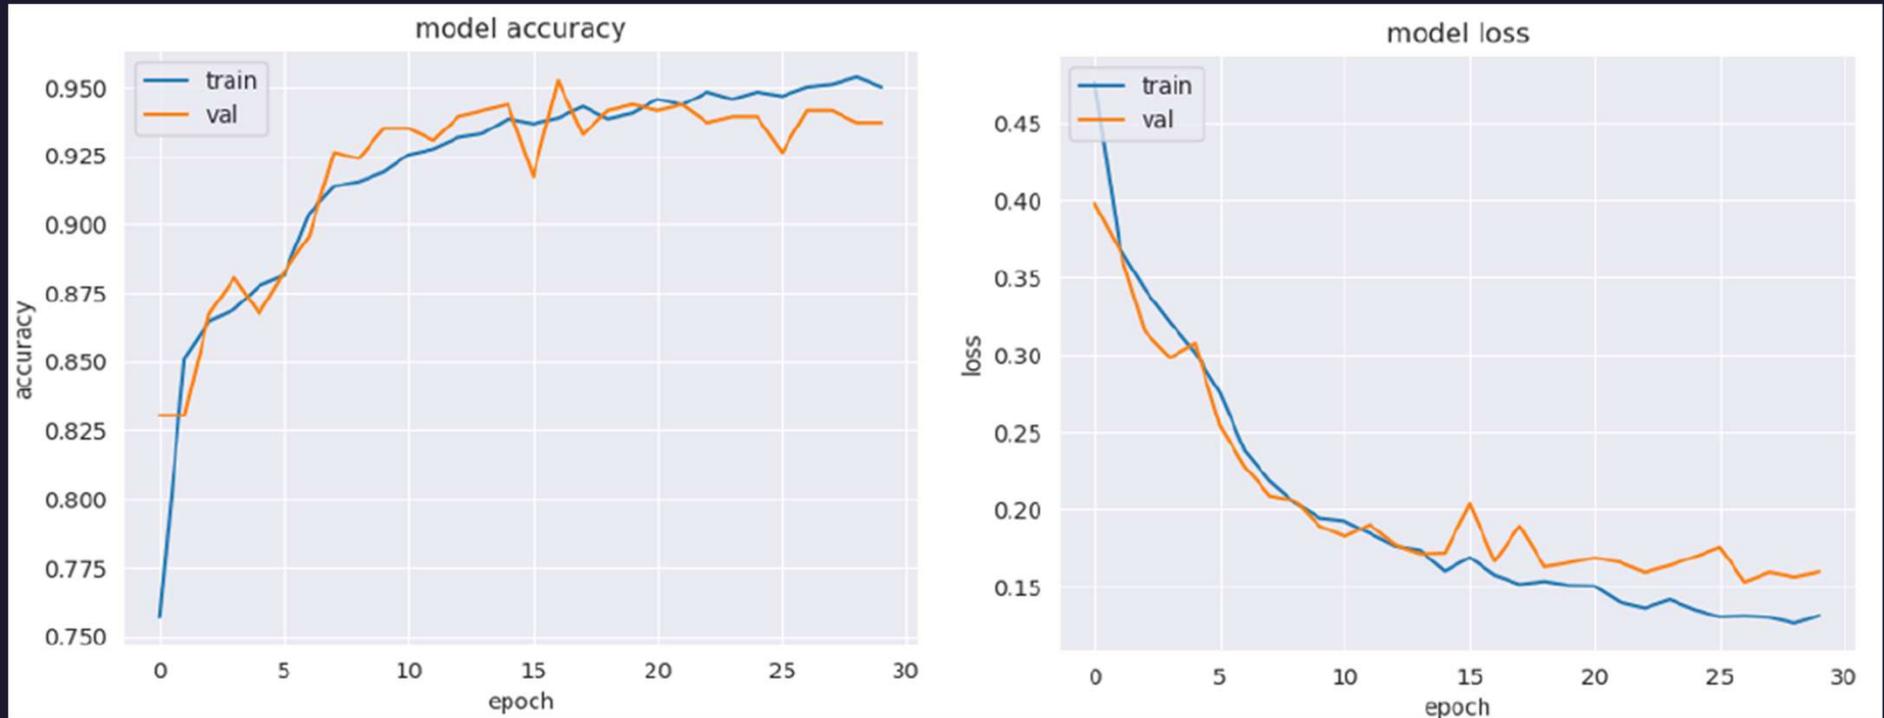
# Dataset et apprentissage



L'architecture du modèle retenue

Architecture	Hyperparamètres	f1-score
Conv2D_1(64) max_pooling2d_1 Conv2D_2(64) max_pooling2d_2 Flatten () Dense_1 (64) Dense_2 (2)	epochs=80 batch_size =16 Optimizer =Adam Learning Rate = 0.00001	76%
Conv2D_1(64) max_pooling2d_1 Conv2D_2(64) max_pooling2d_2 Conv2D_3(64) max_pooling2d_3 Flatten () Dense_1 (64) Dense_2 (64) Dense_3 (2)	epochs=80 batch_size =16 Optimizer =Adam Learning Rate = 0.00001	95%
Conv2D_1(64) max_pooling2d_1 Conv2D_2(64) max_pooling2d_2 Conv2D_3(128) max_pooling2d_3 Conv2D_4(128) max_pooling2d_4 Flatten () Dense_1 (128) Dense_2 (64) Dense_3 (2)	epochs=80 batch_size =16 Optimizer =Adam Learning Rate = 0.00005	92%

# Dataset et apprentissage



# Résultats et évaluation

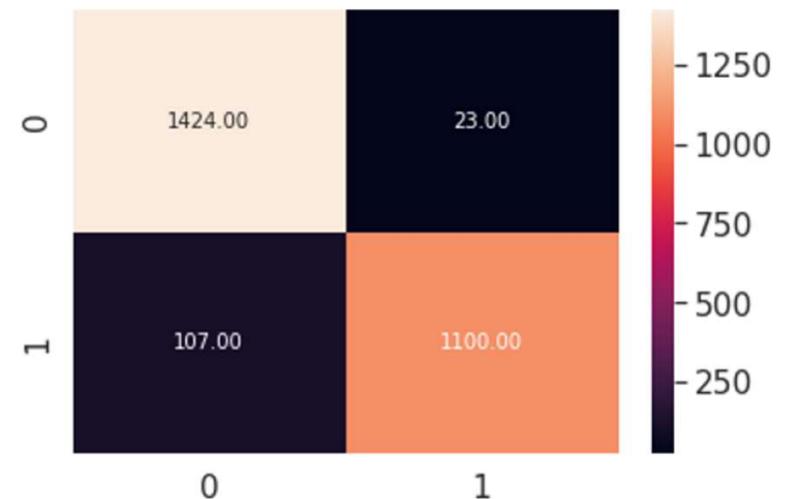
$$Accuracy(Taux\_de\_justesse) = \frac{VP + VN}{VP + VN + FP + FN}$$

$$Precision = \frac{VP}{VP + FP}, \quad Rappel = \frac{VP}{VP + FN}$$

$$F1-score = \frac{2 * Precision * Rappel}{Precision + Rappel} = \frac{2 * VP}{2 * VP + FP + FN}$$

VP : représente les vrais positifs,  
VN : les vrais négatifs,  
FP : les faux positifs,  
FN : les faux négatifs.

	precision	recall	f1-score	support
0	0.93	0.98	0.96	1447
1	0.98	0.91	0.94	1207
accuracy			0.95	2654
macro avg	0.95	0.95	0.95	2654
weighted avg	0.95	0.95	0.95	2654



# Introduction à l'explicabilité via Xplique



**RISE** : génère une carte d'importance indiquant le degré d'importance de chaque pixel pour le modèle.

- Chaque pixel est important pour la prédiction du modèle.
- Rise estime l'importance de manière empirique en sondant le modèle avec des versions aléatoirement masquées de l'image d'entrée et en obtenant les sorties correspondantes,

Ref : <https://arxiv.org/pdf/1806.07421.pdf%20/>

**Occlusion** : met en évidence les parties de l'image qui sont les plus importantes pour la classification d'un réseau profond.

- La méthode d'occlusion perturbe des petites zones de l'image en entrée en les remplaçant par un masque d'occlusion, généralement un carré gris.
- Le masque se déplace sur l'image et la modification du score de probabilité pour une classe donnée est mesurée en fonction de la position du masque.

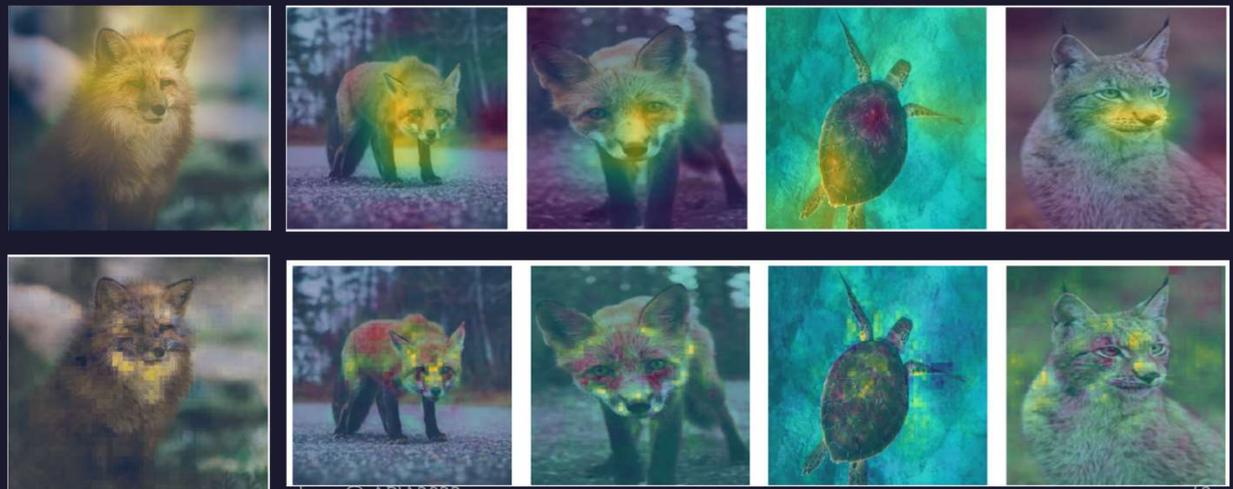
Ref : <https://arxiv.org/pdf/1311.2901.pdf>



Xplique

Rise

Occlusion



# Analyse et explicabilité

Les patches en RVB :



Patch768\_2560 (exploitable)



Patch768\_2816 (exploitable)

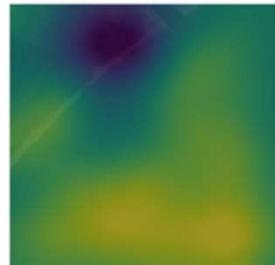
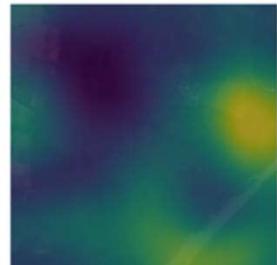
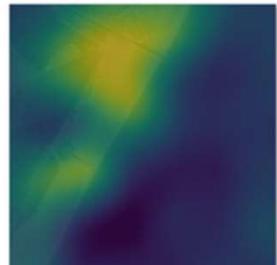
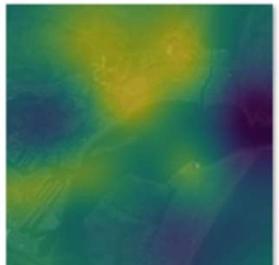


Patch1536\_1536 (non exploitable)

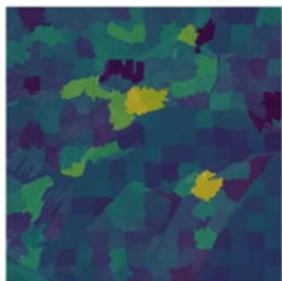


Patch1792\_1536 (non exploitable)

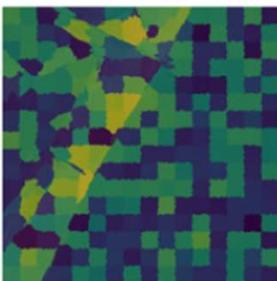
Explicabilité via Rise :



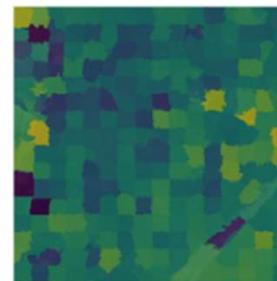
Explicabilité avec Occlusion



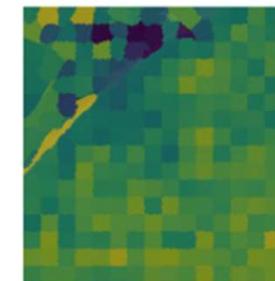
patch768\_2560.png



patch768\_2816.png



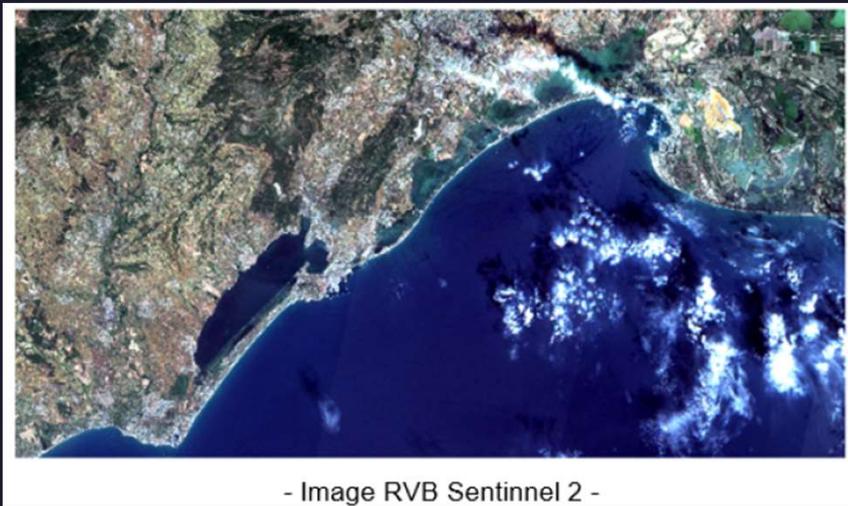
patch1536\_1536.png



patch1792\_1536.png

- Dans notre cas d'usage : D'après l'analyse de l'explicabilité, nous pouvons constater que :
  - Les méthodes donnent des cartes de chaleur assez similaires,
  - Des pixels représentant des zones habitées (zone terre) influencent sur la prise de décision du modèle  
→ Contrairement à ce qui est attendu. Vu que la phase de labélisation se base sur les pixels de la zone côtière pour les calculs des paramètres ACOLITE.

# Idée : Appliquer le masque terre et réentraîner le modèle



Appliquer le masque terre



Réentraînement du modèle

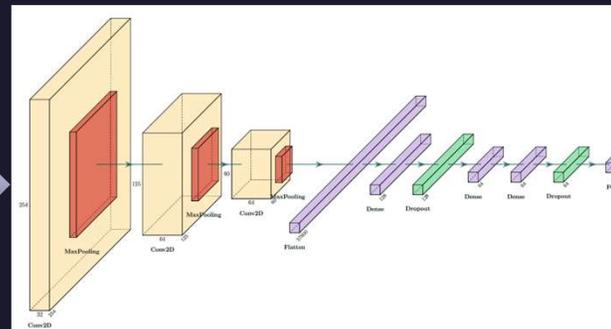


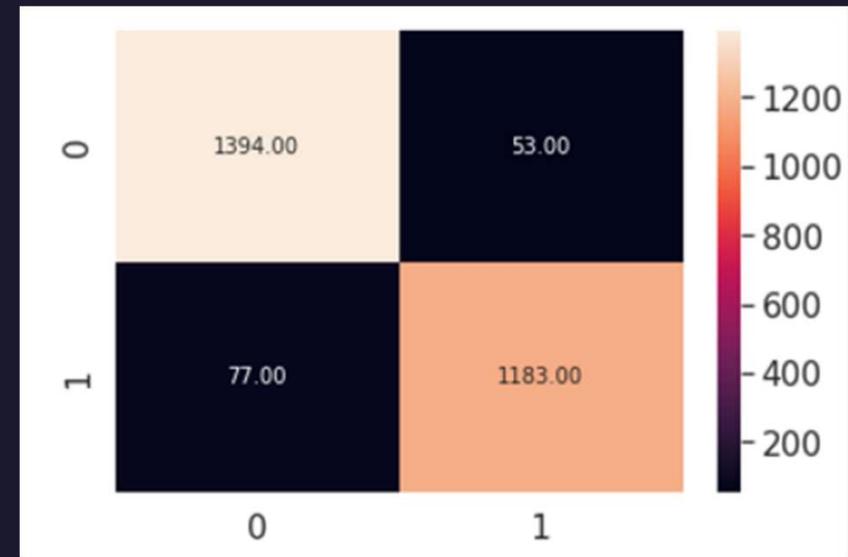
Image exploitable

Image non-exploitable

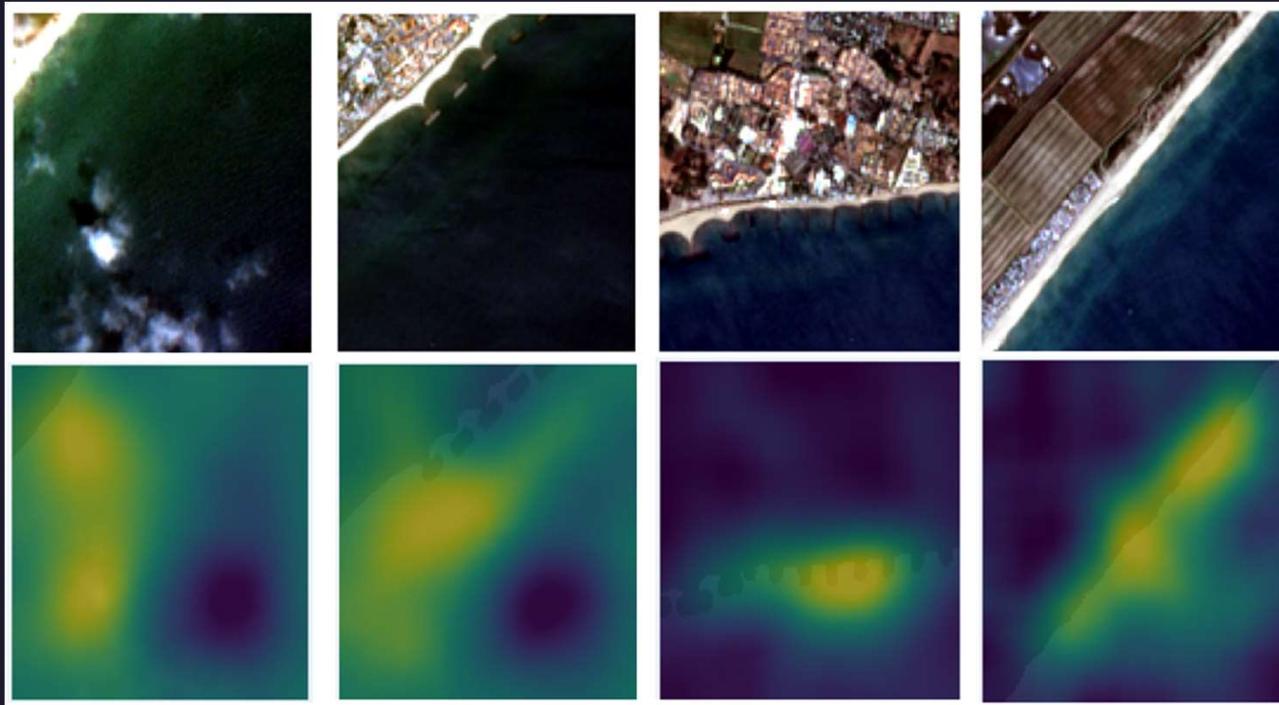
# Résultats et évaluation

- Le CNN entraîné sur les images masquées est plus performant que le modèle entraîné sur les images complètes,
- Sur 2707 images, le modèle se trompe sur 130 patches → 95,20% de précision.

	precision	recall	f1-score	support
0	0.95	0.96	0.96	1447
1	0.96	0.94	0.95	1260
accuracy			0.95	2707
macro avg	0.95	0.95	0.95	2707
weighted avg	0.95	0.95	0.95	2707



# Analyse et explicabilité

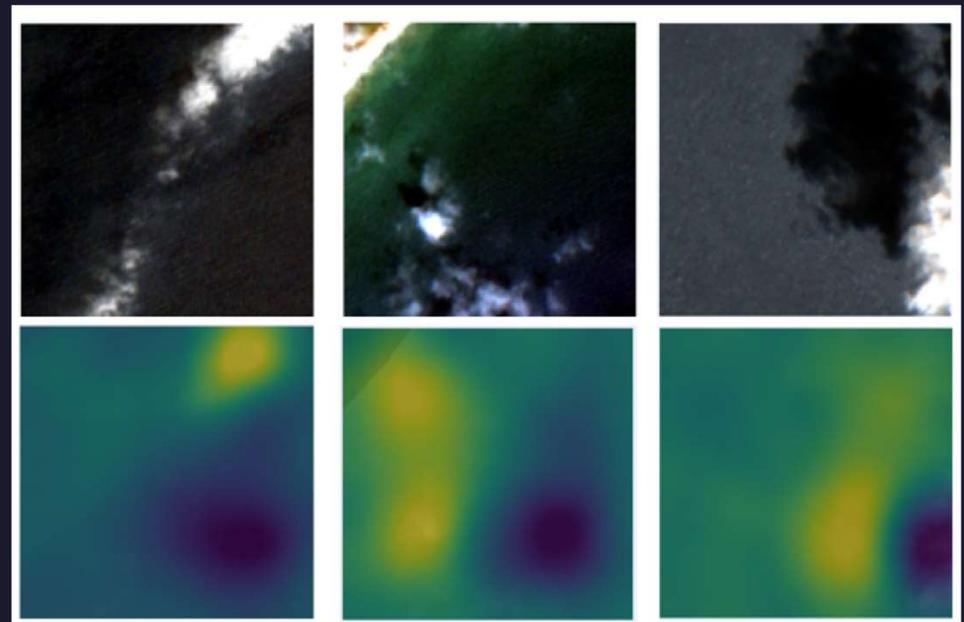


- Avec le CNN entraîné sur les images masquées, nous remarquons que les décisions sont prises à partir des pixels de la zone côtière,
- Contrairement au modèle entraîné avec les images complètes, et grâce à l'application du masque terre, nous avons pu guider le modèle à apprendre uniquement sur les données de la zone côtière.

# Conclusion et perspectives

- Le CNN implémenté est capable d'identifier de manière très précise si une image satellite est exploitable ou pas par le processus d'inversion bathymétrique (95% de précision).
- Grâce à un étiquetage efficace via l'outil ACOLITE , ainsi qu'au masque terre, nous avons pu guider le modèle à raisonner uniquement sur les pixels de l'image représentant la mer et à ignorer les pixels terre.
- Comme perspectives, nous prévoyons de:
  - Etudier la corrélation entre l'explicabilité et les paramètres physiques produites par ACOLITE.
  - Exploiter lors de l'apprentissage du modèle les masques de nuages et de leurs ombres fournis avec les produits. En effet, les travaux d'explicabilité ont montré que les nuages et leurs ombres peuvent induire en erreur le CNN.

Quelques exemples d'erreur de classification





# Merci

Amine Chemchem  
[lamine.chemchem@atos.net](mailto:lamine.chemchem@atos.net)