



HAL
open science

SACSAT - Suivi des activités conchyliques par satellite

Benoît Beguet, Rémi Budin

► **To cite this version:**

Benoît Beguet, Rémi Budin. SACSAT - Suivi des activités conchyliques par satellite. i-Sea. 2022, pp.64. ⟨hal-04346994⟩

HAL Id: hal-04346994

<https://ofb.hal.science/hal-04346994v1>

Submitted on 15 Dec 2023

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



HAL Authorization

SACSAT - Suivi des activités conchylicoles par satellite

*Développement d'un dispositif de suivi automatisé des zones d'activité
conchylicole par imagerie satellitaire à très haute résolution spatiale*

Rapport Méthodologique



31/03/2023

FICHE DOCUMENTAIRE

Date	31/03/2022
Maitre d'ouvrage	OFB, Office français de la biodiversité.
Réalisation	i-Sea 30 avenue de Canteranne 33400 PESSAC Site internet : http://i-sea.fr/fr/
Rédacteurs	Benoit Beguet : benoit.beguet@i-sea.fr Rémi Budin : remi.budin@i-sea.fr
Approbateur	Virginie Lafon : virginie.lafon@i-sea.fr
Citation recommandée	i-Sea, 2022. SACSAT : Suivi des activités conchylicoles par satellite, développement d'un dispositif de suivi automatisé des zones d'activité conchylicole par imagerie satellitaire à très haute résolution spatiale. Rapport Méthodologique, OFB/i-Sea, 64 p.

Table des matières

Table des matières.....	3
1 Contexte et objectifs de l'étude	6
2 Méthodologie.....	7
2.1 Forêt d'arbres décisionnels (Random Forest).....	7
2.2 Mise en œuvre pratique (Random Forest).....	7
2.3 Réseaux de neurones convolutifs et SegNet.....	8
2.4 Mise en œuvre pratique (SegNet).....	9
3 Données.....	10
3.1 Images satellite	10
3.2 Image aérienne	10
3.3 Comparaison des sources de données	15
4 Modèle Random Forest : application et évaluation des résultats	16
4.1 Typologie.....	16
4.2 Base de données d'apprentissage.....	17
4.3 Résultats cartographiques	18
5 Modèles SegNet sur les images satellites : application et évaluation des résultats.....	25
5.1 Modèle Cotentin	25
5.1.1 Base de données d'apprentissage.....	25
5.1.2 Résultats	34
5.1.3 Corrections manuelles	36
5.1.4 Comparaison de l'approche Random Forest à l'approche Deep Learning.....	36
5.1.5 Résultats cartographiques	36
5.2 Généralisation du modèle de prédiction	40
5.2.1 Base de données d'apprentissage.....	40
5.2.2 Evolution des résultats	40
5.2.2.1 Résultats sur les images du Cotentin utilisées pour l'entraînement du modèle Cotentin	40
5.2.2.2 Résultats sur l'image Cote Est de 2020 et les images du Bassin d'Arcachon	45
5.3 Comparaison avec le cadastre existant	45
6 Caractérisation des types d'activité conchylicole (SegNet multiclasse sur images aériennes).....	54
6.1 Typologie.....	54
6.2 Base de données d'apprentissage.....	54
6.3 Résultats	57
7 Conclusions.....	63
8 Bibliographie.....	64

Table des illustrations

Figure 1. Représentation de l'architecture SegNet, Badrinarayanan [7].	9
Figure 2. Emprise des zones d'étude sur le Cotentin, exemple des scènes Pléiades utilisées.	12
Figure 3. Emprise de la zone d'étude sur le Bassin d'Arcachon, exemple des scènes Pléiades utilisées.	13
Figure 4. Emprise de la zone d'étude de l'orthophotographie du ROL.	14
Figure 5. Comparaison des deux sources de données, satellite (à gauche) et aérienne (à droite).	15
Figure 6. Comparaison des deux sources de données, satellite (à gauche) et aérienne (à droite).	16
Figure 7. Guide de lecture d'une matrice de confusion.	20
Figure 8. Matrice de confusion obtenue sur l'ensemble de test pour le site "Côte Ouest", OA : Overall Accuracy (précision globale).	21
Figure 9. Matrice de confusion obtenue sur l'ensemble de test pour le site "Côte Est", OA : Overall Accuracy (précision globale).	22
Figure 10. Cartographie des surfaces d'activités conchylicoles et des milieux environnants par télédétection (Pléiades 50 cm), approche Random Forest – extrait (Tuile B3) de l'atlas cartographique du site « Chausey ».	23
Figure 11. Cartographie des surfaces d'activités conchylicoles et des milieux environnants par télédétection (Pléiades 50 cm), approche Random Forest – extrait (Tuile F1) de l'atlas cartographique du site « Côte Est ».	24
Figure 12. Exemple de digitalisation manuelle sur une image Pléiades.	26
Figure 13. Exemple de digitalisation manuelle sur un secteur "ROI GG" d'une image Pléiades (A : Prédiction du modèle Cotentin initial sur un secteur du site « Portbail » - B : Digitalisation manuelle sur ce secteur).	27
Figure 14. Répartition des zones analysées sur la scène Pléiades du 14/01/2022 sur le site de Chausey.	28
Figure 15. Répartition des zones analysées sur la scène Pléiades du 13/01/2022 sur le secteur nord du site Côte Est.	29
Figure 16. Répartition des zones analysées sur la scène Pléiades du 13/01/2022 sur le secteur sud du site Côte Est.	30
Figure 17. Répartition des zones analysées sur la scène Pléiades du 14/01/2022 sur le site Granville.	31
Figure 18. Répartition des zones analysées sur la scène Pléiades du 04/04/2020 sur le site Pointe d'Agon.	32
Figure 19. Répartition des zones analysées sur la scène Pléiades du 04/04/2020 sur le site Portbail.	33
Figure 20. Illustration des résultats de prédiction des deux stades d'entraînement du modèle Cotentin.	35
Figure 21. Comparaison des deux approches de détection d'activité conchylicole sur un secteur du site "Côte Est" (A : Random Forest, B : Segnet).	37
Figure 22. Cartographie des surfaces d'activités conchylicoles et des milieux environnants par télédétection (Pléiades 50 cm), approche Deep Learning, extrait (Tuile B3) de l'atlas cartographique du site « Chausey ».	38
Figure 23. Cartographie des surfaces d'activités conchylicoles et des milieux environnants par télédétection (Pléiades 50 cm), approche Deep Learning, g-extrait (Tuile F1) de l'atlas cartographique du site « Côte Est ».	39
Figure 24. Répartition des zones de digitalisations manuelles analysées sur la scène Pléiades du 16/03/2020 sur un secteur du site Côte Est.	41
Figure 25. Répartition des zones de digitalisations manuelles analysées sur la scène Pléiades du 05/11/2021 sur le site Bassin d'Arcachon.	42
Figure 26. Répartition des zones de digitalisations manuelles analysées sur la scène Pléiades du 14/07/2022 sur le site Bassin d'Arcachon.	43
Figure 27. Illustrations des résultats de prédiction des deux stades d'entraînement du modèle Cotentin et du modèle général.	44
Figure 28. Vue d'ensemble des prédictions cartographiques (modèle général Deep Learning) de l'activité conchylicole sur le site Bassin d'Arcachon (scène Pléiades du 14/07/2022) – aperçu 1.	46

Figure 29. Vue d'ensemble des prédictions cartographiques (modèle général Deep Learning) de l'activité conchylicole sur le site Bassin d'Arcachon (scène Pléiades du 14/07/2022) – aperçu 2.	47
Figure 30. Vue d'ensemble des prédictions cartographiques (modèle général Deep Learning) de l'activité conchylicole sur le site Bassin d'Arcachon (scène Pléiades du 05/11/2021) – aperçu 1.	48
Figure 31. Vue d'ensemble des prédictions cartographiques (modèle général Deep Learning) de l'activité conchylicole sur le site Bassin d'Arcachon (scène Pléiades du 05/11/2021) – aperçu 2.	49
Figure 32. Vue d'ensemble des prédictions cartographiques (modèle général Deep Learning) de l'activité conchylicole sur le site Côte Est (scène Pléiades du 16/03/2020.	50
Figure 33. Comparaison du modèle Cotentin (Deep Learning) avec le cadastre - site Côte Est, scène Pléiades du 13/01/2022.	51
Figure 34. Comparaison du modèle Cotentin (Deep Learning) avec le cadastre - site Granville, scène Pléiades du 14/01/2022.	52
Figure 35. Comparaison du modèle Cotentin (Deep Learning) avec le cadastre - site Pointe d'Agon, scène Pléiades du 04/04/2020.	53
Figure 36. Récapitulatif des différents éléments de la typologie des types d'activités conchylicoles.	55
Figure 37. Répartition des secteurs de digitalisation sur l'orthophotographie.	56
Figure 38. Matrice de confusion du modèle, créée à partir de l'ensemble de validation.	58
Figure 39. Visuels de comparaison RGB / Digitalisation / Prédiction illustrant chaque classe de la typologie.	59
Figure 40. Comparaison de la prédiction à la digitalisation manuelle sur un secteur d'étude élargi – zone 1.	60
Figure 41. Comparaison de la prédiction à la digitalisation manuelle sur un secteur d'étude élargi – zone 2.	61
Figure 42. Comparaison de la prédiction à la digitalisation manuelle sur un secteur d'étude élargi – zone 3.	62
Tableau 1. Images satellite (Pléiades) reçues pour ce projet sScènes utilisées dans l'étude en bleu clair et scènes mises de côté en gris).	11
Tableau 2. Résumé de l'effort de digitalisation pour l'apprentissage des modèles Random Forest.	18
Tableau 3. Evolution des performances des modèles sur l'ensemble de validation.	34
Tableau 4. Evaluation des performances des différents modèles sur l'ensemble de validation de la base de données d'apprentissage du modèle Cotentin.	40
Tableau 5. Evaluation des performances des différents modèles sur l'ensemble de validation de la base de données d'apprentissage du modèle Général.	45
Tableau 6. Résumé de l'effort de digitalisation sur l'orthophotographie.	57

1 CONTEXTE ET OBJECTIFS DE L'ETUDE

Le projet SACSAT vise à développer un dispositif automatisé de cartographie des activités conchylicoles reposant sur l'exploitation de données satellitaires à très haute résolution spatiale de type Pléiades. Il a vocation notamment à répondre aux besoins des opérateurs responsables de la mise en œuvre des directives européennes (Directive cadre sur l'eau (DCE) et Directive Cadre Stratégie pour le Milieu Marin (DCSMM)) en données fines, précises et actualisables, pour le suivi à grande échelle des changements affectant l'intégrité des fonds marins. Le projet est bâti sur l'expérimentation de deux approches de traitement des images Pléiades, le Machine Learning (algorithme des forêts aléatoires) déjà éprouvé pour des applications similaires de cartographie des habitats littoraux, notamment des formations benthiques intertidales à partir d'orthophotographies, et le Deep Learning (réseaux neuronaux convolutifs, Segnet), approche novatrice. Il vise également à répondre à des besoins de gestion à l'échelle locale et s'inscrit dans la continuité des expériences de cartographie des friches ostréicoles menées en partenariat avec le Parc Naturel Marin du Bassin d'Arcachon (PNMBA) [1].

Les travaux sont réalisés sur deux sites pilotes : le littoral du Cotentin et du Bassin d'Arcachon. Dans un premier temps, une cartographie binaire (présence/absence) des activités conchylicoles sera réalisée. A partir d'images satellites Pléiades, deux méthodes seront envisagées (Forêts aléatoires & SegNet) pour réaliser une cartographie à grande échelle. Dans un deuxième temps, une expérience visant à réaliser une cartographie plus détaillée des activités conchylicoles utilisera une image aérienne à très haute résolution combinée à l'utilisation de méthodes de classification (SegNet) déjà éprouvées dans le cadre des travaux menés en collaboration avec le PNMBA [2]. Ces travaux, entamés dès l'année 2018 avec une première phase de recherche et développement pour la cartographie automatique des friches ostréicoles se sont poursuivis jusqu'à aujourd'hui. Ils visent à doter le PNMBA d'informations spatialisées de précision pour la gestion du site du Bassin d'Arcachon, plus précisément sur les thématiques des friches ostréicoles, des activités de production ostréicole et du suivi du couvert végétal sur vasière. La méthodologie développée a fait ses preuves pour ces trois thématiques et produit aujourd'hui des cartographies à partir d'images aériennes (avec une résolution de 15 cm) et cela à l'échelle du Bassin d'Arcachon. Cette cartographie plus avancée devra permettre la distinction entre les différentes activités conchylicoles et le suivi de l'état des installations dédiées à la culture de coquillages.

2 METHODOLOGIE

Cette section détaille la méthodologie déployée par notre approche, en commençant par une brève présentation des méthodes envisagées et de leur mise en œuvre opérationnelle. Les premières expérimentations ont été menées sur les sites du Cotentin en effectuant une comparaison entre l'approche SegNet privilégiée et une approche plus classique (au niveau pixel) pressentie comme une méthode de second plan au cas où l'approche SegNet ne fonctionnerait pas avec la résolution proposée par Pléiades. Cette seconde approche que nous appellerons approche « Random Forest » est utilisée pour la cartographie des habitats naturels par télédétection multi-temporelle satellitaire dans le cadre du service Biocoast (service commercial développé et déployé par i-Sea).

Après avoir appliqué les deux méthodes sur les sites du Cotentin, l'approche la plus performante sera appliquée sur le site du Bassin d'Arcachon et sur de nouvelles images dans un premier effort de généralisation.

Nous héritons au départ de toute l'expérience acquise sur le Bassin d'Arcachon pour la mise en œuvre de l'approche SegNet, avec notamment un processus de raffinements successifs du modèle de prédiction permettant d'optimiser les allers-retours homme machine. Il reste cependant un certain nombre d'incertitudes au début du projet Sacsat au sujet d'adaptations à faire en termes de dimensionnement du problème (taille des images et dimension du contexte spatial, choix des paramètres d'optimisation du modèle, etc...), la question de la résolution limite (50 cm) de Pléiades et la dimension des objets à détecter (tables et espaces entre les tables) restant la contrainte principale du projet.

2.1 Forêt d'arbres décisionnels (Random Forest)

Les Random Forests ou forêts aléatoires ont été introduites par Breiman [3]. C'est un algorithme d'apprentissage statistique très performant, à la fois pour les objectifs de classification mais aussi de prédiction. L'algorithme appartient à la famille des méthodes d'ensemble de classificateurs. Le principe général de ces méthodes est de construire une collection de classificateurs (prédicteurs) en nombre réduit, pour ensuite agréger l'ensemble de leurs prédictions afin d'obtenir un classificateur robuste. Le classificateur de base considéré est un arbre de décision de type Classification and Regression Tree (CART) [4] dont le principe général est de partitionner récursivement l'espace d'entrée de façon dyadique, puis de déterminer une sous-partition optimale pour la prédiction.

Biocoast, basé sur le couplage intelligent entre une série multi-temporelle d'images satellite et les données terrain, propose une méthode automatisée articulée autour de cet algorithme classificateur des *Random Forest*. Cette approche a démontré son potentiel opérationnel pour accompagner les acteurs de la biodiversité dans leurs travaux de cartographie des végétations et des habitats des espaces naturels littoraux et terrestres. Elle peut également être utile à d'autres cas d'application visant à des cartographies fines de l'occupation des sols.

2.2 Mise en œuvre pratique (Random Forest)

L'adaptation de la chaîne de traitement Biocoast à la présente étude a pour but de réaliser une cartographie exhaustive de l'occupation et / ou des usages des estrans et petits fonds littoraux,

en incluant l'activité conchylicole dans cet exercice de classification. Cette méthode présente de nombreux avantages pour la classification au niveau pixel, mais est limitée pour l'étude des textures et pour la mise en contexte du contenu du pixel avec son voisinage. De plus, au contraire de la mise en œuvre classique du protocole Biocoast, il n'est pas prévu ici d'inclure une dimension multi-temporelle ou de travailler à partir de relevés terrains. Cette méthode a été appliquée uniquement sur le Cotentin pour comparer ses performances avec l'approche Deep Learning développée. Les résultats ont très vite montré que cette approche n'était pas la plus adaptée à la cartographie des activités conchylicoles, elle n'a donc pas été appliquée sur le Bassin d'Arcachon. Les principaux résultats obtenus sur le Cotentin ont été conservés pour la démonstration.

La première étape de la classification est la création d'une typologie rendant compte des différents habitats / objets présents dans les images. Une base de données d'échantillons d'apprentissage est ensuite créée par photo-interprétation selon cette typologie. Cette base de données est utilisée pour l'apprentissage d'un modèle Random Forest, et des classifications cartographiques des images sont produites et analysées. Selon les problèmes mis en évidence dans les classifications, un travail d'allers-retours entre la définition de la typologie, des échantillons d'apprentissage et des prédictions est mis en place jusqu'à obtenir un résultat satisfaisant.

2.3 Réseaux de neurones convolutifs et SegNet

Les réseaux de neurones convolutifs (CNN pour Convolutional Neural Networks) [5] sont des réseaux de neurones multicouches qui sont spécialisés dans des tâches de reconnaissance de forme. Ils sont réputés pour leur robustesse aux faibles variations d'entrée, et pour le faible taux de prétraitement nécessaire à leur fonctionnement. De plus, ils ne requièrent aucun choix d'extracteur de caractéristiques spécifiques. L'architecture proposée repose sur plusieurs réseaux de neurones profonds alternant entre couches de convolution et couches d'agrégation (pooling). Ces réseaux de neurones profonds appartiennent à une classe de modèles s'inspirant des travaux de Hubel et Wiesel [6] sur le cortex visuel primaire du chat. Le début de l'architecture consistant en une succession de couches de convolutions et d'agrégations est dédié à l'extraction automatique de caractéristiques, tandis que la seconde partie, composée de couches de neurones complètement connectés, est dédiée à la classification.

SegNet [7] est une architecture de réseaux de neurones convolutifs dédiée à la segmentation d'images. Contrairement à d'autres architectures, la résolution de sortie du réseau est la même que la résolution d'entrée, ce qui permet d'étiqueter les données à la résolution d'image originale, produisant ainsi des cartes à une échelle 1 :1. Symétriquement à la première partie du réseau (dite encodeur), qui extrait les caractéristiques abstraites de l'entrée, un décodeur ramène ces caractéristiques abstraites au niveau pixel et attribue en même temps les étiquettes finales. L'architecture est présentée Figure 1. La principale force de cette architecture est que les étapes de sous-échantillonnage des caractéristiques abstraites de l'encodeur sont utilisées par le décodeur pour sur-échantillonner ces caractéristiques jusqu'à la résolution voulue. La partie de l'apprentissage dédiée au sur-échantillonnage est donc fortement réduite, et les résultats sur les petits objets, autrement mal classés ou égarés, sont fortement améliorés [7].

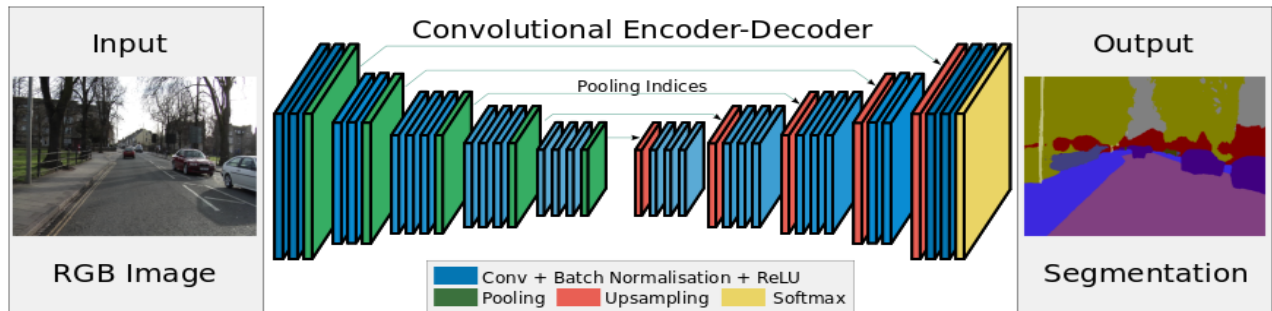


Figure 1. Représentation de l'architecture SegNet, Badrinarayanan [7].

L'intérêt principal de cette approche est que le processus de classification intègre l'analyse des caractéristiques de formes et de textures dans l'image, cela à toutes les échelles que permettent les couches de convolutions du modèle. Cet outil est donc particulièrement adapté à l'analyse d'images texturées telles que des orthophotographies aériennes à une résolution spatiale permettant aux friches ostréicoles d'apparaître avec leur forme et leur grain caractéristique.

2.4 Mise en œuvre pratique (SegNet)

Le point de départ de notre cartographie est le modèle de détection des tables ostréicoles affiné et testé pour la cartographie du Bassin d'Arcachon 2020 [2]. L'idée est de raffiner pas à pas ce modèle, en ajoutant de nouveaux échantillons d'apprentissage digitalisés sur les images des différents sites. En effet, même si les contextes et les résolutions sont différents, nous pouvons hériter de l'apprentissage poussé réalisé sur le Bassin d'Arcachon et le spécialiser sur de nouveaux sites et de nouvelles images. Il faut, dans un premier temps, construire, par photo-interprétation, une base de données d'apprentissage spécifique, ciblée sur des zones variées et complexes. Après une première phase d'apprentissage utilisant cette base de données d'apprentissage, de nouvelles zones ciblées vont être sélectionnées, digitalisées, et injectées dans l'apprentissage du modèle jusqu'à obtenir une prédiction pertinente et homogène à l'échelle du site d'étude. De nombreux allers-retours ont donc été réalisés entre la machine et l'expert photo-interprète, ce dernier analysant les prédictions et choisissant de nouvelles zones à cibler en fonction des difficultés identifiées sur les résultats. Si une version de modèle est moins performante que la précédente, le processus reprend la précédente version et va chercher à l'améliorer avec une nouvelle configuration de données d'apprentissage et/ou avec une paramétrisation différente.

L'évaluation entre les différentes versions du modèle se fait par l'analyse des précisions obtenues sur un ensemble de données de validation indépendant mais surtout par l'analyse qualitative critique de l'expert photo-interprète. C'est ce dernier qui guide d'une certaine façon l'apprentissage du modèle par raffinements successifs. On distinguera dans notre processus plusieurs types de ROI (ou régions d'intérêts) :

- les ROI ou zones de **digitalisation initiale** : elles représentent la base de l'apprentissage

avec un effort important de digitalisation au début du processus de cartographie.

- les ROI **GG** (« Good Game ») ce sont des zones ajoutées au fur et à mesure dans l'apprentissage du modèle pour le corriger. Ces ROI sont composées de zones où le modèle a été performant, elles permettent alors, après correction, d'ajouter de l'information à apprendre. Elles sont ensuite composées de zones où le modèle rencontre de grandes difficultés dans sa prédiction. Ces zones sont digitalisées avec attention puis injectées dans la base de données d'apprentissage avant une nouvelle étape de raffinement.

- les ROI **NCS** (« Non ClasseS ») ou zones de « non classe » : ces zones sont ajoutées en fin de processus, elles permettent de forcer le modèle à ne pas prédire d'activité conchylicole dans des zones de l'image où elles ne sont pas présentes, cela permet de réduire considérablement les sur-détections.

Enfin, notre modèle adapté aux images et aux caractéristiques de l'activité conchylicole des sites considérés permet de prédire l'ensemble des pixels du site. Une phase de vérification / correction par photo-interprétation est ensuite menée afin de produire une couche d'information la plus robuste possible.

3 DONNEES

3.1 Images satellite

Pour le littoral du Cotentin, une série d'images Pléiades (4 bandes spectrales, dans le visible et le proche infrarouge, 0,5 m de résolution spatiale) a été acquise au début de l'année 2022 et complétée par des images Pléiades d'archive acquises entre 2019 et 2021. Pour le Bassin d'Arcachon, une série d'images Pléiades a également été récupérée (images d'archive et programmées), plus tardivement dans la chronologie du projet. Cela a motivé l'application de la première expérience uniquement sur le littoral du Cotentin dans un premier temps.

La base de données a été collectée et mise à disposition par DINAMIS¹ (Dispositif Institutionnel National d'Approvisionnement Mutualisé en Imagerie Satellitaire), elle est détaillée dans le Tableau 1 et contient 12 images en totalité. L'emprise des sites d'étude est détaillée sur les Figure 2 (Cotentin) et Figure 3 (Arcachon).

3.2 Image aérienne

Une orthophotographie (RGBPIR, 0,1 m de résolution spatiale) acquise au cours du mois de septembre 2020 a été mise à disposition par le ROL² (Réseau d'Observation du Littoral de Normandie et des Hauts-de-France). Cette image couvre une grande partie du littoral du Cotentin, et seulement une portion de la surface couverte est considérée dans cette étude (6000 ha sur le site de Granville / Chausey, Figure 4).

¹ data-terra.org

² <http://www.rolnhdf.fr/>

Tableau 1. Images satellite (Pléiades) reçues pour ce projet sScènes utilisées dans l'étude en bleu clair et scènes mises de côté en gris).

Zone géographique	Sous site	Date	Image	Usage
Cotentin	Granville - Chausey	14/09/2019	ORT_2019091440751569_LA93	Non utilisée, niveau d'eau élevé et emprise incomplète
		04/04/2020	ORT_2020040440000706_LA93	Non utilisée, niveau d'eau élevé et nuages
		05/10/2021	ORT_2021100541649845_LA93	Non utilisée, niveau d'eau élevé et nuages
		14/01/2022	ORT_2022011440058319_LA93	Utilisée
		14/01/2022	ORT_2022011440066217_LA93	Utilisée
	Côte est	16/03/2020	ORT_2020031639787524_LA93	Utilisée pour le modèle général
		13/01/2022	ORT_2022011340469336_LA93	Utilisée
		04/04/2020	ORT_2020040439995297_LA93	Utilisée
	Pointe d'Agon - Portbail	26/02/2022	ORT_2022022641136569_LA93	Non utilisée, niveau d'eau élevé
		26/02/2022	ORT_2022022641139329_LA93	Non utilisée, niveau d'eau élevé
05/11/2021		ORT_2021110539414371_LA93	Utilisée pour le modèle général	
Bassin d'Arcachon		14/07/2022	ORT_2022071440540719_LA93	Utilisée pour le modèle général

Projet SACSAT - Emprises des sites d'études

Zone géographique du Cotentin




Figure 2. Emprise des zones d'étude sur le Cotentin, exemple des scènes Pléiades utilisées.

Projet SACSAT - Emprises des sites d'études

Zone géographique du Bassin d'Arcachon




Figure 3. Emprise de la zone d'étude sur le Bassin d'Arcachon, exemple des scènes Pléiades utilisées.

Projet SACSAT - Orthophotographie du ROL

Zone d'étude de l'image



Figure 4. Emprise de la zone d'étude de l'orthophotographie du ROL.

3.3 Comparaison des sources de données

Les figures suivantes (Figure 5 et Figure 6) illustrent les différences entre les deux sources de données : les images Pléiades (50 cm de résolution spatiale) et l'orthophotographie du ROL (10 cm de résolution spatiale). Outre les différences dues à l'écart temporel entre les deux acquisitions (niveau d'eau, cultures différentes, etc.) on peut noter que l'image satellite ne permettra pas de distinguer les différents types de cultures, mais le niveau de détail présent dans la scène Pléiades est suffisant pour rendre compte de l'activité conchylicole sur un secteur.

Granville - Scène Pléiades du 14/01/2022



Granville - Ortho-photographie du ROL



i-Sea





Figure 5. Comparaison des deux sources de données, satellite (à gauche) et aérienne (à droite).

Granville - Scène Pléiades du 14/01/2022



Granville - Ortho-photographie du ROL



i-Sea

0 10 20 m

Figure 6. Comparaison des deux sources de données, satellite (à gauche) et aérienne (à droite).

4 MODELE RANDOM FOREST : APPLICATION ET EVALUATION DES RESULTATS

Pour chacun des sites d'études du Cotentin, l'image exploitable la plus récente est sélectionnée pour être traitée. Cette même sélection sera conservée pour la section suivante. Les deux approches sont menées en parallèle dans l'optique d'être comparées sur les mêmes secteurs.

4.1 Typologie

La première étape de cette approche Random Forest est la constitution d'une typologie, destinée à rendre compte des différentes classes de l'occupation et / ou des usages des estrans et petits fonds littoraux sur les différents sites du Cotentin.

Une analyse visuelle des images Pléiades sélectionnées permet de lister les différents types d'objets ou de textures qui formeront les classes de la typologie. Une attention particulière est accordée au niveau d'eau dans la définition des classes, puisque la colonne d'eau modifie significativement la signature spectrale des objets immergés. La présence d'herbiers sur la côte

ouest du Cotentin nous pousse à considérer deux typologies différentes, une pour chaque côté du littoral.

Cela implique pour la suite une division des sites d'études : « Côte Est » d'un côté, « Granville / Chausey » et « Pointe d'Agon / Portbail » de l'autre dans les traitements. Pour la suite de cette section les sites sont regroupés en « Côte Ouest » et « Côte Est ».

Les classes formant les deux typologies sont listées ci-après :

- Table
- Table dans l'eau
- Sable sec
- Sable humide
- Sable sous l'eau peu profonde
- Sable sous l'eau profonde
- Récif émergé
- Récif émergé végétalisé
- Récif immergé végétalisé
- Eau profonde
- Sable-vaseux
- Vase texturée
- Herbier (uniquement pour le modèle Côte ouest)

Ces différentes classes ont été définies avant l'obtention de l'orthophotographie du ROL, à partir des images Pléiades, donc les détails fins des différentes activités conchylicoles n'étaient pas visibles. Il serait plus juste de renommer les classes *Table* et *Table dans l'eau* avec des termes plus généraux comme *Activité conchylicole* et *Activité conchylicole dans l'eau*, puisqu'une partie de ces « tables » sont notamment des cultures de moules, après comparaison avec l'orthophotographie. Dans la suite de cette section et dans les livrables cartographiques joints à ce rapport, les mentions aux « tables » sont conservées par soucis de simplification.

4.2 Base de données d'apprentissage

La seconde étape de l'approche est la préparation de l'apprentissage du modèle Random Forest. Par photo-interprétation, une base de données d'apprentissages est constituée. Il s'agit de créer des polygones reprenant les limites des objets appartenant aux différentes classes des typologies. Contrairement aux travaux utilisant des réseaux de neurones convolutifs, ce travail de digitalisation n'a pas le besoin d'être exhaustif dans une zone donnée. Les échantillons d'apprentissages seront les valeurs des pixels extraits de ces polygones.

Le résumé de l'effort de digitalisation est présenté sur le *Tableau 2*.

Le site « Côte Est » étant composé d'une seule image, moins de polygones d'apprentissage ont été requis pour obtenir de bonnes performances pour le modèle. Cela explique le déséquilibre entre les deux sites.

Au terme de la phase d'apprentissage, on produit une mesure de la pertinence des prédictions

du modèle au travers d'une matrice de confusion. Il s'agit d'un tableau de contingence croisant prédictions et données de référence et permet de mesurer les performances d'un modèle de classification multi-classes. Un guide de lecture de ces matrices est illustré par la Figure 7.

Deux modèles différents ont été entraînés pour les deux groupes de sites « côte ouest » et « côte est », les deux matrices de confusion associées sont présentées (Figure 8 et Figure 9). Ces matrices ont été produites à partir d'un ensemble de test, portion de la base de données d'apprentissage, sur lequel le modèle n'a pas été entraîné. Les résultats sont encourageants mais ne permettent pas de rendre compte de la qualité des prédictions cartographiques, seulement de la pertinence du modèle sur la base de données d'apprentissage.

Tableau 2. Résumé de l'effort de digitalisation pour l'apprentissage des modèles Random Forest.

Site Typologie	Côte Est		Côte Ouest	
	Nombre Polygones	Surface (ha)	Nombre Polygones	Surface (ha)
Eau profonde	18	56,18	34	522,10
Récif émergé	43	18,12	73	6,18
Récif émergé végétalisé	49	5,69	78	6,98
Récif immergé végétalisé	40	38,48	235	15,44
Sable eau peu profonde	74	106,49	122	147,67
Sable eau profonde	31	36,96	83	514,11
Sable humide	19	5,92	48	5,93
Sable sec	20	2,82	43	7,96
Sable vaseux	19	15,81	45	98,68
Table	664	8,05	905	8,51
Table dans l'eau	282	5,28	1561	34,13
Terre bâti	19	9,14	60	25,25
Terre végétation	27	25,29	37	82,86
Vase texturée	49	19,78	49	37,55
Herbier			32	26,07
Total	1354	354,02	3405	1539,42

4.3 Résultats cartographiques

Après la phase d'apprentissage du modèle, des prédictions cartographiques sur chaque image de chaque site sont réalisées. On produit ensuite des atlas cartographiques pour chaque sous-site du Cotentin, livrés avec le présent rapport. Un exemple de ces cartes pour le site « Côte Ouest » et « Côte Est » est présenté dans les figures Figure 10 et Figure 11, respectivement.

Si les résultats produits par cette approche sont très encourageants, les contours prédits des surfaces d'activité conchylicole sont très grossiers. Cette approche n'est pas spécialisée dans la reconnaissance de formes et de textures, ce qui induit des prédictions peu satisfaisantes pour nos classes d'intérêts (activité conchylicole). L'approche Deep Learning, testée en parallèle de cette approche, a démontré sa supériorité en termes de pertinence de reconnaissance et de prédiction de contours fins des activités conchylicoles. L'approche Random Forest n'est donc pas à privilégier pour répondre aux objectifs de l'étude. Elle reste cependant à conserver pour la

cartographie des habitats à partir de série temporelle d'images satellitaires.

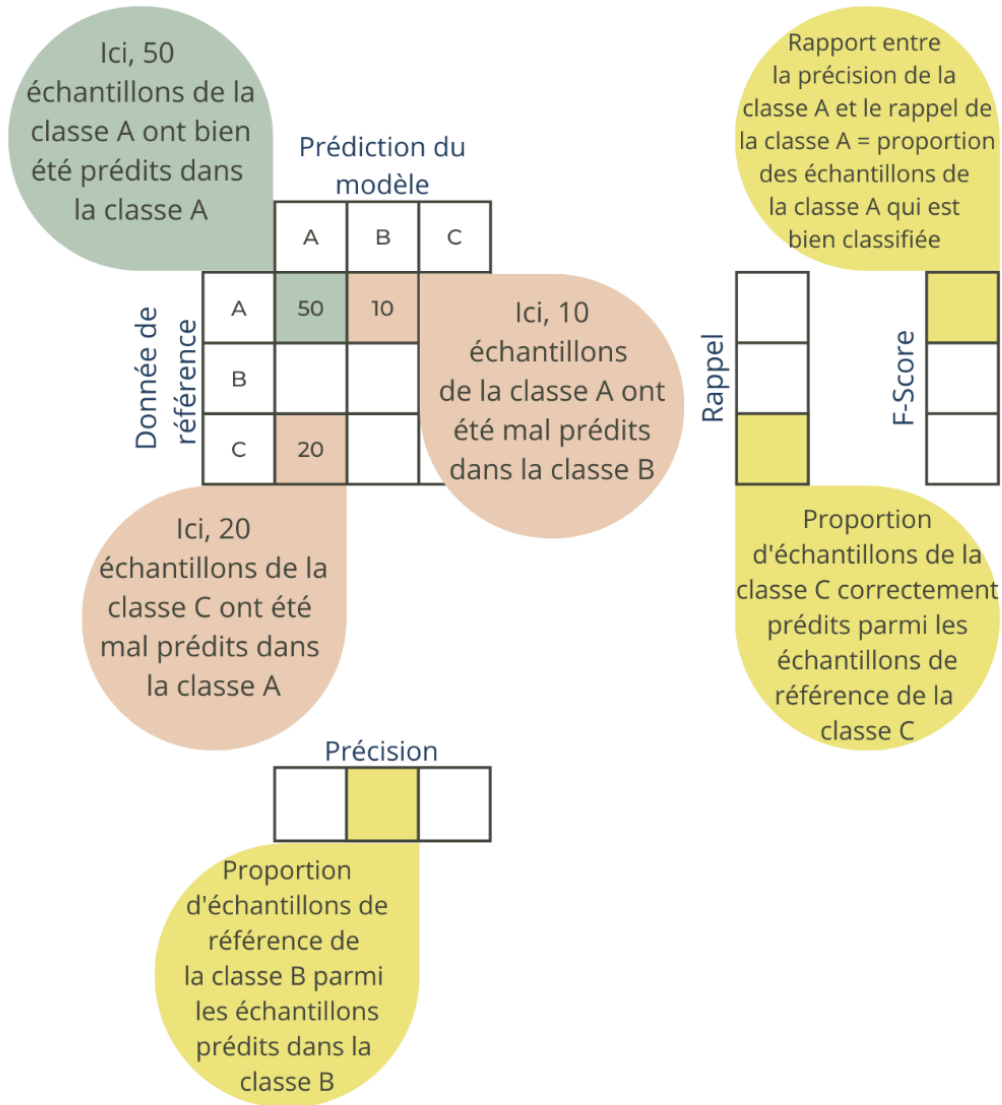


Figure 7. Guide de lecture d'une matrice de confusion.

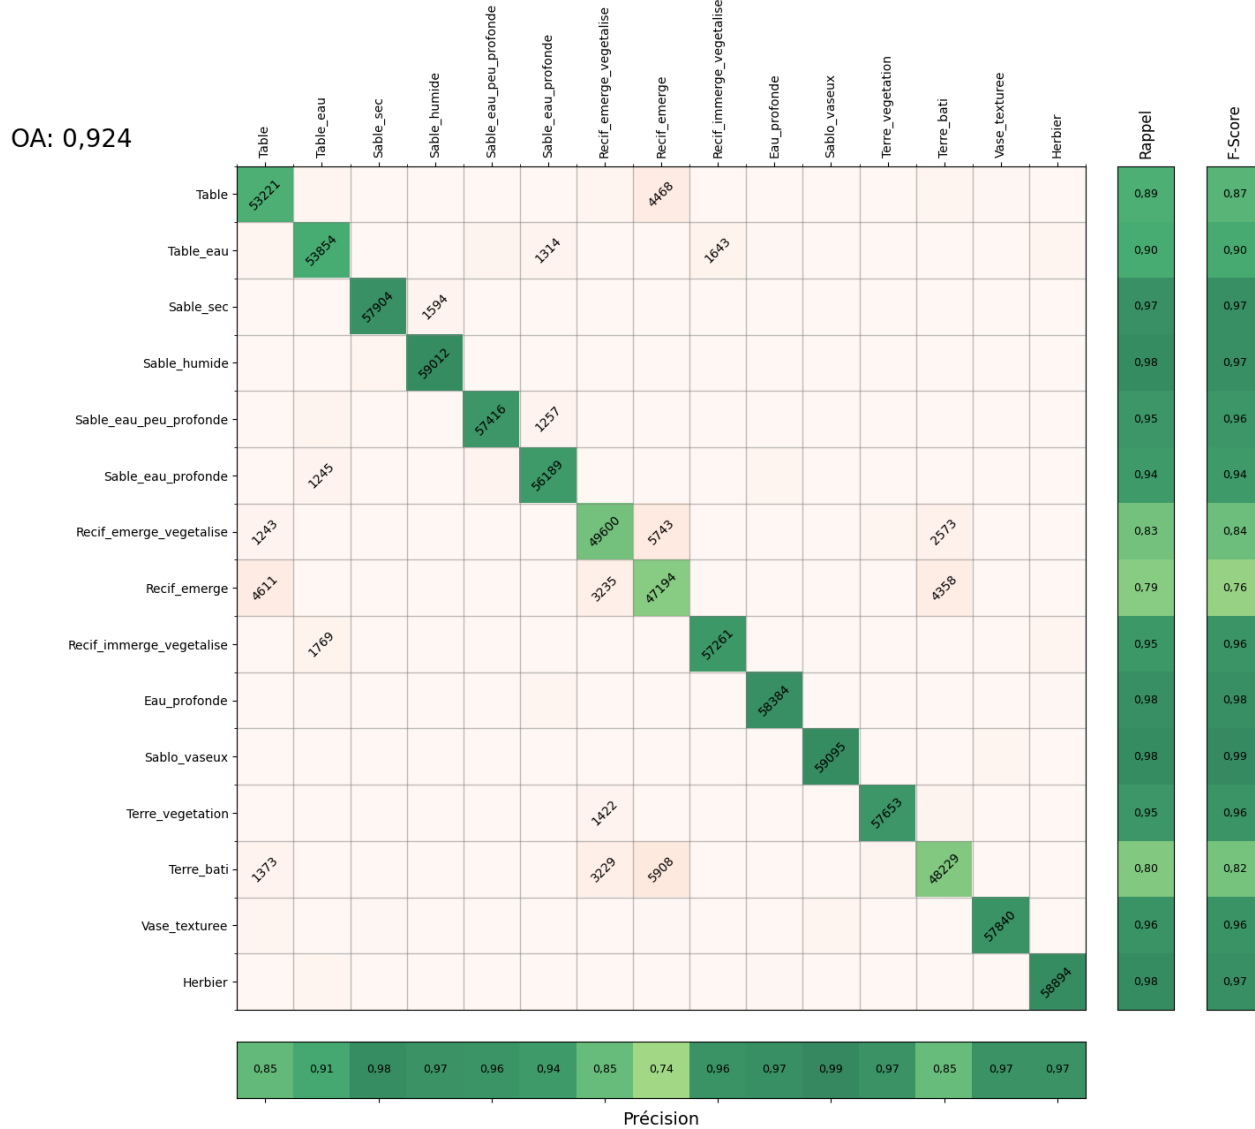


Figure 8. Matrice de confusion obtenue sur l'ensemble de test pour le site "Côte Ouest", OA : Overall Accuracy (précision globale).

OA: 0,913





Figure 9. Matrice de confusion obtenue sur l'ensemble de test pour le site "Côte Est", OA : Overall Accuracy (précision globale).



Cartographie des surfaces d'activités conchylicoles et des milieux environnants par télédétection (Pléiades 50cm), approche RandomForest
Cotentin - Chausey - 2022



Éditée le : 15 / 6 / 2022



B3

Légende

- Table
- Table dans l'eau
- Sable sec
- Sable humide
- Sable sous l'eau peu profonde
- Sable sous l'eau profonde
- Récif émergé
- Récif émergé végétalisé
- Récif immergé végétalisé
- Eau profonde
- Sablo-vaseux
- Vase texturée
- Herbier



Réalisation : i-Sea 2022
Sources :
- i-Sea
- Natural Earth
- IGN
Image (traitement et fond) : image Pléiades du 14/01/2022 ©CNES distribution AIRBUS DS
Système de coordonnées : Lambert 93




Figure 10. Cartographie des surfaces d'activités conchylicoles et des milieux environnants par télédétection (Pléiades 50 cm), approche Random Forest – extrait (Tuile B3) de l'atlas cartographique du site « Chausey ».



Cartographie des surfaces d'activités conchylicoles et des milieux environnants par télédétection (Pléiades 50cm), approche Deeplearning
Cotentin - Côte Est - 2022



Éditée le : 15 / 6 / 2022



F1

Légende

- Table
- Table dans l'eau
- Sable sec
- Sable mouillé
- Eau peu profonde
- Eau profonde
- Récif émergé végétalisé
- Récif émergé
- Récif immergé végétalisé
- Eau profonde
- Sablo vaseaux
- Terre végétation
- Terre bâti
- Vase texturée

0 50 100 m



Réalisation : i-Sea 2022
Sources :
- i-Sea
- Natural Earth
- IGN
Image (traitement et fond) : image Pléiades du 13/01/2022 ©CNES distribution AIRBUS DS
Système de coordonnées : Lambert 93




Figure 11. Cartographie des surfaces d'activités conchylicoles et des milieux environnants par télédétection (Pléiades 50 cm), approche Random Forest – extrait (Tuile F1) de l'atlas cartographique du site « Côte Est ».

5 MODELES SEGNET SUR LES IMAGES SATELLITES : APPLICATION ET EVALUATION DES RESULTATS

5.1 Modèle Cotentin

Les images utilisées pour le test de l'approche Random Forest sont retenues pour l'analyse de l'activité conchylicole par Deep Learning. Un modèle est entraîné sur toutes ces zones à la fois pour ensuite obtenir des prédictions cartographiques de l'activité conchylicole. Ce modèle est mentionné ci-après comme le « Modèle Cotentin ».

5.1.1 Base de données d'apprentissage

La base de données d'apprentissage initiale pour le modèle Cotentin contient des images sur 12 secteurs, répartis sur les différents sites d'étude du Cotentin. Ces secteurs ont été définis de manière à rendre compte de la variabilité des cultures et de l'environnement. Les polygones apparentés à des tables sont détournés manuellement sur la base des images satellites à disposition. A l'instar de la définition donnée dans la section précédente, on entend par tables les signes d'activités conchylicoles observables sur les images satellite.

Au total, 2452 polygones ont été digitalisés, ils représentent une surface cumulée d'environ 30,9 ha sur les 346,5 ha analysés. Un exemple de secteur digitalisé est représenté sur la Figure 12.

Par la suite, le modèle a été raffiné à l'aide d'une base de données d'apprentissage secondaire, constituée en définissant les différentes Régions d'intérêt « ROI GG » et « ROI NCS » à partir des premières prédictions du modèle. Une deuxième phase de digitalisation a donc été opérée sur 17 secteurs « ROI GG », résultant en 1306 polygones digitalisés. Ces derniers représentent une surface digitalisée d'environ 24,1 ha, sur, approximativement, les 330 ha analysés.

La Figure 13 **Erreur ! Source du renvoi introuvable.** montre un exemple du travail qui est réalisé autour d'une de ces régions d'intérêt. La prédiction observée n'est pas satisfaisante, une sous-détection importante est observée dans ce type de secteur. La zone est corrigée, digitalisée et vérifiée manuellement pour permettre de produire de nouvelles imagerie d'entraînement et ainsi permettre au modèle de mieux reconnaître ce type de faciès, partout dans les images.

Les 5 secteurs « ROI NCS » représentent quant à eux une surface d'environ 11,8 ha sans trace d'activité conchylicole.

Les figures Figure 14 à Figure 19 récapitulent les différents secteurs de digitalisation utilisés pour la création des bases de données d'apprentissage. « INIT » fait référence aux zones de digitalisation initiales.

Projet SACSAT - Exemple de digitalisation manuelle

Cote Est - Scène Pléiades du 13/01/2022




Figure 12. Exemple de digitalisation manuelle sur une image Pléiades.

Projet SACSAT - Exemple de digitalisation manuelle sur une "ROI GG"

Portbail - Scène Pléiades du 04/04/2020




Figure 13. Exemple de digitalisation manuelle sur un secteur "ROI GG" d'une image Pléiades (A : Prédiction du modèle Cotentin initial sur un secteur du site « Portbail » - B : Digitalisation manuelle sur ce secteur).

Projet SACSAT - Zones de digitalisations manuelles

Chausey - Scène Pléiades du 14/01/2022




Figure 14. Répartition des zones analysées sur la scène Pléiades du 14/01/2022 sur le site de Chausey.

Projet SACSAT - Zones de digitalisations manuelles

Côte Est - Scène Pléiades du 13/01/2022




Figure 15. Répartition des zones analysées sur la scène Pléiades du 13/01/2022 sur le secteur nord du site Côte Est.

Projet SACSAT - Zones de digitalisations manuelles

Côte Est - Scène Pléiades du 13/01/2022




Figure 16. Répartition des zones analysées sur la scène Pléiades du 13/01/2022 sur le secteur sud du site Côte Est.

Projet SACSAT - Zones de digitalisations manuelles

Granville - Scène Pléiades du 14/01/2022




Figure 17. Répartition des zones analysées sur la scène Pléiades du 14/01/2022 sur le site Granville.

Projet SACSAT - Zones de digitalisations manuelles

Pointe d'Agon - Scène Pléiades du 04/04/2020




Figure 18. Répartition des zones analysées sur la scène Pléiades du 04/04/2020 sur le site Pointe d'Agon.

Projet SACSAT - Zones de digitalisations manuelles

Portbail - Scène Pléiades du 04/04/2020




Figure 19. Répartition des zones analysées sur la scène Pléiades du 04/04/2020 sur le site Portbail.

5.1.2 Résultats

Une fois la phase d'apprentissage conclue, des prédictions de l'activité conchylicole sont produites pour chaque image et chacun des deux modèles.

La Figure 20 présente les résultats de prédiction sur quelques petits secteurs pour le modèle Cotentin initial et le modèle Cotentin raffiné. De gauche à droite, on peut comparer l'image RGB à la digitalisation de l'opérateur, puis les deux étapes de prédiction. On observe une nette amélioration sur la plupart des secteurs, et une quasi exhaustivité des prédictions, même dans les contextes difficiles (niveau d'eau élevé, présence de rochers, etc.).

En plus de cette évaluation visuelle des performances des modèles, on évalue mathématiquement ces performances à l'aide d'une portion de la base de données, mise de côté durant l'apprentissage. Ces 10% des échantillons (l'ensemble de validation), qui n'ont pas servi à l'entraînement du modèle, permettent de confronter la digitalisation manuelle à des prédictions et d'ainsi évaluer la réelle performance d'un modèle face à des images jamais rencontrées durant l'apprentissage.

Deux métriques sont utilisées ici pour évaluer les prédictions :

- La précision globale (OA), qui est la proportion de pixels « bien prédits » sur le nombre total de pixel dans l'image. On compte non seulement les prédictions d'activité conchylicole, mais également les prédictions d'absence d'activité. Plus la précision est proche de 1, meilleure est la prédiction.
- L'index kappa de Cohen, qui est une mesure du degré de concordance entre prédiction et référence (ici la digitalisation manuelle), et la compare à une classification aléatoire. Cet index permet de nuancer la précision globale, qui peut être élevée malgré une classe mal prédite, à cause d'un déséquilibre entre les classes dans la base de données. Plus l'index est proche de 1, plus la prédiction concorde avec la référence.

Le Tableau 3 résume l'évolution de ces deux métriques suite au raffinement du modèle, sur un ensemble de validation.

Tableau 3. Evolution des performances des modèles sur l'ensemble de validation.

	Modèle Cotentin initial	Modèle Cotentin raffiné
OA	0,94	0,94
Kappa	0,49	0,61

Il est intéressant de noter que d'un modèle à l'autre, c'est l'index Kappa qui augmente, plutôt que la précision qui, elle, reste la même. Notre ensemble de validation est déséquilibré, il présente plus de « non-classe », d'absence d'activité conchylicole, et donc OA, la précision, est biaisée.

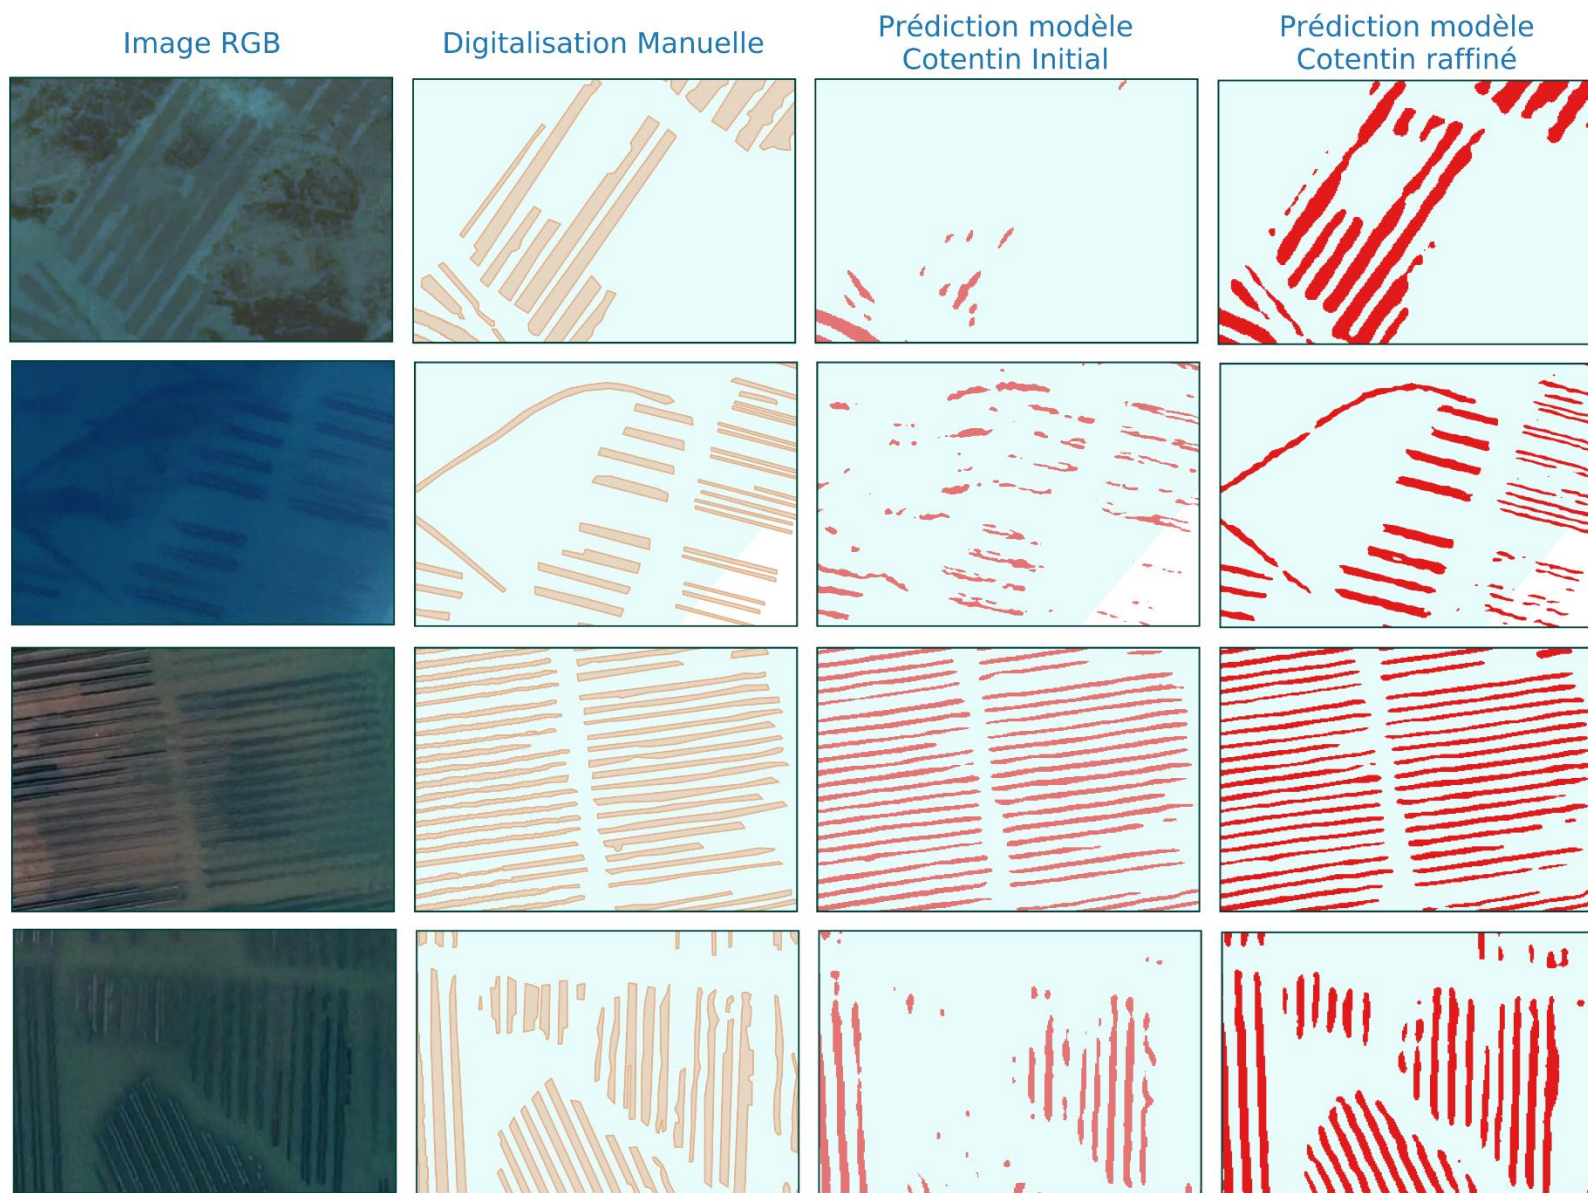


Figure 20. Illustration des résultats de prédiction des deux stades d'entraînement du modèle Cotentin.

A l'issue de l'entraînement initial, le modèle Cotentin donne déjà des résultats très encourageants sur l'ensemble des images. Le raffinement du modèle initial, grâce à la seconde base de données d'apprentissage, ciblée sur les secteurs mal prédits par celui-ci, permet d'obtenir des prédictions de confiance sur la majeure partie des surfaces en jeu. Il reste toutefois des confusions : on pourrait envisager l'ajout de nouvelles données d'apprentissage par le biais de nouvelles « ROI GG », toutefois on juge ici que la qualité globale des prédictions est suffisamment satisfaisante pour passer à l'étape suivante.

5.1.3 [Corrections manuelles](#)

Une fois que la prédiction est jugée performante et pertinente sur les différentes images, un opérateur procède à la vérification des polygones à dire d'expert, en s'appuyant sur les images satellite ayant servies dans l'analyse. Cette opération de nettoyage/validation permet de supprimer une grande partie des confusions.

5.1.4 [Comparaison de l'approche Random Forest à l'approche Deep Learning](#)

La Figure 21 offre une illustration des résultats de détection d'activité conchylicole pour chacune des deux approches (Random Forest et Deep Learning). Bien que pertinente, l'approche Random Forest produit des résultats assez diffus, notamment lorsque le niveau d'eau est élevé. Dans le cas présent, l'approche Deep Learning est meilleure.

5.1.5 [Résultats cartographiques](#)

Une fois chaque prédiction manuellement corrigée, des atlas cartographiques pour chaque sous-site du Cotentin sont réalisés. Un exemple de ces cartes pour chaque site est présenté dans les figures Figure 22 et Figure 23.

Projet SACSAT - Comparaison de l'approche Random Forest et de l'approche Deep Learning

Cote Est - Scène Pléiades du 13/01/2022






Figure 21. Comparaison des deux approches de détection d'activité conchylicole sur un secteur du site "Côte Est" (A : Random Forest, B : Segnet)



**Cartographie des surfaces d'activités conchylicoles
par télédétection (Pléiades 50cm), approche DeepLearning**
Cotentin - Chausey - 2022




Éditée le : 15 / 6 / 2022



B3

Légende

 Table ostréicole



Réalisation : i-Sea 2022
Sources :
- i-Sea
- Natural Earth
- IGN
Image (traitement et fond) : image Pléiades
du 14/01/2022 © CNES distribution AIRBUS DS
Système de coordonnées : Lambert 93

Figure 22. Cartographie des surfaces d'activités conchylicoles et des milieux environnants par télédétection (Pléiades 50 cm), approche Deep Learning, extrait (Tuile B3) de l'atlas cartographique du site « Chausey ».



**Cartographie des surfaces d'activités conchylicoles
par télédétection (Pléiades 50cm), approche DeepLearning**
Cotentin - Côte Est - 2022



Éditée le : 15 / 6 / 2022



F1

Légende

 Table ostréicole



Réalisation : i-Sea 2022
Sources :
- i-Sea
- Natural Earth
- IGN
Image (traitement et fond) : image Pléiades
du 13/01/2022 ©CNES distribution AIRBUS DS
Système de coordonnées : Lambert 93

Figure 23. Cartographie des surfaces d'activités conchylicoles et des milieux environnants par télédétection (Pléiades 50 cm), approche Deep Learning, g-extrait (Tuile F1) de l'atlas cartographique du site « Côte Est ».

5.2 Généralisation du modèle de prédiction

Les images utilisables laissées de côté dans la section précédente, notamment les deux images du Bassin d'Arcachon, sont exploitées ici pour évaluer la capacité de généralisation de la méthode.

5.2.1 Base de données d'apprentissage

La première étape, encore une fois, est la constitution de la base de données d'apprentissage. Des prédictions cartographiques de l'activité conchylicole sont réalisées sur chaque image grâce au « modèle Cotentin ». En fonction de la pertinence des résultats, et comme précédemment, des zones « ROI GG » et « ROI NCS » sont délimitées sur chaque image, et les prédictions sont manuellement corrigées/complétées par un opérateur, pour former une nouvelle base de données d'apprentissage. Au total, 7 secteurs « ROI GG » sont analysés (surface d'environ 114 ha), pour 1691 polygones sont digitalisés (représentant une surface d'environ 23,4 ha).

Les figures Figure 24 à Figure 26 récapitulent les différents secteurs de digitalisation concernés par la création de la base de données d'apprentissage.

5.2.2 Evolution des résultats

5.2.2.1 Résultats sur les images du Cotentin utilisées pour l'entraînement du modèle Cotentin

Lors de l'entraînement du modèle général, la base de données d'apprentissage est en réalité constituée de toutes les bases de données précédentes. Elle inclut donc les données digitalisées pour l'entraînement du modèle Cotentin. Alternativement, on pourrait choisir de ne s'entraîner que sur les échantillons d'entraînement d'une image, afin de maximiser les performances du modèle sur celle-ci. La présente étude vise plutôt à l'élaboration d'un modèle général, qui pourrait être utilisé sans raffinement préalable sur n'importe quelle image.

La présence d'échantillons d'apprentissage des anciennes images permet aux prédictions sur ces dernières de ne pas perdre en qualité, comme le montrent le Tableau 4 et la Figure 27 (figure et tableau qui reprennent les illustrations des performances du modèle Cotentin, en ajoutant celles du modèle général).

Tableau 4. Evaluation des performances des différents modèles sur l'ensemble de validation de la base de données d'apprentissage du modèle Cotentin.

	Modèle Cotentin initial	Modèle Cotentin raffiné	Modèle Général
OA	0,94	0,94	0,95
Kappa	0,49	0,61	0,71

Projet SACSAT - Zones de digitalisations manuelles

Cote Est - Scène Pléiades du 16/03/2020

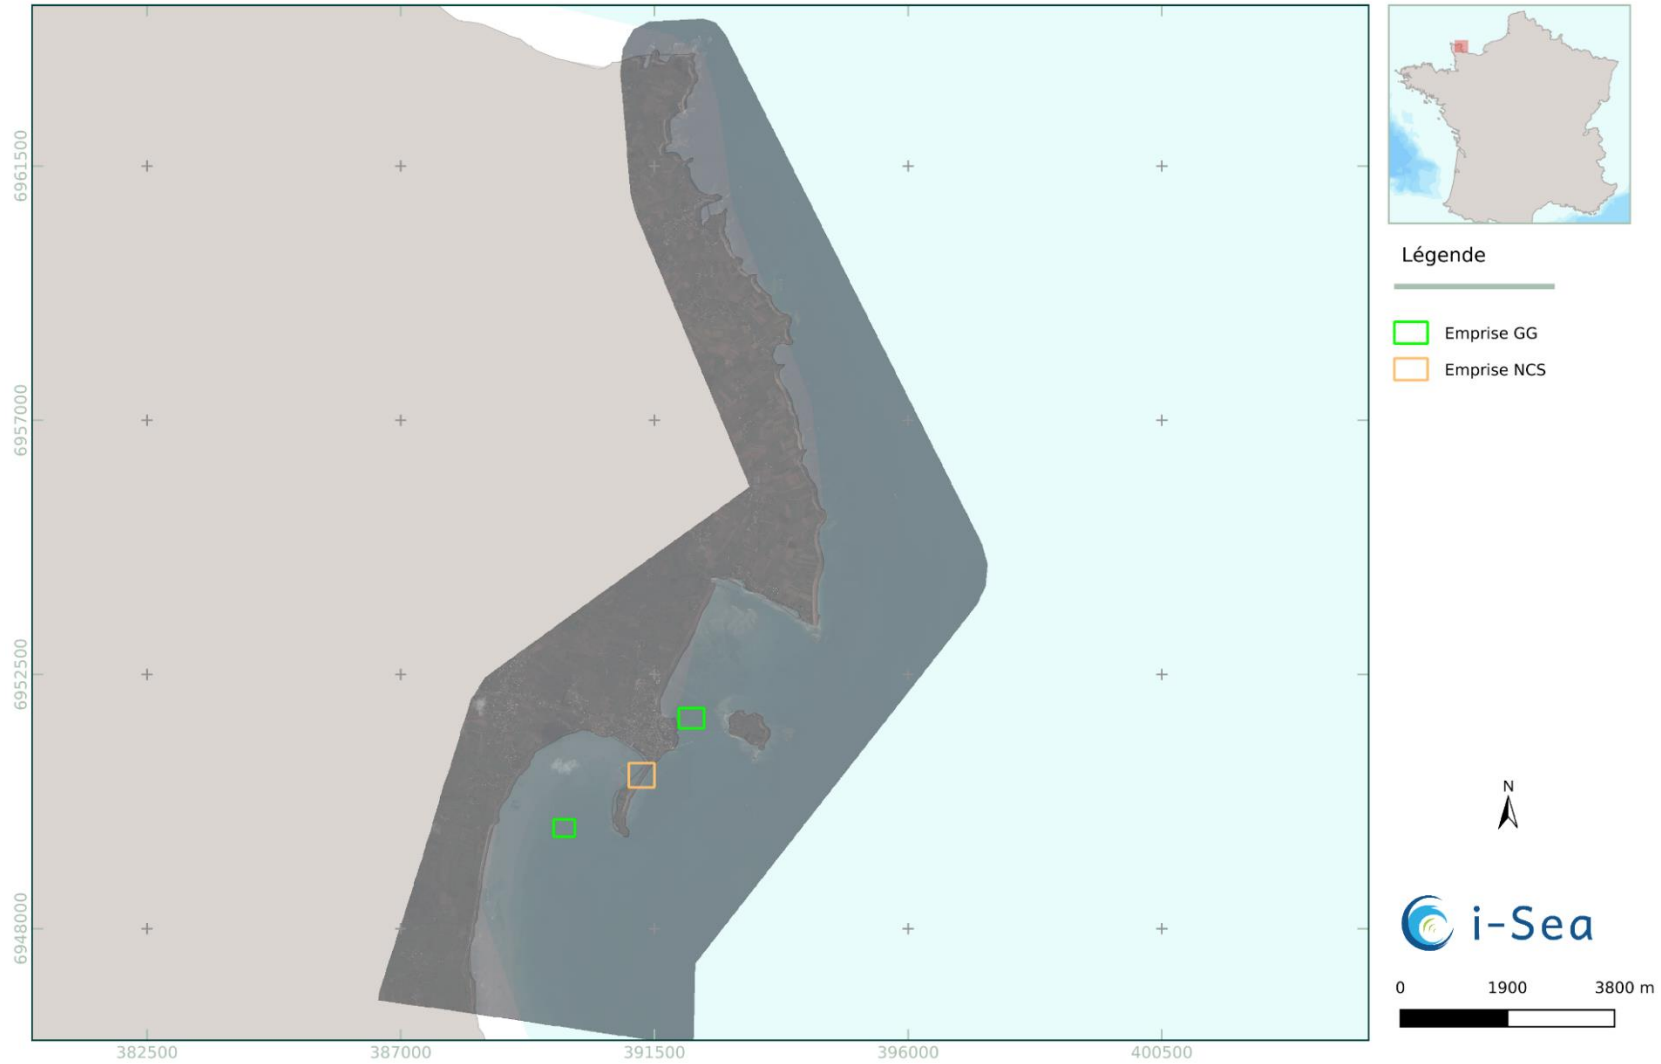


Figure 24. Répartition des zones de digitalisations manuelles analysées sur la scène Pléiades du 16/03/2020 sur un secteur du site Côte Est.

Projet SACSAT - Zones de digitalisations manuelles

Bassin d'Arcachon - Scène Pléiades du 05/11/2021




Figure 25. Répartition des zones de digitalisations manuelles analysées sur la scène Pléiades du 05/11/2021 sur le site Bassin d'Arcachon.

Projet SACSAT - Zones de digitalisations manuelles

Bassin d'Arcachon - Scène Pléiades du 14/07/2022




Figure 26. Répartition des zones de digitalisations manuelles analysées sur la scène Pléiades du 14/07/2022 sur le site Bassin d'Arcachon.

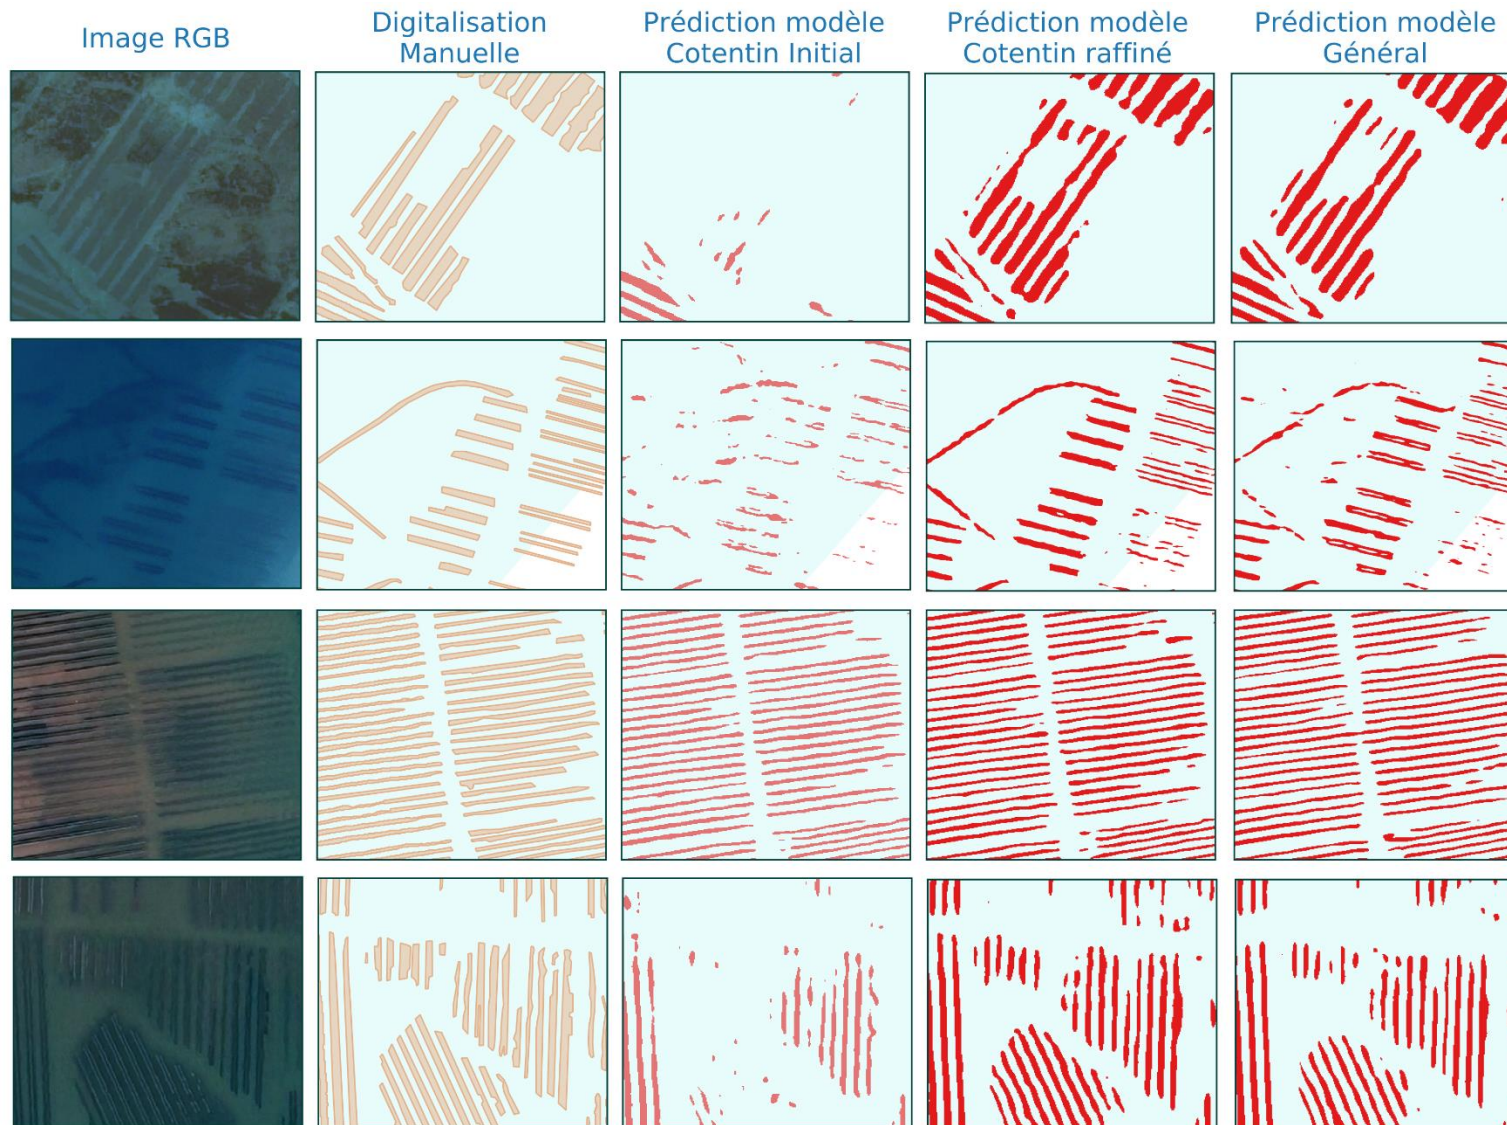


Figure 27. Illustrations des résultats de prédiction des deux stades d'entraînement du modèle Cotentin et du modèle général.

5.2.2.2 Résultats sur l'image Cote Est de 2020 et les images du Bassin d'Arcachon

Comme précédemment, un ensemble de validation est formé à partir de la nouvelle base de données d'apprentissage. On peut ainsi non seulement mesurer la pertinence des prédictions du modèle général, mais également évaluer la progression effectuée par rapport aux deux stades du modèle Cotentin, comme le montre le Tableau 5.

Tableau 5. Evaluation des performances des différents modèles sur l'ensemble de validation de la base de données d'apprentissage du modèle Général.

	Modèle Cotentin initial	Modèle Cotentin raffiné	Modèle Général
OA	0,86	0,82	0,94
Kappa	0,30	0,19	0,76

On remarque que le modèle Cotentin initial est plus performant sur ce nouvel ensemble de validation que le modèle Cotentin raffiné. Une explication possible peut être que le modèle étant dérivé du modèle de prédiction des tables ostréicoles du Bassin d'Arcachon, la première version du modèle Cotentin, plus proche du modèle Arcachon que le modèle raffiné, se comporte mieux sur ce secteur du fait de l'organisation particulière des cultures ostréicoles.

Les figures Figure 28 à Figure 32 montrent des résultats de prédiction cartographique de l'activité conchylicole sur certains secteurs des nouvelles images. La conclusion de ce travail de généralisation du modèle Cotentin montre qu'avec un effort de digitalisation, et une variabilité des formes d'activités dans les choix des secteurs analysés, un modèle général de prédiction de l'activité conchylicole est tout à fait accessible. Cependant, ces résultats de prédictions restent à valider à dire d'expert. En effet, plus l'effort de digitalisation est moindre, plus la proportion de confusions dans les prédictions risque d'augmenter.

5.3 Comparaison avec le cadastre existant

Une des potentielles applications pour ce type de prédictions cartographiques est de contribuer à la mise à jour régulière du cadastre d'activité conchylicole. Dans cette section sont présentées quelques illustrations des prédictions cartographiques du modèle Cotentin juxtaposées au cadastre DDTM50 (figures Figure 33 à Figure 35). On peut noter des différences entre les prédictions et ce dernier, différences qui une fois analysées pourraient représenter un premier outil de gestion locale de l'activité conchylicole. Aller plus loin dans l'analyse nécessiterait une expertise thématique et plus d'informations sur la date de dernière mise à jour du cadastre.

Projet SACSAT - Vue d'ensemble des prédictions cartographiques de l'activité conchylicole

Bassin d'Arcachon - Scène Pléiades du 14/07/2022 - Aperçu 1



Figure 28. Vue d'ensemble des prédictions cartographiques (modèle général Deep Learning) de l'activité conchylicole sur le site Bassin d'Arcachon (scène Pléiades du 14/07/2022) – aperçu 1.

Projet SACSAT - Vue d'ensemble des prédictions cartographiques de l'activité conchylicole

Bassin d'Arcachon - Scène Pléiades du 14/07/2022 - Aperçu 2



Figure 29. Vue d'ensemble des prédictions cartographiques (modèle général Deep Learning) de l'activité conchylicole sur le site Bassin d'Arcachon (scène Pléiades du 14/07/2022) – aperçu 2.

Projet SACSAT - Vue d'ensemble des prédictions cartographiques de l'activité conchylicole

Bassin d'Arcachon - Scène Pléiades du 05/11/2021 - Aperçu 1




Figure 30. Vue d'ensemble des prédictions cartographiques (modèle général Deep Learning) de l'activité conchylicole sur le site Bassin d'Arcachon (scène Pléiades du 05/11/2021) – aperçu 1.

Projet SACSAT - Vue d'ensemble des prédictions cartographiques de l'activité conchylicole

Bassin d'Arcachon - Scène Pléiades du 05/11/2021 - Aperçu 2



Figure 31. Vue d'ensemble des prédictions cartographiques (modèle général Deep Learning) de l'activité conchylicole sur le site Bassin d'Arcachon (scène Pléiades du 05/11/2021) – aperçu 2.

Projet SACSAT - Vue d'ensemble des prédictions cartographiques de l'activité conchylicole

Cote Est - Scène Pléiades du 16/03/2020




Figure 32. Vue d'ensemble des prédictions cartographiques (modèle général Deep Learning) de l'activité conchylicole sur le site Côte Est (scène Pléiades du 16/03/2020).

Projet SACSAT - Comparaison des prédictions avec le cadastre

Cote Est - Scène Pléiades du 13/01/2022




Figure 33. Comparaison du modèle Cotentin (Deep Learning) avec le cadastre - site Côte Est, scène Pléiades du 13/01/2022.

Projet SACSAT - Comparaison des prédictions avec le cadastre

Granville - Scène Pléiades du 14/01/2022




Figure 34. Comparaison du modèle Cotentin (Deep Learning) avec le cadastre - site Granville, scène Pléiades du 14/01/2022.

Projet SACSAT - Comparaison des prédictions avec le cadastre

Pointe d'Agon - Scène Pléiades du 04/04/2020




Figure 35. Comparaison du modèle Cotentin (Deep Learning) avec le cadastre - site Pointe d'Agon, scène Pléiades du 04/04/2020.

6 CARACTERISATION DES TYPES D'ACTIVITE CONCHYLICOLE (SEGNET MULTICLASSE SUR IMAGES AERIENNES)

Dans la continuité des travaux réalisés avec le PNMBA (Parc Naturel Marin du Bassin d'Arcachon) sur la cartographie 2020 des types de tables ostréicoles à partir d'orthophotographie aérienne (15 cm) [2], une seconde expérience est mise en œuvre pour la caractérisation des types d'activités conchylicoles sur les sites d'étude du Cotentin. En tirant profit de la très haute résolution de l'orthophotographie du ROL, il est possible de faire la distinction entre différents types de cultures et d'aller plus loin dans le suivi des activités conchylicoles par télédétection et ainsi proposer une échelle d'analyse plus pertinente pour de potentielles actions de gestion. Un secteur de l'image aérienne couvert également par les images Pléiades est sélectionné pour cette expérience (voir Figure 4) qui a pour objectif de faire la démonstration de notre approche pour la discrimination des différents types d'activités conchylicoles.

6.1 Typologie

A la suite d'une analyse visuelle préalable d'une partie de l'orthophotographie, une typologie à 9 classes est créée pour rendre compte des objets présents dans l'image. Ces classes n'ont pas vocation à faire une description exhaustive et thématique de l'activité conchylicole, mais à éprouver la méthode développée pour discerner les objets fins dans une image. En ce sens, les noms des classes sont volontairement imprécis, et un travail supplémentaire avec des spécialistes de la question devra être mis en œuvre pour aller plus loin.

Cette typologie est présentée Figure 36, avec un ou plusieurs aperçus des objets considérés dans cette typologie.

6.2 Base de données d'apprentissage

La base de données d'apprentissage est répartie sur 8 secteurs, distribués sur une portion de l'orthophotographie (Figure 37). Ces secteurs ont été définis de manière à rendre compte de la variabilité des objets présents dans l'image. Les polygones apparentés à une des classes définies dans la typologie sont détournés manuellement sur la base de l'orthophotographie et leur est assigné le nom et le code numérique de leur classe.

Objet plein



Objet vide



Caisse



Emplacement caisse



Indéterminé



Moules



Piège à poissons



Table pleine



Table vide



Figure 36. Récapitulatif des différents éléments de la typologie des types d'activités conchycolles.

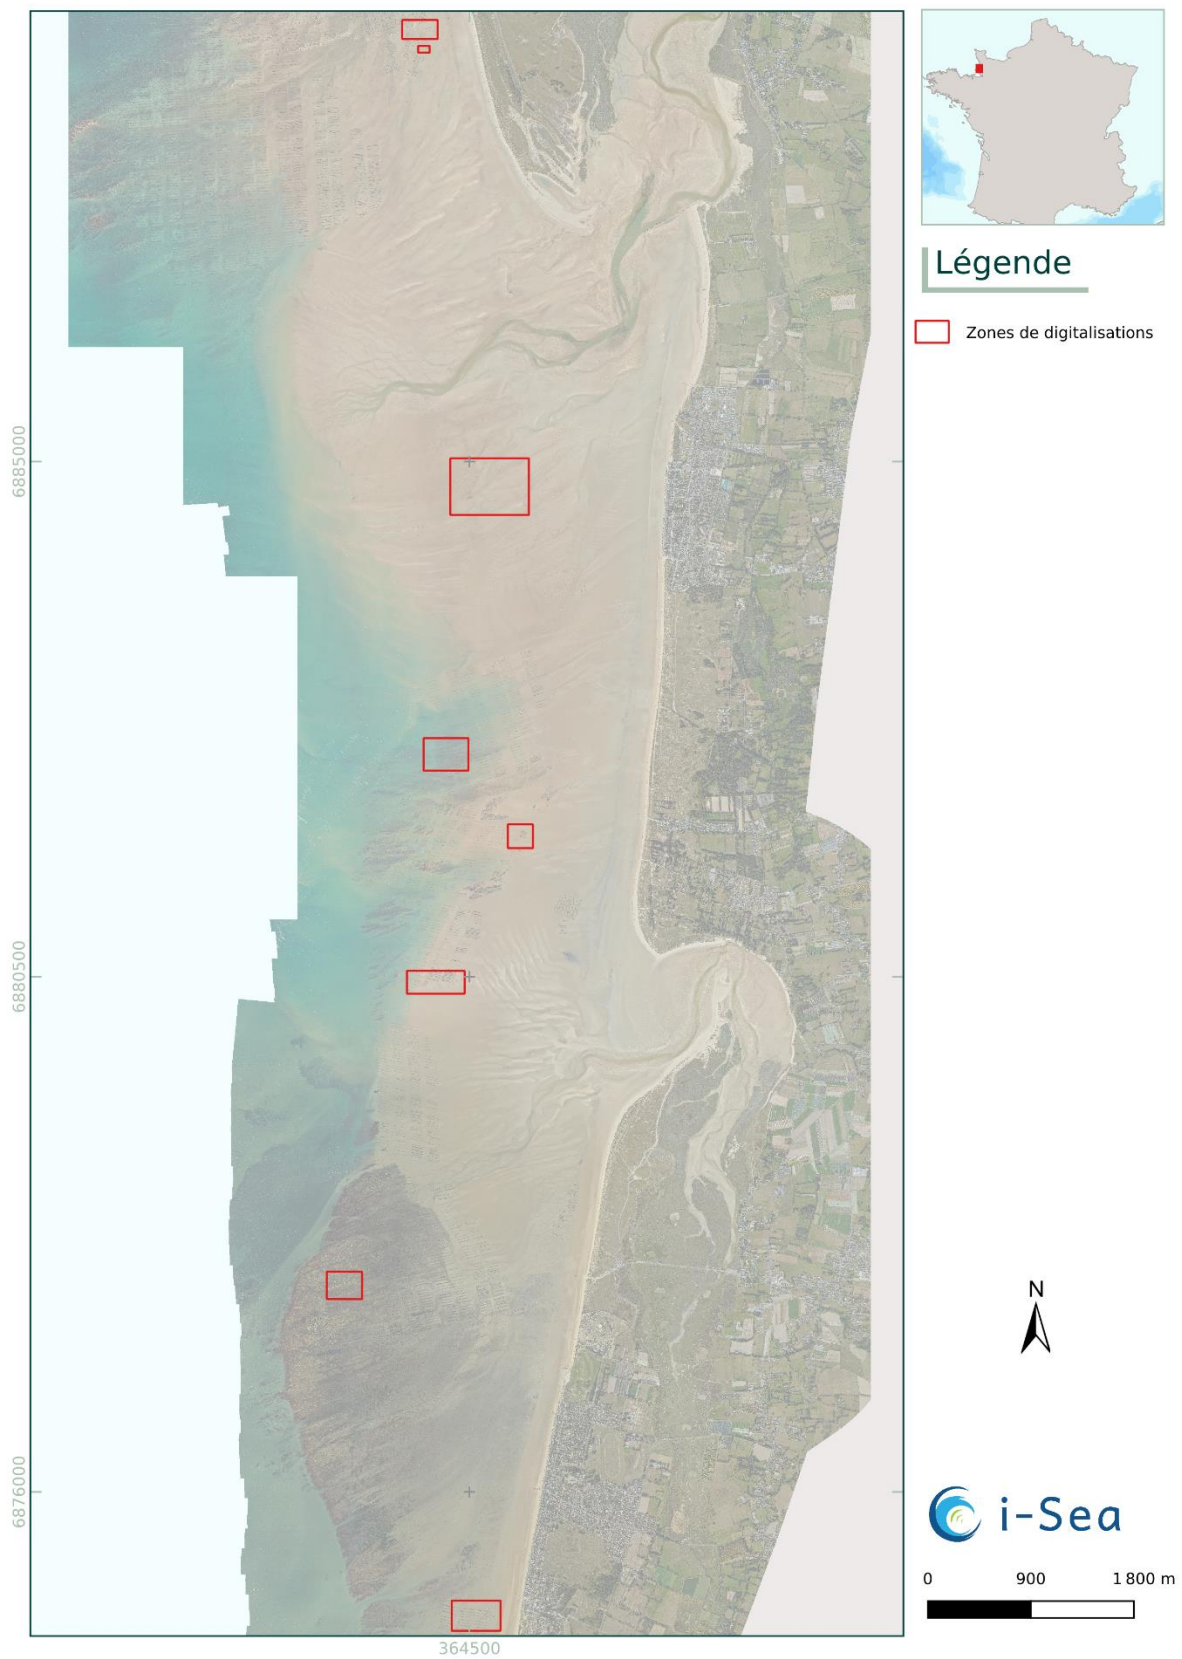


Figure 37. Répartition des secteurs de digitalisation sur l'orthophotographie.

Au total, sur les 84 ha analysés, 2134 polygones ont été digitalisés, soit une surface d'environ 2,4 ha. Le Tableau 6 présente un récapitulatif des digitalisations pour chaque classe de la typologie.

Tableau 6. Résumé de l'effort de digitalisation sur l'orthophotographie.

Classe	Nombre de polygones	Surface (m2)
Objet plein	22	5461,68
Objet vide	339	577,45
Caisse	59	218,21
Emplacement caisse	12	87,55
Indéterminé	33	135,16
Moules	357	5995,13
Piège à poissons	1	1013,52
Table pleine	918	8788,17
Table vide	395	1604,78

6.3 Résultats

On évalue les performances du modèle grâce à la précision des prédictions sur des imageries par rapport à la digitalisation manuelle. Une partie de la base de données d'apprentissage est extraite avant la phase d'apprentissage pour former un « ensemble de validation », qui sert à évaluer le modèle sur des imageries qui n'ont pas été utilisées pour l'entraîner. La Figure 38 présente la matrice de confusion du modèle obtenue sur cet ensemble de validation.

La classe « NC » fait référence à la « non classe », c'est-à-dire tout ce qui ne rentre pas dans la typologie sur les différents secteurs digitalisés. Le déséquilibre entre le nombre d'échantillons de « non classe » et les échantillons de classe d'intérêt fausse la précision globale du modèle : on a une précision de 98%, alors que certaines classes, comme la classe « Indéterminé » sont très mal reconnues par le modèle. Les différentes valeurs du F-score montrent cependant qu'une majeure partie des classes est bien reconnue et prédite par le modèle, les résultats sont plutôt très encourageants.

La Figure 39 présente des résultats de prédictions pour chaque classe, accolés à l'imagerie et à la digitalisation manuelle. Les classes les plus représentées sont assez bien prédites, ce sont les classes de « Caisse », « Emplacement caisse » et « Indéterminé » qui sont les moins reconnues par le modèle. Il s'agit soit d'un manque d'échantillons d'apprentissage, soit d'une mauvaise définition du problème : la classe « Indéterminé » est très mal prédite, les objets apparentés à cette classe sont trop différents. C'est là que l'apport de connaissances thématiques sur l'activité conchylicole est indispensable : face à une grande variété d'objets sur l'image, une typologie avisée n'est possible qu'avec des échanges sur les types de culture et ce qu'on observe sur l'image.

Les figures Figure 40 à Figure 42 présentent des résultats de prédiction accolés aux digitalisations manuelles, sur les zones de digitalisation élargies.

OA: 0,983




Figure 38. Matrice de confusion du modèle, créée à partir de l'ensemble de validation.

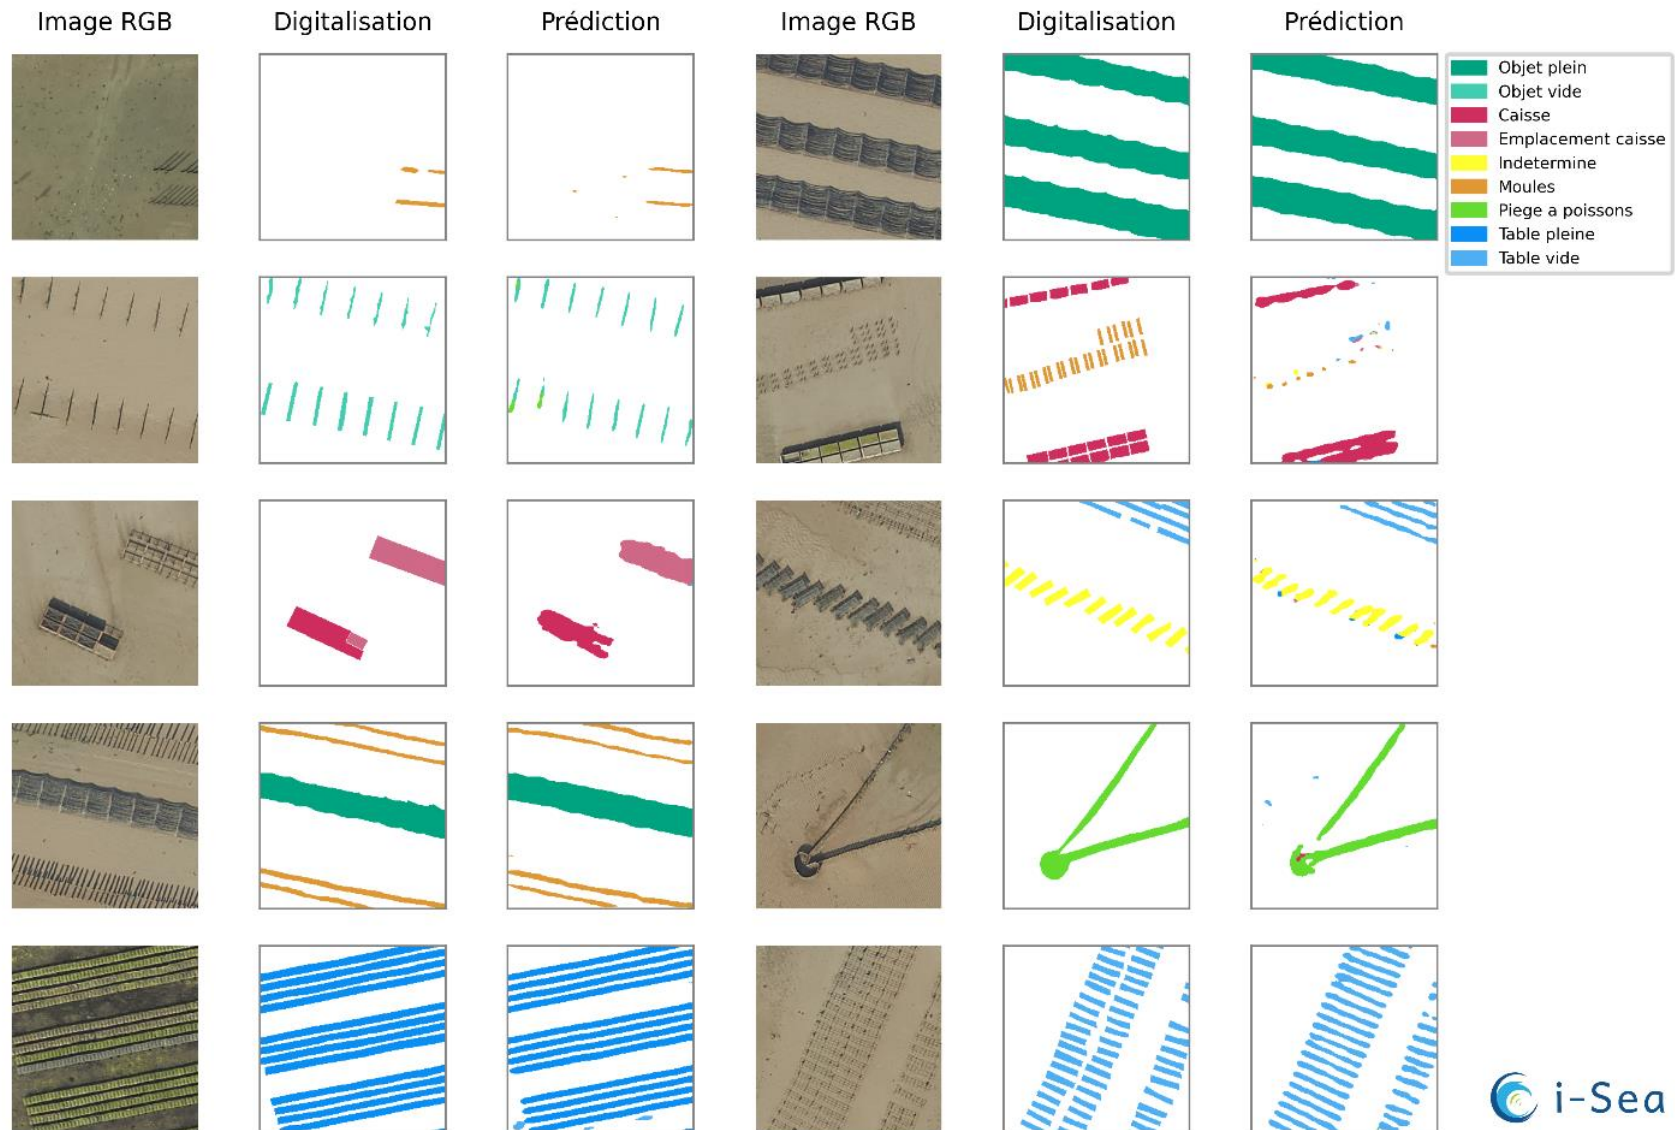



Figure 39. Visuels de comparaison RGB / Digitalisation / Prédiction illustrant chaque classe de la typologie.

Activité conchylicole digitalisée



Activité conchylicole prédite



Légende

- Zone(s) de digitalisations
- Zone(s) de prédiction
- Objet plein
- Objet vide
- Caisse
- Emplacement caisse
- Indeterminé
- Moules
- Piège à poissons
- Table pleine
- Table vide






Figure 40. Comparaison de la prédiction à la digitalisation manuelle sur un secteur d'étude élargi – zone 1.

Activité conchylicole digitalisée



Activité conchylicole prédite



Légende

- Zone(s) de digitalisations
- Zone(s) de prédiction
- Objet plein
- Objet vide
- Caisse
- Emplacement caisse
- Indeterminé
- Moules
- Piège à poissons
- Table pleine
- Table vide


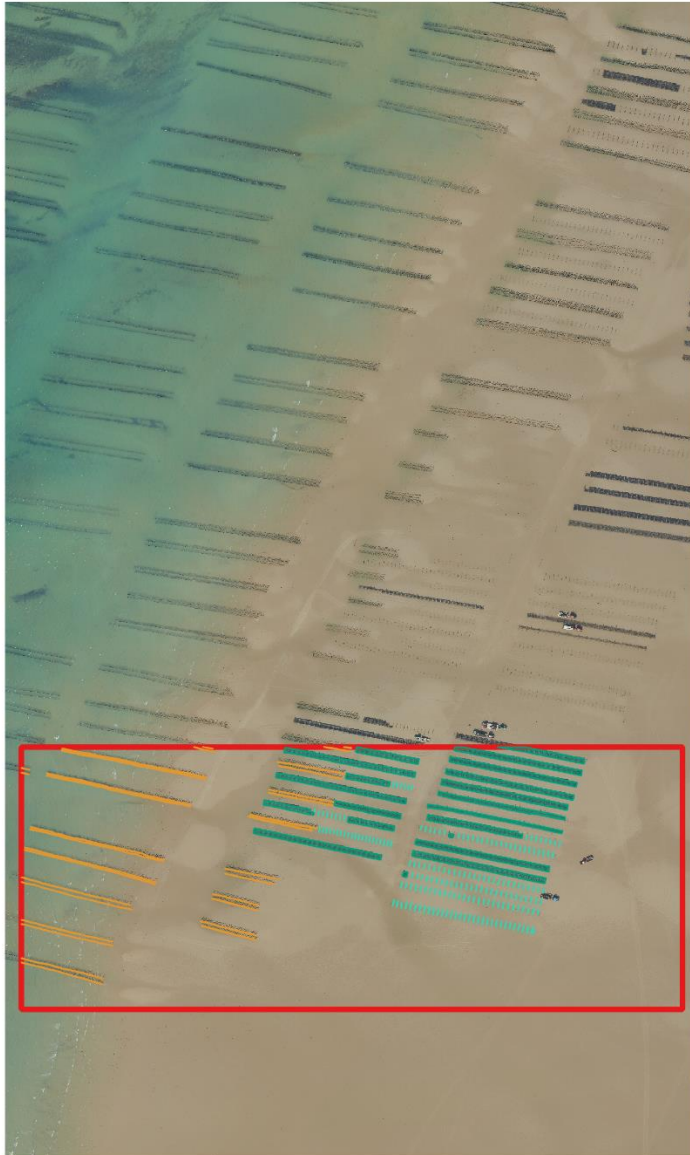



Figure 41. Comparaison de la prédiction à la digitalisation manuelle sur un secteur d'étude élargi – zone 2.

Activité conchylicole digitalisée



Activité conchylicole prédite



Légende

- Zone(s) de digitalisations
- Zone(s) de prédiction
- Objet plein
- Objet vide
- Caisse
- Emplacement caisse
- Indeterminé
- Moules
- Piège à poissons
- Table pleine
- Table vide




Figure 42. Comparaison de la prédiction à la digitalisation manuelle sur un secteur d'étude élargi – zone 3.

7 CONCLUSIONS

Notre approche de cartographie des friches et tables ostréicoles à partir d'orthophotographies (15 cm) développée sur le Bassin d'Arcachon a été adaptée et appliquée avec succès pour la cartographie d'activités conchylicoles à partir d'images Pléiades (50 cm).

L'effort de transfert et d'adaptation méthodologique s'est concentré sur les sites du Cotentin avec la constitution d'une base de données digitalisée spécifique. Cette base de données a permis de raffiner un modèle de prédiction hérité des travaux réalisés sur le Bassin d'Arcachon. Notre approche a été comparée avec une approche plus classique (Random Forest au niveau pixel que nous utilisons pour la cartographie des végétations et habitats naturels). Cette analyse comparative a montré que la méthode utilisée ici donnait de bien meilleurs résultats sur cette application : l'approche Deep Learning (SegNet) est à privilégier pour la cartographie des activités conchylicoles. La mise en œuvre de cet algorithme aboutit à des résultats très pertinents et satisfaisants sur l'ensemble de la côte du Cotentin.

Dans un second temps, on a cherché à démontrer le potentiel de généralisation de ce type d'algorithmes de détection en étendant notre process d'apprentissage à différentes images Pléiades, notamment sur le site d'Arcachon. On a ainsi montré que notre méthode a une bonne capacité de généralisation, ouvrant d'excellentes perspectives opérationnelles. On peut imaginer des modèles génériques à l'échelle des grandes façades maritimes, dont la performance reste toutefois à démontrer.

Enfin, la dernière étape de ce projet s'est intéressée à la caractérisation des types de tables ostréicoles, non distinguables à partir de l'analyse des images Pléiades. Suite aux travaux réalisés sur le Bassin d'Arcachon [2] (deep learning à partir d'orthophotographies à 15 cm de résolution), nous avons proposé une démonstration sur le Cotentin pour la caractérisation des types d'activités conchylicoles à partir d'orthophotographies (10 cm), avec succès.

Nous avons ainsi pu obtenir des images Pléiades exploitables - malgré les marées, les couvertures nuageuses, etc. - sur un grand linéaire côtier. Même dans le cas de niveau d'eau trop élevé, la méthode a montré de bons résultats sous l'eau. Dans le cas de secteurs n'ayant pas pu être observés par Pléiades durant un exercice, l'imagerie aéroportée peut être utilisée en complément pour la cartographie de grandes façades. Nous avons également montré que le niveau de détail atteignable avec ce type d'imagerie (avec des résolutions inférieures à 20 cm) permet la différenciation des types de culture et des stades d'exploitation, ceci représente un potentiel important pour la gestion locale des sites.

Dans un futur proche, nous pouvons imaginer à l'échelle de grandes façades, une plateforme en ligne permettant pour chaque image Pléiades acquise sur une zone d'intérêt, le déclenchement d'un traitement automatique de détection d'activités conchylicoles. Cette perspective, ainsi que la possibilité de développer des modèles génériques à l'échelle des façades maritimes, nous invite à poursuivre et approfondir les travaux réalisés dans le cadre de ce projet SACSAT.

8 BIBLIOGRAPHIE

- [1] i-Sea (2020). *Cartographie des friches ostréicoles du Bassin d’Arcachon via deep learning et imagerie aéroportée*. Rapport final, contrat OFB/PNMBA 2019-246, 10 p.
- [2] i-Sea (2022) *Cartographie des friches ostréicoles du Bassin d’Arcachon via Deep Learning et imagerie aéroportée*, Rapport volet 2: Evaluation complémentaire de la méthode pour la cartographie des tables et concessions ostréicoles du Bassin d’Arcachon. Rapport PNMBA Contrat RD 20 0711, i-Sea, 31 p.
- [3] Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- [4] Breiman, L., Friedman, J., Olshen, R., & Stone, C. (1984). *Cart. Classification and Regression Trees*.
- [5] LeCun, Y., & Bengio, Y. (1995). Convolutional networks for images, speech, and time series. *The handbook of brain theory and neural networks*, 3361(10), 1995.
- [6] Hubel, D. H., & Wiesel, T. N. (1962). Receptive fields, binocular interaction and functional architecture in the cat's visual cortex. *The Journal of physiology*, 160(1), 106.
- [7] Vijay Badrinarayanan, Alex Kendall, Roberto Cipolla (2015). *SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation*. <https://arxiv.org/abs/1511.00561>.

– Fin du document –