



# Automatisation du tri des images *CoastSnap* par IA : une réponse au flux croissant des données participatives

Adrien CARTIER<sup>1</sup> et Litissia HENKOUS<sup>1</sup>

1. Géodunes, 56 rue de la république 59430 St Pol sur Mer.

[cartier@geodunes.fr](mailto:cartier@geodunes.fr); [lhenkous@geodunes.fr](mailto:lhenkous@geodunes.fr)

## Résumé :

Dans l'optique d'une optimisation des traitements Coastsnap, un module complémentaire a été développé afin de permettre l'importation automatique des images, l'extraction des Exifs, l'attribution automatique des hauteurs d'eau à partir des données marégraphiques, le tri qualitatif, la visibilité de la limite Terre-Mer ainsi que l'alignement des clichés. Plusieurs approches numériques IA ont été testées telles que la Vision Par Ordinateur (VPO) et du Deep Learning (DL) notamment pour : 1) le tri (exploitables/non exploitables, algorithme AKAZE) ; 2) l'alignement des clichés (Méthode ORB) ; 3) la détection la mer. Les résultats de ces tests de sensibilité de modèles IA ont montré leur potentiel pour l'optimisation de la gestion du flux de données. L'apprentissage profond s'est révélé inefficace pour l'alignement des photos au contraire de la VPO qui peut approcher les 100% de réussite. Pour les phases de classification, les 2 méthodes présentent des résultats satisfaisant dépendant fortement du nombre d'images disponibles et des caractéristiques environnementales observables.

**Mots-clés :** sciences participatives, intelligence artificielle, deep learning, littoral, coastsnap

## 1. Introduction

Lancé en 2017 à l'initiative de l'UNSW (Université de Nouvelle-Galles du Sud) par l'équipe de Mitchell Harley (HARLEY *et al.*, 2019) le système Coastsnap connaît un essor significatif en 2026 avec plus de 600 stations à travers le monde. En France, de nombreux territoires se sont dotés du dispositif portant le nombre de stations à environ une soixantaine. Ce système de sciences participatives permet d'analyser quantitativement les évolutions morphologiques des environnements côtiers observés (DEBURGHGRAEVE *et al.*, 2023) mais également de mesurer l'évolution d'un indicateur côtier : la limite terre-mer (LTM). Outre la mise en valeur des données récoltées (SOUZA *et al.*, 2026, FRANCE *et al.*, 2025), l'aspect participatif (ELRICK-BARR *et al.*, 2023), ou les analyses issues de l'algorithme, le développement purement

technique du système est peu documenté. CARTIER et al, (2024) ont récemment mis en exergue l'évaluation du système sur des environnements sableux macrotidaux ainsi qu'une description précise de la phase de paramétrage.

Bien que conceptualisés dès le milieu du XXe siècle (TURING, 1950), l'intelligence artificielle (IA) a été récemment mise en lumière auprès du grand public notamment grâce à la démocratisation des agents conversationnels. Les modèles génératifs actuels ont rendu accessibles ces méthodologies à un écosystème de chercheurs plus vaste. En morphodynamique du littoral, l'utilisation du Deep Learning et du Machine Learning (LECUN et al., 2015) est encore peu fréquente et tente de se placer comme une alternative moins chronophage aux modèles numériques classiques. Récemment, SENECHAL et COCO (2024) se sont notamment intéressés à la prédiction de la position du trait de côte à partir de différents jeux de données dont des images Coastsnap tout en utilisant des architectures de réseaux de neurones.

La gestion du flux de données inhérentes aux sciences participatives est alors un point essentiel pour la mise en valeurs rapide des données récoltées. En l'état actuel, très peu de documentation existe spécifiquement sur la manière de gérer l'important volume de données générées par les stations Coastsnap. La gestion et le tri des photos sont réalisés manuellement ce qui devient particulièrement chronophage avec l'augmentation du nombre de photographies et de stations. Si des données numériques classiques peuvent être facilement automatisées, la reconnaissance d'objet et l'interprétation qualitative d'une image fait appel à des méthodologies plus complexes.

Cette étude vise donc à évaluer la performance de plusieurs algorithmes d'IA avec l'objectif d'automatiser la pré-sélection des clichés en vue d'une analyse morphodynamique fine au sein du système Coastsnap.

## **2. Présentation des stations**

L'étude est basée sur l'acquisition de clichés provenant de plusieurs stations Coastsnap positionnées sur le littoral de la Manche et de la Mer du Nord (voir figure 1). Ces stations appartiennent à 3 réseaux Coastsnap différents : Côte d'Opale, Ter'Bessin et Seinomarin (à travers le Syndicat Mixte du Littoral de Seine-Maritime, SML76). Les stations de la Côte d'Opale sont localisées sur la façade Mer du Nord de Dunkerque (Nord) au niveau de secteurs stratégiques comme : 1) la Digue des Alliés (DDA) où la plage est soumise à des rechargements annuels; 2) le cordon dunaire de Zuydcoote (ZDC) protégé par des ganivelles et les dunes du Perroquet (PER) situé au droit d'un camping littoral. Sur le territoire du Ter'Bessin (Calvados), les stations sont positionnées de part et d'autre de la plage artificielle de Grandcamp-Maisy, surveillant à l'ouest (GCMO), le niveau de sable au pied du perré du quai Crampon et à l'est (GCME), le cordon de galets protégeant les habitations de la commune. En Seine-Maritime, les stations sont toutes localisées sur des secteurs à forts enjeux et caractérisées par la présence d'un cordon de galets très dynamique. La station de Ste Adresse (STA) au nord du Havre permet de suivre

l'évolution du stock de sédiments dans les casiers d'épis jalonnant l'ensemble du linéaire local. A Etretat (ETR) et Veulettes sur mer (VSM), les stations permettent de suivre à haute fréquence le niveau de galets en pied d'ouvrage.

La diversité des environnements surveillés par ces différentes stations (plages macrotidales, environnements dunaires, pied de perré et cordon de galets) permet d'avoir un jeu de données varié, idéal pour tester différents algorithmes de traitements d'image.

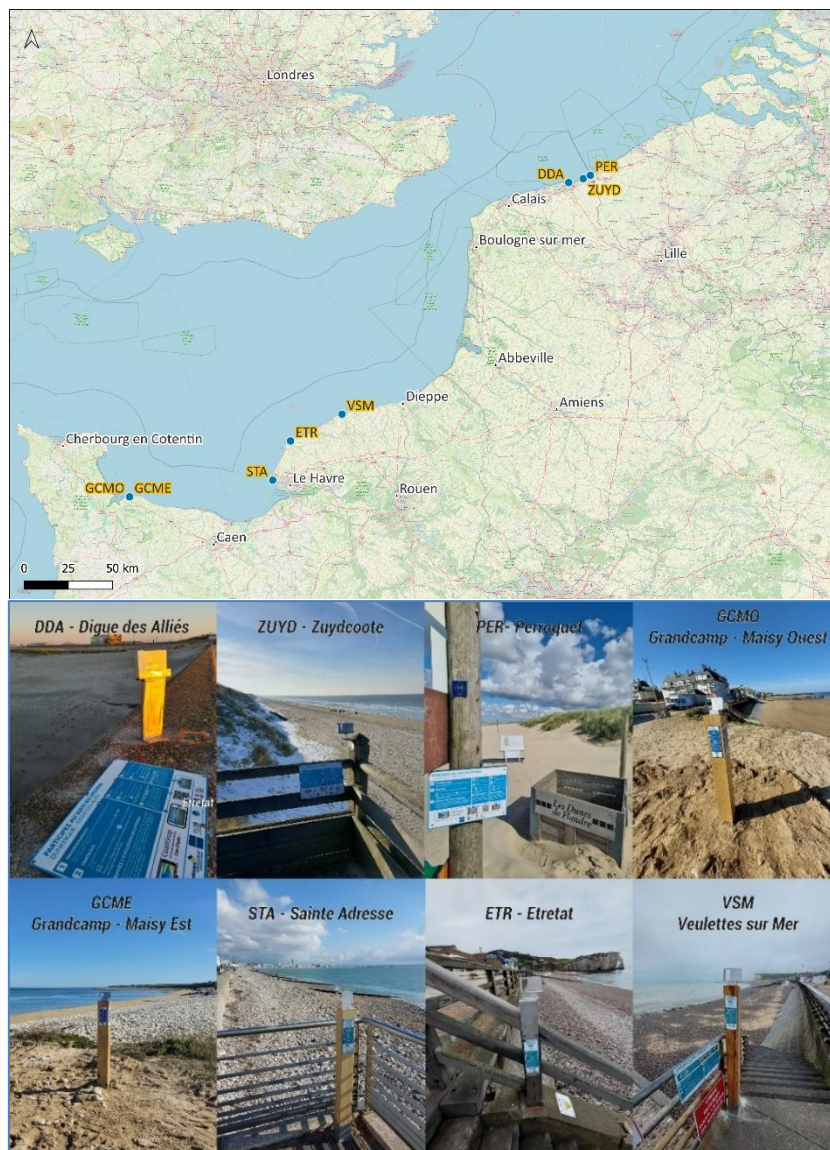


Figure 1. Localisation des stations Coastsnap

### 3. Méthodologie

En amont de l'utilisation de l'algorithme Coastsnap, il est primordial de réaliser un pré-traitement des images reçues afin d'obtenir une base de données fiables et exploitables pour leur analyse future. Quatre phases sont nécessaires : 1) un pré-tri en fonction du dimensionnement des photos ; 2) l'élimination des photos non exploitables (floue, mal

cadrée, hors sujet, mauvaise colorimétrie etc.); 3) l'alignement des clichés à partir d'une photo dite de référence; 4) la détection de la mer sur les images afin d'isoler les photos qui pourront être traitées par l'algorithme Coastsnap avec pour objectif de détecter la limite Terre-Mer (LTM) (voir figure 2). L'ensemble de ce workflow vise donc à optimiser la qualité des clichés reçus dans le but d'affiner les analyses quantitatives (détection de la LTM) et qualitatives (suivi visuel de la morphodynamique).

En raison du volume important de données reçues et de la nécessité de pouvoir mettre en valeur rapidement les résultats de ces suivis à court terme, plusieurs approches numériques IA ont été testées telles que la Vision Par Ordinateur (VPO) et le Deep Learning (DL).

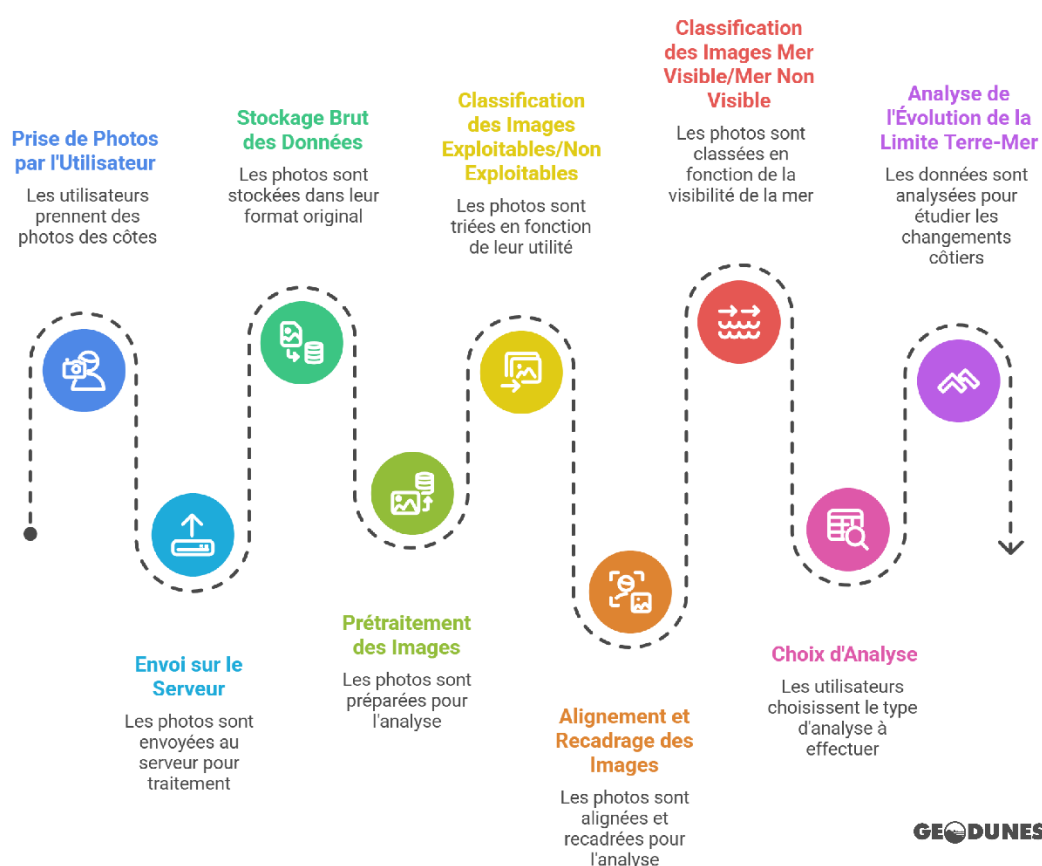


Figure 2. Chaîne de traitement des photographies avant leur analyse via Coastsnap

Les analyses ont porté sur un jeu de données brut de 1607 images couvrant une période temporelle de Août 2023 à Décembre 2025, ce jeu de données correspond à l'ensemble des images collectées avant la phase de prétraitement (voir tableau 1).

Tableau 1. Synthèse des photographies récoltés et analysées dans le cadre de l'étude

Territoire	Stations	Périodes temporelles	Avant pré-traitement	Après pré-traitement	
			Nombre d'images	Nombre d'images	Total
Côte d'Opale	DDA	Août 2023 – Décembre 2025	1020	753	926
	ZUYD	Septembre 2023 – Octobre 2025	187	139	
	PER	Septembre 2024 – Novembre 2025	42	34	
Ter Bessin	GCMO	Avril 2025 – Novembre 2025	58	27	70
	GCME	Mars 2025 – Août 2025	41	43	
SML76	VSM	Juillet 2025 – Décembre 2025	159	103	181
	STA	Octobre 2025 – Decembre 2025	71	55	
	ETR	Septembre 2025 – Décembre 2025	29	23	

### 3.1 La Vision Par Ordinateur

La VPO est un ensemble de méthodes permettant aux machines d'analyser une image comme le ferait un humain. Ces méthodes sont caractérisées par des algorithmes mathématiques permettant d'extraire des caractéristiques visuelles à partir d'images. Dans cette étude, trois algorithmes ont été utilisés en fonction des besoins spécifiques de chaque phase (2 à 4).

Au cours de la phase de tri (2), et à partir d'une image de référence considérée comme exploitable, l'algorithme AKAZE (*Accelerated KAZE*) permet de détecter des points de correspondance entre l'image de référence et l'image testée (voir figure 3). En fonction du nombre de correspondances détectées et de la définition d'un seuil, l'image est classée comme étant exploitable ou non exploitable.

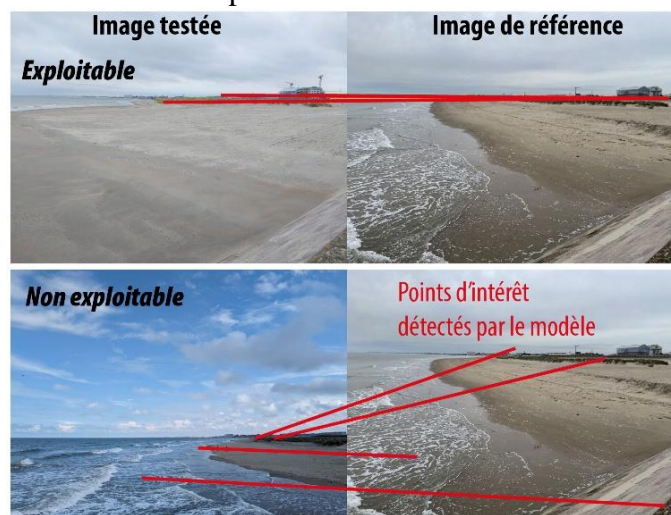


Figure 3. Exemple de détection de points d'intérêt par l'algorithme AKAZE.

L'algorithme ORB (*Oriented FAST and Rotated BRIEF*) a été utilisé pour la phase d'alignement (3). Celui-ci permet de calculer l'orientation des points d'intérêt puis de réaliser une transformation géométrique des photographies (principe homographique) afin de correspondre à une image de référence prédéfinie (voir figure 4).




Figure 4. Exemple de détection de points d'intérêt par l'algorithme ORB avant l'alignement de l'image testée.

La visibilité de la mer sur les clichés (4) a été déterminée grâce à l'espace de couleur HSV (Hue, Saturation, Value) implémentée de filtres de Gabor (voir figure 5). La mer étant caractérisée par une signature chromatique dominante dans la gamme bleu-cyan, l'algorithme identifie les images avec une forte proportion de ces couleurs.

Les filtres de Gabor sont ensuite utilisés pour analyser les textures dans les images afin d'identifier des motifs orientés tels que : les vagues et les structures répétitives. La combinaison de ces 2 paramètres (couleur + texture) permet de classifier les photographies.




Figure 5. Exemple de traitement d'image par l'algorithme HSV.

### 3.2 Le Deep Learning

Le principe de base du DL repose sur une phase d'apprentissage du modèle à partir d'un jeu de données prédéfini, fourni par l'opérateur ou à partir d'un modèle pré-entraîné. En théorie, l'apprentissage doit se baser sur une proportion similaire d'images dites positives et négatives, or notre base de données n'est pas suffisante (E.g. 9% de photos non exploitables).

Un modèle d'apprentissage par transfert (*Transfer Learning*) a donc été utilisé pour les phases 2 et 4, associé à une validation croisée en 5 *fold* . Ainsi, 80% du jeu de données

est utilisé pour l'entraînement et 20% pour la validation du modèle (STONE, 1974). Celui-ci est ensuite entraîné 5 fois à partir d'un échantillonnage d'image différent défini aléatoirement pour chaque itération. Par ailleurs, ces modèles utilisent le réseau de neurones convolutionnels VGG16 largement reconnu et pré-entraîné sur des millions d'images (SIMONYAN et ZISSERMAN, 2014), ce qui limite le biais lié au faible nombre de photos disponibles.

Pour la phase 3 d'alignement, l'approche hybride combine le modèle LoFTR (*Local Feature Transformer*), l'algorithme RANSAC (*RANdom SAmple Consensus*) et une transformation homographique. Le modèle LoFTR permet d'estimer des correspondances pixel à pixel sans détecteur de point clé préalable comme le fait la VPO. Tout comme le réseau VGG16, le modèle LoFTR est pré-entraîné sur un jeu de données de scènes extérieures et conçu pour la reconnaissance de correspondances entre deux images. L'algorithme RANSAC filtre les points afin d'effectuer une transformation géométrique par homographie permettant ainsi d'aligner les photos.

#### **4. Résultats**

Pour chaque phase, les résultats issus des modèles VPO et DL sont confrontés avec le classement manuel réalisé par un opérateur. Plusieurs critères strictes ont donc été définies afin de ne pas laisser de place à une interprétation trop subjective.

##### 4.1 Présentation des métriques

Une métrique est un outil statistique qui aide à évaluer la performance d'un modèle. Il existe plusieurs métriques dans le domaine du DL et du traitement d'images :

- *Le Recall* : mesure la proportion d'éléments positifs correctement détectés parmi l'ensemble des éléments réellement positifs (E.g. un recall de 80 % signifie que le modèle détecte 80 % des images où la mer est réellement visible) ;
- *La Précision* : mesure la proportion de prédictions positives correctes parmi l'ensemble des prédictions positives (E.g. une précision de 80 % signifie que lorsque le modèle prédit qu'il y a de la mer visible, il a raison dans 80 % des cas);
- *Le F1-Score* : est la moyenne harmonique de la précision et du recall. Il permet d'évaluer l'équilibre entre la capacité du modèle à détecter les positifs et la fiabilité de ces détection (E.g. Un F1-score de 80 % indique que le modèle parvient à détecter la majorité des images comportant une mer visible tout en limitant raisonnablement les erreurs de classification) ;

Dans le cadre de cette étude, l'analyse va se concentrer principalement sur quelques métriques jugées les plus pertinentes notamment le F1-Score.

#### 4.2 Phase 2 : Exploitable/Non Exploitable

L'algorithme AKAZE utilisé par le modèle VPO permet l'utilisation de plusieurs seuils de détection des points d'intérêt (10, 15, 50, 80 et 150) afin d'analyser le comportement du modèle. Plus le seuil est élevé, plus le nombre de points de correspondance est important ce qui augmente le niveau d'exigence de classification.

L'analyse montre que les meilleurs résultats sont obtenus avec des seuils faibles de 10 et 15 où le F1-score atteint 64% en moyenne. Pour les seuils élevés de 50 à 150, il atteint seulement 23%. Il y a également une forte hétérogénéité des résultats entre les sites notamment des scores faibles pour DDA (47%), PER (30%) et ZUYD (59%). Lorsque la scène observée présente peu d'éléments fixes, comme c'est le cas des stations dunaires ZUYD et PER, les performances du modèle chutent en raison d'une grande variabilité des pixels lié à la dynamique dunaire. Sur le site DDA, la base de données plus importante (753 images) ainsi que la période temporelle de 2 ans impliquant des changements significatifs de la morphologie de la plage génère une plus faible performance du modèle.

Tableau 2. Synthèse du F1-Score (%) pour la détermination de l'exploitabilité des photographies par VPO et l'algorithme AKAZE

Sites	Seuil Akaze avec 1 photo de référence				
	10	15	50	80	150
DDA	47%	47%	1%	1%	0%
ETR	91%	91%	69%	59%	42%
GCME	83%	62%	26%	26%	14%
GCMO	72%	55%	5%	0%	0%
PER	30%	13%	7%	7%	7%
STA	96%	81%	70%	66%	35%
VSM	85%	76%	29%	14%	8%
ZUYD	59%	40%	0%	0%	0%
Sites	Seuil Akaze avec 2 photos de référence				
	10	15	50	80	150
DDA	54%	25%	1%	1%	0%
ETR	94%	94%	77%	69%	42%
GCME	100%	94%	41%	41%	41%
GCMO	96%	96%	60%	60%	60%
PER	44%	26%	13%	13%	13%
STA	98%	98%	95%	93%	87%
VSM	94%	89%	35%	16%	2%
ZUYD	73%	52%	6%	6%	6%

L'ajout d'une 2<sup>e</sup> image de référence augmente par conséquent l'efficacité du modèle. Par exemple, sur le site GCMO, le F1-Score passe de 72% à 96% et de 59% à 73% sur le site ZUYD pour le seuil de 10 (voir tableau 2). Sur GCMO, la végétation au premier plan s'est bien développée et sur ZUYD, les ganivelles ont complètement disparu suite à l'engraissement du pied de dune. Sur ces deux sites, l'environnement observé évolue donc de manière significative. Tant que le modèle n'a pas été soumis à des images comportant ces modifications visuelles, il classera comme non exploitable ces images alors qu'elles le sont parfaitement.

Les résultats issus du DL montrent également des performances hétérogènes en fonction des sites et apparaissent plus performants que la VPO dans certains cas. Il est globalement meilleur sur les sites DDA, ZDC, PER et GCMO (+20%). Il est en revanche moins performant sur les sites GCME, ETR, VSM et chute complètement sur le site STA avec un F1-score de seulement 40%.

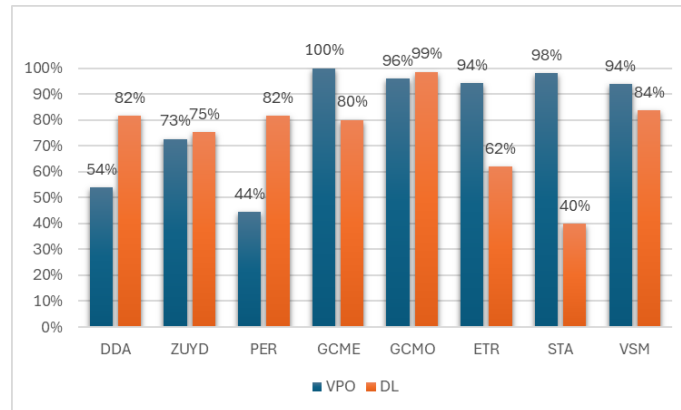


Figure 6. Comparaison du F1-score entre la VPO et le DL pour la phase de classification des photographies exploitables

#### 4.2 Phase 3 : Alignement des clichés

Pour l'évaluation de l'alignement des clichés, l'image est considérée comme bien alignée si le cadrage est identique et superposable à l'image de référence. Il n'y a donc pas de classification comme pour les phases 2 et 4, l'image est bien alignée ou non. Les résultats montrent que le Deep Learning échoue complètement pour l'alignement des images où aucune image autre que celle de référence parvient à être aligné (voir tableau 3).

Les résultats issus de la VPO montrent une grande variabilité entre les sites où le % de réussite est proche de 100% pour GCM et STA.

Tableau 3. Performances des modèles VPO et DL pour l'alignement des photographies

Secteurs	Sites	VPO		% OK par Secteur	DL		% OK par Secteur
		Nb d'images alignées (OK)	% OK		Nb d'images alignées (OK)	% OK	
Cote d'opale	DDA	529	77%	50%	1	0%	2%
	ZDC	50	40%		1	1%	
	PER	9	33%		1	4%	
Ter'Bessin	GCMO	33	89%	89%	1	3%	3%
	GCME	24	89%		1	4%	
SML76	STA	21	41%	51%	1	2%	3%
	VSM	72	77%		1	1%	
	ETR	6	35%		1	6%	

Il est de l'ordre de 70 à 80% pour VSM, ETR et DDA alors qu'il est de seulement de 30% pour ZUYD et PER. Les meilleurs résultats sont donc atteints au niveau des stations présentant de nombreux éléments fixes et stables dans le temps (perré, digue etc.). Sur les zones dunaires comme ZUYD et PER, la majorité de l'image est caractérisée par des

éléments potentiellement mobiles et par une plus grande variabilité des textures. Le modèle a donc plus de difficulté à aligner les photographies.

#### 4.3 Phase 4 : Limite Terre-Mer Visible / Non visible

Les environnements macrotidaux impliquent une forte variation du plan d'eau à travers la zone intertidale. Par conséquent, certaines stations ne permettent pas la visualisation de la LTM au cours de la marée basse.

Les résultats montrent une meilleure performance du DL vis-à-vis de la VPO avec également une variabilité entre les différents sites et secteurs (voir figure 7). Par exemple, sur le site DDA, la VPO a une performance de seulement 4% contre 89% avec le DL. Sur les sites PER et GCMO, aucune des 2 méthodes ne parvient à classifier les images sans doute en raison du faible nombre de clichés (34 pour PER et 27 pour GCMO). Néanmoins, les stations ETR, GCME et STA ont également une base de données limitée (<60 clichés) ce qui suggère l'importance des caractéristiques intrinsèques de la scène et de sa variabilité au sein du jeu de données disponible.

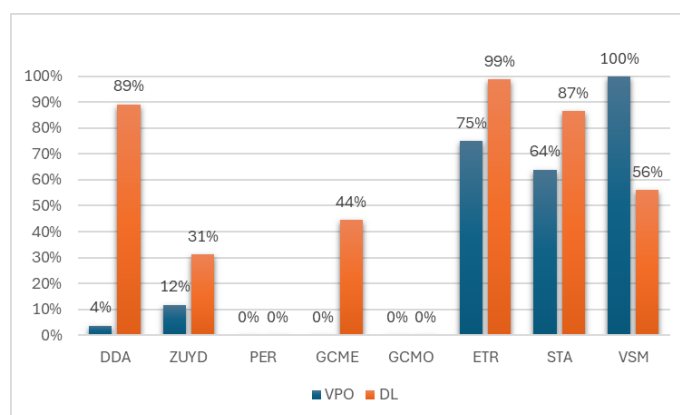


Figure 7. Comparaison du F1-score entre la VPO et le DL pour la phase de classification des photographies mer visible/mer non visible

## 5. Discussion

Les résultats de ces tests de sensibilité de modèles IA pour la classification et le traitement des images Coastsnap ont montré leur potentiel pour l'optimisation de la gestion du flux de données. Initialement géré manuellement par un opérateur, la possibilité d'automatiser certaines tâches de reconnaissance qualitative permet de réduire drastiquement le temps de préparation des images en vue de leur analyse morphosédimentaire. Néanmoins, la performance des modèles algorithmiques d'intelligence artificielle comme la VPO et le Deep Learning est fortement dépendante des caractéristiques de la base de données.

La VPO classique ne nécessite pas un nombre important d'image car les paramètres sont fixés manuellement. En revanche, la représentativité de la variabilité de la scène est fondamentale comme le montre les différences de performance entre 1 et 2 images de

références pour la phase 2. A contrario, l'apprentissage profond (DL) prend en compte la base de données dans son ensemble. Il permet d'apprendre les représentations internes et les motifs complexes des images proposées. Il a cependant besoin de beaucoup de données avec un équilibre dans les classes à déterminer. Le fait d'utiliser des modèles pré-entraînés comme le VGG16 permet d'obtenir des résultats satisfaisants mais si l'équilibre entre les classes est trop différent, le modèle va naturellement privilégier la classe majoritaire comme c'est le cas pour la classification exploitable/non exploitable (Phase 2).

Le Deep Learning peut également subir un phénomène de surentraînement lorsque le modèle s'adapte excessivement aux données d'apprentissage, ce qui dégrade sa capacité à s'adapter à de nouvelles données. Les performances élevées observées sur les sites PER et ZUYD pour la phase 2 suggèrent ce phénomène en raison du faible nombre de photos disponibles. L'apprentissage profond s'est révélé également inefficace pour l'alignement des photos au contraire de la VPO qui peut approcher les 100% de réussite. Les modèles de Deep Learning sont essentiellement conçus pour de la classification et non la réalisation de traitement. Ainsi, une seconde phase d'analyse serait d'utiliser un modèle DL pour évaluer l'alignement réalisé par la VPO.

## **6. Conclusions**

L'étude a démontré le potentiel des méthodologies d'intelligence artificielle pour le pré-traitement automatisé des images issues du suivi participatif Coastsnap. Bien que ces approches ne puissent se substituer totalement à l'expertise humaine, notamment pour la validation finale des résultats, elles permettent de réduire significativement le temps consacré à la gestion et à la préparation des données en vue d'analyses morphosédimentaires. La Vision Par Ordinateur apparaît particulièrement adaptée pour l'alignement des photos tandis que le Deep Learning est plus performant pour les tâches de classification (Phase 2 et 4) avec cependant une forte dépendance aux caractéristiques de la base d'images disponibles. Les modèles et les paramètres utilisés dans le cadre de cette étude peuvent être modifiés et optimisés comme les caractéristiques des filtres de Gabor pour la classification de la visibilité de la mer. Des approches hybrides plus complexes combinant vision par ordinateur classique, apprentissage profond et contraintes géométriques, pourraient également être explorées afin d'améliorer la robustesse des classifications. Indéniablement, la diversité des images et le nombre de photos disponibles sont au cœur de la performance de ces modèles. Ils sont en effet dans l'incapacité de reconnaître une scène qui n'a jamais été vue au cours de la phase d'entraînement.

## **7. Références bibliographiques**

CARTIER A., BLAISE E., GIRAUD N. (2024). *Paramétrage et évaluation de la performance du système CoastSnap dans la surveillance du trait de côte sur le littoral du*

*nord de la France, Dunkerque (59)*. XVIIIèmes Journées Nationales Génie Côtier – Génie Civil, Anglet. <https://doi.org/10.5150/jngcgc.2024.049>

DEBURGHGRAEVE A., ROBINET A., LECACHEUX S., BOUVIER C., SIMON E., ROSEBERY D. (2023). *Monitoring shoreline rotation with a CoastSnap system at the mesotidal embayed beach of Lafitenia, France*. *Coastal Sediments 2023*, pp 296–304. [https://doi.org/10.1142/9789811275135\\_0026](https://doi.org/10.1142/9789811275135_0026)

ELRICK-BARR C.E., CLIFTON J., CUTTLER M., PERRY C., ROGERS A.A. (2023). *Understanding coastal social values through citizen science: the example of CoastSnap in Western Australia*. *Ocean & Coastal Management*, Vol. 238, 106563. <https://doi.org/10.1016/j.ocecoaman.2023.106563>

FRANCE A., MCNAUGHT K., O'MALLEY N., ROULSTON J., WIGLEY T. (2025). *CoastSnap: Working with the Hurunui District Council*. Report produced as part of the GEOG309 – Research for Resilient Communities and Environments course, University of Canterbury.

HARLEY M.D., KINSELA M., SÁNCHEZ-GARCÍA E., VOS K. (2019). *Shoreline change mapping using crowd-sourced smartphone images*. *Coastal Engineering*, Vol. 150, pp 175–189. <https://doi.org/10.1016/j.coastaleng.2019.04.003>

LECUN Y., BENGIO Y., HINTON G. (2015). *Deep learning*. *Nature*, Vol. 521, pp 436–444. <https://doi.org/10.1038/nature14539>

SÉNÉCHAL N., COCO G. (2024). *On the role of hydrodynamic and morphologic variables on neural network prediction of shoreline dynamics*. *Geomorphology*, Vol. 451, 109084.

SIMONYAN K., ZISSERMAN A. (2014). *Very deep convolutional networks for large-scale image recognition*. International Conference on Learning Representations (ICLR 2015).

SOUZA V.G., ALBUQUERQUE M.G., PAULA D.P., LEINS M.M., FAÇANHA M.C., BENDÔ A.R., FREITAS S.C. (2026). *Low-cost coastal monitoring using citizen scientist data: an overview of the CoastSnap program in Brazil*. *Finisterra*, LXI, e42824. <https://doi.org/10.18055/Finis42824>

STONE M. (1974). *Cross-validatory choice and assessment of statistical predictions*. *Journal of the Royal Statistical Society: Series B (Methodological)*, Vol. 36, No. 2, pp 111–147.

TURING A.M. (1950). *Computing machinery and intelligence*. *Mind*, Vol. 59, No. 236, pp 433–460.