



## Super-résolution appliquée à la modélisation spectrale des vagues en zone côtière

Jannik KUEHN <sup>1</sup>, Stéphane ABADIE <sup>1</sup>, Matthias DELPEY <sup>2</sup>, Volker ROEBER <sup>1</sup>

1. Université de Pau et des Pays de l'Adour, E2S-UPPA, SIAME, 64600 Anglet, France.

[jannik.kuhn@univ-pau.fr](mailto:jannik.kuhn@univ-pau.fr); [abadie@univ-pau.fr](mailto:abadie@univ-pau.fr); [volker.roeber@univ-pau.fr](mailto:volker.roeber@univ-pau.fr)

2. SUEZ Eau France, Rivages Pro Tech, 64210 Bidart, France.

### Résumé :

Récemment, les réseaux de neurones sont devenus une méthode courante pour augmenter la vitesse de calcul, au détriment parfois d'une certaine précision. Dans cette étude, nous présentons une approche de super-résolution qui agit comme une méthode hybride conciliant précision et vitesse pour le calcul de prévision de vagues. Cette méthode consiste à calculer une prévision de hauteur significative des vagues avec un modèle spectral à basse résolution, puis à augmenter la résolution de la prévision à l'aide d'un réseau de neurones en graphes. La faisabilité de cette approche est démontrée dans une étude de cas basée sur un jeu de données produit par une simulation spectrale rétrospective (hindcast) de 44 ans couvrant la côte basque française. Nous montrons que l'approche proposée est jusqu'à 70 fois plus rapide que le modèle spectral avec une erreur très limitée.

### Mots-clés :

Apprentissage profond, SWAN, Modèle numérique spectral, Super-résolution, Réseaux de neurones en graphes.

### 1. Introduction

La prévision précise des vagues en zone côtière est indispensable à la gestion du littoral (GOPINATH & DWARAKISH, 2015). Or, bien que l'océan mondial hauturier soit aujourd'hui largement couvert par les systèmes de modélisation de vagues des grands centres de météorologie nationaux et internationaux, les prévisions à l'échelle locale en zone côtière sont encore assez peu développées du fait de l'importante charge de calcul nécessaire (CAMUS *et al.*, 2011).

Avec la récente montée en puissance de l'intelligence artificielle, les approches statistiques ou d'apprentissage profond sont devenues de plus en plus courantes, y compris dans l'étude des états de mer. Une des techniques courantes consiste à entraîner un réseau de neurones pour remplacer les calculs numériques de vagues tout en réduisant considérablement le coût de calcul. Cependant, cette économie est souvent obtenue au détriment de la précision de l'information produite (JAMES *et al.*, 2018). La méthode

## Thème 1 – Hydrodynamique marine et côtière

utilisée dans cette étude s'inspire de ce type de techniques, avec pour objectif de réduire la perte de précision. Plus précisément, nous avons opté pour une approche de super-résolution, dont le but est de convertir les résultats de modèles à basse résolution spatiale en données de meilleure résolution à l'aide d'un réseau de neurones en graphes (GNN). Cette méthode vise à concilier la précision des modèles numériques de vagues traditionnels et la rapidité des modèles de substitution. Dans le cadre de l'océanographie, ZHU *et al.*, (2023) et KUEHN *et al.*, (2023) ont déjà appliqué la super-résolution afin de réduire le temps de calcul de modèles numériques à maillage structuré pour la prévision de la hauteur des vagues. Bien que des modèles de substitution pour des prévisions de vagues existent déjà sur des maillages non structurés (SHI *et al.*, 2022), ce n'est pas encore le cas pour la super-résolution. L'objectif de la présente étude est, dans un premier temps, d'étendre l'approche de super-résolution aux maillages non structurés, et dans un second temps, d'analyser les performances de différents modèles appliqués à différents climats de vagues.

### 2. Jeu de données

Nous avons choisi de travailler avec la base de données d'hindcast de 44 ans dans la zone côtière basque par (LASTIRI *et al.*, 2020). Cette base de données a été initialement générée afin d'optimiser l'emplacement des convertisseurs d'énergie de vagues dans la région (Figure 1). Cet hindcast a été réalisé à l'aide du modèle spectral de référence SWAN. Les calculs de ce modèle ont été effectués sur un maillage non structuré comportant 45156 nœuds. Les mailles sont triangulaires avec des pas variables de 100 m aux alentours du canyon de Capbreton et de la côte, jusqu'à 2000 m plus au large. Pour plus d'informations sur la configuration du modèle et de la simulation d'hindcast, le lecteur pourra se référer à (LASTIRI *et al.*, 2020).

Pour créer un jeu de données à basse résolution de l'hindcast initial, nous utilisons la même configuration pour le modèle SWAN (BOOIJ *et al.*, 1999) mais avec un maillage de calcul beaucoup plus grossier. Pour créer ce maillage, la procédure suivie est rigoureusement identique à celle employée par LASTIRI *et al.*, (2020), mais la longueur des arêtes des cellules est augmentée d'un facteur 8. Le maillage est généré par triangulation de Delaunay contrainte avec des angles minimums de 25° pour s'assurer qu'il soit conforme aux prérequis de SWAN. Le nombre de nœuds du maillage basse résolution est ainsi réduit à 1059, soit un facteur de sous-échantillonnage global de 42. Nous disposons ainsi pour notre étude d'une chronique de vagues de 44 ans à haute résolution (hindcast initial sur 45156 nœuds) et son homologue à basse résolution (hindcast sur grille réduite à 1059 nœuds).

Etant donné qu'il est très coûteux en puissance de calcul d'entraîner un réseau de neurones sur tout le domaine couvert par le modèle, et que les zones d'intérêt sont généralement limitées à quelques régions spécifiques, il a été décidé pour notre analyse de diviser l'hindcast en trois régions d'étude, avec des climats de vagues bien distincts. La Figure 1

montre la localisation des trois régions par rapport à l'ensemble de la zone d'étude. La région 1 est située au sud du canyon sous-marin de Capbreton et couvre les plages de Biarritz et ses alentours. Cette région est caractérisée par des plages rocailleuses avec une bathymétrie locale hétérogène, ce qui influence fortement la distribution spatiale des vagues localement. Plus au nord, la région 2 englobe la côte autour de Capbreton, à la sortie du canyon sous-marin, dont l'influence sur le champ de vagues est dominante. Enfin, la région 3 est située plus au nord dans la région des Landes, où la bathymétrie est beaucoup plus régulière le long de la côte ; par conséquent, le champ de vagues est principalement uniforme dans cette région.

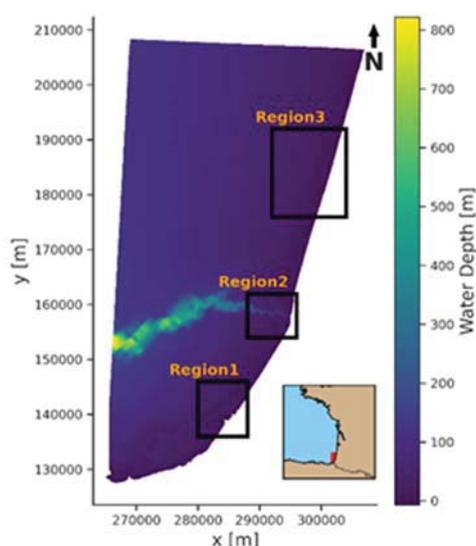


Figure 1. Bathymétrie de la zone d'étude.  
Système de coordonnées : Lambert III, EPSG :27573.

Afin de maintenir une quantité raisonnable de données d'entraînement, un sous-ensemble de 5 ans, extrait de l'hindcast original de 44 ans, est utilisé pour l'entraînement ; celui-ci s'étend de 1959 à 1963, et l'année complète de 1964 est utilisée à des fins de test. Ce jeu d'entraînement est lui-même à nouveau divisé avec 80% dédiés à l'entraînement des modèles, et 20% mis de côté pour la validation.

### 3. Méthodologie

À l'origine, la super-résolution est une problématique classique de vision par ordinateur (computer vision). La question sous-jacente est de savoir s'il est possible de reconstruire des détails à haute résolution à partir d'une image à basse résolution et, si oui, dans quelle mesure. Dans cette optique, la méthode privilégiée ces dernières années est celle des réseaux de neurones. Ces derniers sont entraînés à la fois sur des données à basse et à haute résolution et sont capables d'extraire des motifs récurrents dans les données. Ainsi, KUEHN *et al.*, (2023) montrent que la super-résolution est capable de convertir la sortie

## Thème 1 – Hydrodynamique marine et côtière

d'un calcul numérique de vagues sur une grille de 10x10 cellules en une information affinée sur une grille de 160x160 sur la même extension. Les erreurs moyennes associées à cette transformation sont inférieures à 2 cm pour la hauteur significative des vagues. Cependant, l'approche utilisée dans cette étude, comme dans la plupart des autres études à ce sujet, nécessite une donnée d'entrée semblable à une image, c'est-à-dire une donnée fournie sur un maillage régulier et rectangulaire. Ce prérequis s'avère être une contrainte majeure puisqu'une grande partie des prévisions et hindcasts de vagues travaillent aujourd'hui avec des maillages non structurés. Bien qu'un simple réseau de neurones entièrement connecté soit techniquement compatible avec la super-résolution appliquée à des maillages non structurés, nous avons décidé, après une analyse initiale de performance, de nous concentrer sur les réseaux de neurones en graphes. Ces derniers, bien que relativement récents, sont à la fois polyvalents et performants.

### 3.1 Réseaux de neurones en graphes et MeshGraphNets

Les réseaux de neurones en graphes ont connu un pic d'intérêt considérable ces dernières années, en raison de leur performance sur une grande variété de tâches et leur capacité à travailler avec des données non euclidiennes. L'une des structures les plus adaptées pour travailler avec des maillages de données issues d'équations numériques physiques est l'architecture Encodeur-Processus-Décodeur avec des blocs GraphNet. Cette architecture a été introduite pour la première fois par SANCHEZ-GONZALES *et al.*, (2020), puis étendue aux calculs basés sur des maillages avec MeshGraphNets par PFAFF *et al.*, (2021), avant d'être encore améliorée par FORTUNATO *et al.*, (2022) avec l'architecture MultiScale MeshGraphNet, qui permet de travailler avec différentes résolutions. Pour notre application, nous convertissons un maillage non structuré donné en un graphe non orienté  $G = (V, E)$ , défini par un ensemble de nœuds ou sommets  $V$ , ainsi qu'un ensemble d'arêtes  $E$  les reliant, en faisant correspondre les nœuds du maillage aux nœuds du graphe et en utilisant les côtés des cellules du maillage comme arêtes. Chaque nœud et chaque arête peut se voir attribuer une caractéristique associée, telle que la hauteur significative des vagues, la période des vagues, ou encore la distance entre deux nœuds. Comme dans FORTUNATO *et al.*, (2022), nous travaillons avec deux graphes distincts, un graphe de basse résolution  $G_l = (V_l, E_l)$  et un graphe de haute résolution  $G_h = (V_h, E_h)$ , qui sont obtenus à partir des maillages correspondants des modèles de vagues de basse et haute résolution. Dans le cadre de notre étude, les caractéristiques de nœuds des graphes de basse résolution sont la hauteur significative des vagues et la direction moyenne des vagues à l'emplacement du nœud. Pour éviter des incohérences numériques à 360°, la direction est transformée en deux vecteurs unitaires 2D. La caractéristique de nœuds des graphes de haute résolution est simplement la hauteur significative des vagues, qui est la variable que nous souhaitons prédire. Les caractéristiques des arêtes sont leurs coordonnées relatives et leur norme. Toutes les caractéristiques des nœuds, à la fois basse et haute résolution, sont standardisées sur les

données d'entraînement. Les caractéristiques des arêtes sont normalisées par la plus grande longueur d'arête.

La structure Encodeur-Processus-Décodeur est implémentée de la même manière que celle décrite par PFAFF *et al.*, (2021), avec des perceptrons multicouches à 2 couches cachées d'une taille latente de 128 et une fonction d'activation par Unité Linéaire Sigmoidale (SiLU). Notre approche diffère principalement par la méthode d'augmentation de résolution du graphe, puisque nous utilisons un algorithme relativement simple d'interpolation des  $k$  plus proches voisins, comme présenté dans QI *et al.*, (2017), pour une mise en œuvre plus rapide et plus simple. Dans tous nos calculs, nous utilisons  $k = 3$ , AdamW comme algorithme d'optimisation avec un taux d'apprentissage de  $5 \times 10^{-5}$ , un dégradé de 0.001, et  $\beta_1 = 0.9$ ,  $\beta_2 = 0.95$ . Le réseau est entraîné jusqu'à convergence avec arrêt prématuré, suivant un paramètre de patience de 30 et en utilisant l'erreur absolue moyenne comme fonction de perte. Enfin, après plusieurs tests, nous choisissons de définir le nombre de couches basse résolution à  $N_l = 15$  et de couches haute résolution à  $N_h = 5$ , cette configuration fournissant les meilleurs résultats dans notre cas.

## 4. Résultats

### 4.1 Distribution de la hauteur significative

Afin d'obtenir un premier aperçu de la performance du modèle MeshGraphNet, une première comparaison sous forme de nuage de points est présentée pour les trois régions d'étude en Figure 2. Les résultats du modèle SWAN haute résolution sont représentés en abscisse et les prédictions respectives des modèles de super-résolution sont représentées en ordonnée. Chaque point correspond à un nœud de la maille, à une date donnée. Le nombre total de points dans le nuage est donc de 7 millions de points. Pour faciliter la distinction des zones plus denses, le nombre de points par pixel est partitionné en intervalles et la densité de points est indiquée par la couleur. Comme outil supplémentaire pour l'interprétation, des histogrammes sur les deux axes montrent la distribution des données de hauteur de vagues. Dans les trois régions, les données à haute résolution sont remarquablement bien reproduites, avec des scores  $R^2$  très proches de 1. On observe une nette différence de performance entre les régions, le modèle de la région 1 présentant l'erreur la plus grande et celui de la région 3, l'erreur la plus faible. Dans tous les cas, la variance augmente avec la hauteur des vagues, ce qui est visible par la forme légèrement conique du nuage de points. Cependant, pour des hauteurs de vagues très élevées, cette variance se met à diminuer pour les régions 2 et 3. En revanche, dans le cas de la région 1, le MeshGraphNet surévalue très clairement la hauteur des vagues. Néanmoins, on peut noter que pour les trois régions, plus de 60% des données se situent dans une plage de hauteur de vagues de 0-1 m, dans laquelle les erreurs sont particulièrement faibles.

# Thème 1 – Hydrodynamique marine et côtière

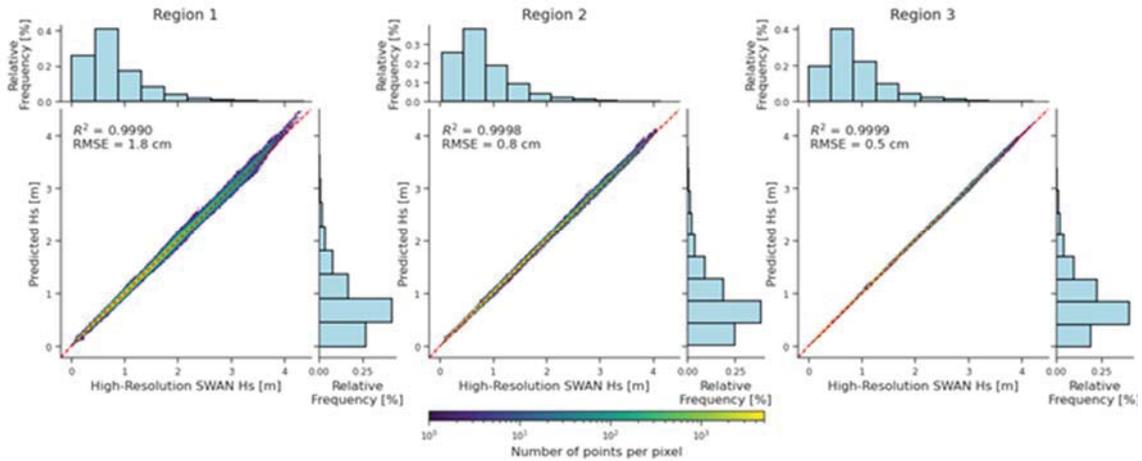


Figure 2. Nuage de points coloré par densité montrant la corrélation entre les prédictions des réseaux de neurones et les simulations haute résolution dans les trois régions (1, 2, 3 pour sud, milieu et nord respectivement).

Cette variabilité dans la performance des modèles d’une région à une autre est en partie attendue. En effet, dans la région 1 par exemple, le champ de vagues est fortement conditionné par la bathymétrie locale très hétérogène, ce qui implique une forte variabilité de la distribution spatiale des hauteurs de vagues à l’échelle locale, qui n’est capturée qu’en haute résolution. C’est ce manque d’information dans la donnée d’entrée basse résolution qui rend la conversion sur la région 1 plus complexe que pour la région 3.

## 4.2 Comparaison spatiale de l’erreur

Afin d’analyser l’erreur des modèles de manière spatiale, nous calculons maintenant, pour chaque nœud, l’erreur moyenne absolue sur l’année de test, et traçons les résultats sur le maillage.

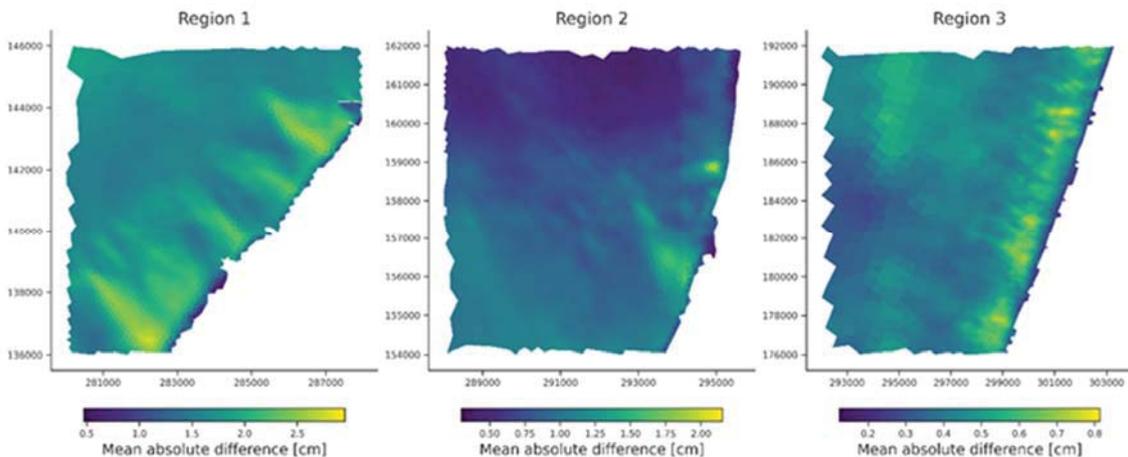


Figure 3. Cartes d’erreur pour les trois régions.

La Figure 3 présente ces cartes d'erreur pour chaque région. On observe que, quelle que soit la région, les erreurs dépendent fortement de la localisation des zones de concentration de l'énergie ou d'ombre engendrée par la réfraction locale des vagues. Dans certains cas, comme celui de la région 1, la carte d'erreur retrace clairement ces schémas de réfraction. La région 2 présente des erreurs plus localisées, avec deux zones d'erreur élevée, qui sont les zones de réfraction moyenne générées par le canyon sous-marin, tandis que le reste de la carte présente des erreurs relativement faibles. En revanche, les erreurs moyennes absolues pour la région 3 sont assez homogènes, bien que les nœuds près du rivage aient tendance à avoir une erreur légèrement plus élevée.

Les zones de réfraction des vagues distinctement visibles peuvent être partiellement expliquées par le fait qu'elles ne sont pas du tout, ou à peine, présentes dans la donnée d'entrée basse résolution, et sont donc plus sujettes aux erreurs à l'issue de la méthode de super-résolution. Néanmoins, il est important de souligner que les erreurs moyennes globales restent très faibles, allant de 0,8 cm à 3 cm. Dans la plupart des cas, ces erreurs peuvent être considérées négligeables dans le contexte habituel de la prévision de vagues.

#### 4.3 Dépendance aux conditions de vagues

La forme conique du nuage de points dans la Figure 2 suggère une certaine dépendance de l'erreur par rapport à la hauteur significative de vagues  $H_s$ . Tandis que  $H_s$  joue certainement un rôle dans la précision de la prédiction, il est également plausible que l'erreur soit influencée plus globalement par le climat de vagues. L'erreur pourrait donc dépendre d'autres variables telles que la période moyenne des vagues ou la direction. Afin d'analyser cette hypothèse, nous calculons la moyenne sur tous les nœuds des variables  $H_s$ ,  $T_{m10}$  (période énergétique) et  $Dir$  (direction moyenne) et les comparons sur un diagramme 3D. Les résultats obtenus pour la région 1 sont présentés en Figure 4, où l'erreur absolue moyenne est indiquée par la couleur.

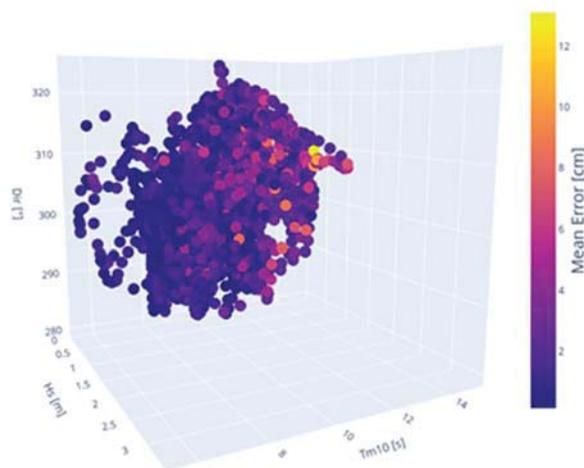


Figure 4. Nuage de points 3D de la hauteur significative, période énergétique et direction moyenne. La couleur indique l'erreur moyenne pour chaque point.

## Thème 1 – Hydrodynamique marine et côtière

Etant donné qu'une figure 3D statique ne permet pas de montrer l'ensemble des informations en raison de la projection 2D, nous fournissons les figures interactives sur le lien [github.com/janfer95/jngcgc2024](https://github.com/janfer95/jngcgc2024) (fichiers HTML).

Bien que la distribution des erreurs varie légèrement d'une région à une autre, la tendance la plus identifiable est la corrélation déjà observée entre la hauteur de vagues et l'erreur. Dans le cas de la direction des vagues, les tendances sont moins claires, même si les vagues venant du nord ont tendance à être moins bien prédites. La période énergétique des vagues présente ses plus larges erreurs dans une fenêtre relativement étroite de 9-11 s, qui correspond également à la période de vagues la plus observée dans notre zone d'étude. Dans le cas des régions 1 et 2, nous observons également une faible augmentation de l'erreur pour des périodes légèrement plus longues de 11-13 s. Dans l'ensemble, il est difficile d'affirmer si certaines conditions de vagues sont susceptibles d'introduire des erreurs particulièrement élevées car on n'observe aucune zone d'erreurs localisée. Néanmoins, les conditions moyennes de vagues avec des hauteurs significatives supérieures à 2-3 m, venant principalement des directions nord à 300-310° avec une période énergétique entre 9-11 s tendent à être plus complexes à reconstruire pour le réseau de neurones.

### 5. Discussion et conclusion

Cet article montre qu'une approche de super-résolution peut considérablement réduire le temps de calcul des modèles numériques spectraux sur un maillage non structuré tout en conservant un niveau de précision élevé. Certes, une approche de super-résolution ne pourra jamais être entièrement précise car il manque des informations essentielles dans la donnée d'entrée à basse résolution. Néanmoins, les résultats présentés dans cette étude suggèrent que les erreurs sont, pour la grande majorité, remarquablement faibles. Même dans le cas de la région 1, qui est une zone d'étude caractérisée par un champ de vagues très hétérogène, l'erreur absolue reste inférieure à 5 cm pour 95% des données. Dans des régions moins complexes, comme la région 3, cette erreur ne dépasse pas 1 cm.

En comparaison avec les erreurs habituellement obtenues avec des modèles numériques spectraux comme SWAN, cette erreur est négligeable. DELPEY *et al.*, (2021) ont généré un hindcast similaire sur la même région que celle utilisée dans notre étude, mais avec une résolution spatiale encore plus fine, allant jusqu'à 10 m. Les auteurs rapportent, lors de la validation de leur modèle, une erreur quadratique moyenne (RMSE) variant de 19 à 33 cm, ce qui est un résultat relativement précis en faible profondeur dans une région complexe comme la Côte Basque. En comparaison, les RMSE de notre approche de super-résolution varient d'environ 0,5 à 1,8 cm, ce qui représente seulement 1 à 10% d'incertitude additionnelle. Une présentation détaillée des temps de calcul dépasse le périmètre de cette communication, mais l'approche de super-résolution permet un calcul 30 à 70 fois plus rapide, selon la région. De manière générale, il existe de nombreux cas d'ingénierie côtière où avoir une prévision de vagues faussée de 20 cm au lieu de 22 cm

n'est pas déterminant ; surtout si cette dernière est calculée beaucoup plus rapidement et peut donc libérer des ressources pour d'autres calculs.

Bien que la super-résolution soit une technique de computer vision déjà bien établie et qu'elle reçoive récemment beaucoup d'attention en mécanique des fluides, son application aux modèles numériques de vagues en zone côtière reste limitée pour le moment. Cela souligne la nécessité de poursuivre la recherche sur la super-résolution pour ce domaine d'application, que ce soit sur un maillage structuré ou non structuré. Un potentiel axe de recherche consisterait à inclure des équations physiques ou des mesures de vagues dans la démarche, afin d'obtenir des résultats encore plus précis que ceux fournis par les modèles numériques spectraux, comme déjà réalisé dans le domaine de la mécanique des fluides pour les simulations d'écoulement de sillage (FORTUNATO *et al.*, 2022).

Les modèles statistiques gagnent de plus en plus en attractivité dans le domaine des sciences naturelles, et bien qu'ils ne soient pas voués à remplacer les modèles numériques, ils constituent certainement un outil complémentaire utile dans le calcul scientifique. Nous sommes convaincus que les approches de super-résolution peuvent apporter une importante contribution aux prévisions des vagues locale en zone côtière, offrant un équilibre entre les calculs numériques complets, précis mais plus lents, et les modèles de substitution, plus rapides mais sujets à des erreurs additionnelles.

### Remerciements

Cette recherche a été réalisée dans le cadre de la chaire HPC-Waves d'E2S-UPPA avec le soutien financier d'E2S-UPPA, de la Communauté d'Agglomération Pays basque (CAPB), et de la Communauté Région Nouvelle Aquitaine (CRNA).

### 6. Références bibliographiques

- BOOIJ N., RIS R.C., HOLTHUIJSEN L.H. (1999). *A third-generation wave model for coastal regions: 1. Model description and validation*. Journal of Geophysical Research: Oceans, Vol. 104, pp 7649-7666. <https://doi.org/10.1029/98JC02622>
- CAMUS P., MENDEZ F.J., MEDINA R. (2011). *A hybrid efficient method to downscale wave climate to coastal areas*. Coastal Engineering Vol. 58, pp 851–862. <https://doi:10.1016/j.coastaleng.2011.05.007>
- DELPEY M., LASTIRI X., ABADIE S., ROEBER V., MARON P., LIRIA P., MADER J. (2021). *Characterization of the Wave Resource Variability in the French Basque Coastal Area Based on a High-Resolution Hindcast*. Renewable Energy, Vol. 178, pp 79–95. <https://doi.org/10.1016/j.renene.2021.05.167>
- FORTUNATO M., PFAFF T., WIRNSBERGER P., PRITZEL A., BATTAGLIA P. (2022). *MultiScale MeshGraphNets*. arXiv. <https://doi.org/10.48550/arXiv.2210.00612>
- GOPINATH D. I., DWARAKISH G. S. (2015). *Wave prediction using neural networks at New Mangalore Port along West Coast of India*. Aquatic Procedia, Vol. 4, pp 143–150. <https://doi.org/10.1016/j.aqpro.2015.02.020>

## *Thème 1 – Hydrodynamique marine et côtière*

- JAMES S. C., ZHANG Y., O'DONNCHA F. (2018). *A machine learning framework to forecast wave conditions*. Coastal Engineering, Vol. 137, pp 1–10. <https://doi.org/10.1016/j.coastaleng.2018.03.004>
- KUEHN J., ABADIE S., LIQUET B., ROEBER V. (2023). *A deep learning super-resolution model to speed up computations of coastal sea states*. Applied Ocean Research, Vol. 141, 103776. <https://doi.org/10.1016/j.apor.2023.103776>
- LASTIRI X., ABADIE S., MARON P., DELPEY M., LIRIA P., MADER J., ROEBER V. (2020). *Wave energy assessment in the south Aquitaine nearshore zone from a 44-year hindcast*. Journal of Marine Science and Engineering, Vol. 8, 199. <https://doi.org/10.3390/jmse8030199>
- PFAFF T., FORTUNATO M., SANCHEZ-GONZALES A., BATTAGLIA P. W. (2021). *Learning mesh-based simulation with graph networks*. 9th International Conference on Learning Representations, <https://doi.org/10.48550/arXiv.2010.03409>
- SANCHEZ-GONZALES A., GODWIN J., PFAFF T., YING R., LESKOVEC J., BATTAGLIA P. W. (2020). *Learning to simulate complex physics with graph networks*. Proceedings of the 37th International Conference on Machine Learning,
- SHI N., XU J., WURSTER S. W., GUO H., WOODRING J., VAN ROEKEL L. P., SHEN H.-W. (2022). *GNN-Surrogate: A hierarchical and adaptive graph neural network for parameter space exploration of unstructured-mesh ocean Simulations*. <https://doi.org/10.48550/arXiv.2202.08956>
- QI C. R., YI L., SU H., GUIBAS L. J. (2017). *PointNet++: Deep hierarchical feature learning on point sets in a metric space*, 31<sup>st</sup> Conference on Neural Information Processing Systems (NIPS 2017), <https://doi.org/10.48550/arXiv.1706.02413>
- ZHU X., WU K., HUANG W. (2023). *Deep learning approach for downscaling of significant wave height data from wave models*. Ocean Modelling, Vol. 185, 102257. <https://doi.org/10.1016/j.ocemod.2023.102257>