

# Prévisions météo-océaniques et enjeux de dérisquage pour les projets éoliens en mer

Robin Marcille, PhD,  
France Energies Marines, Lab-STICC, IMT Atlantique, UMR CNRS 6285

Maxime Thiébaud, Jean-François Filipot – France Energies Marines

Pierre Tandeo, Ronan Fablet – Lab-STICC, IMT Atlantique, UMR CNRS 6285

Pierre Pinson – Imperial College London, Dyson School of Design Engineering




# Outline

1. Introduction
  - Développement de l'éolien en mer en France
  - Défis de la prévision météorologique pour l'éolien en mer
2. Placement optimal de capteurs pour reconstruction de la ressource en vent
3. Prévision court-terme pour les opérations de maintenance

# Introduction

---

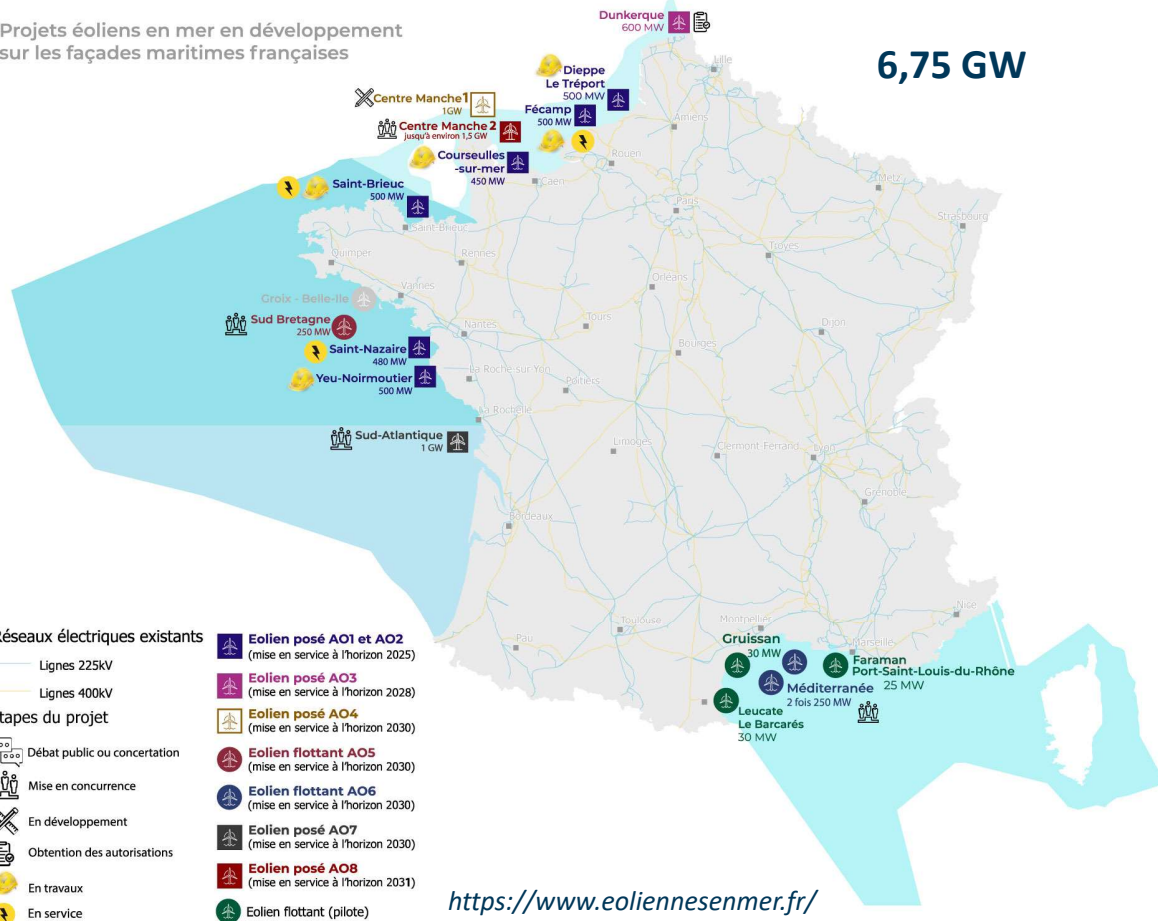


# Contexte

## Feuille de route éolien en mer



Projets éoliens en mer en développement sur les façades maritimes françaises



Objectifs en GW	Objectifs à horizon 10 ans de nouvelles capacités à attribuer (dont extensions (déjà identifiées))	Objectifs à 2050 (comprenant tous les parcs déjà attribués, en cours d'attribution et extensions identifiées)
MEMN – Manche Mer du Nord	Entre 7 et 11	Entre 12 et 15,5
NAMO – Nord Atlantique-Manche Ouest	Entre 6 et 9,5 (dont 0,5GW)	Entre 17 et 25
SA – Sud Atlantique	Entre 2,5 et 5,5 (dont 1GW)	Entre 7 et 11
MED – Méditerranée	Entre 3 et 4,5 (dont 2X0.5GW)	Entre 4 et 7,5

18 – 30 GW

40 – 60 GW

- Efforts majeurs de planification maritime
- Enjeux de dérisquage pour les projets éoliens

# Éolien marin et prévisions météo-océaniques

## ➤ Production d'énergie

- Estimation du productible
- Participation au marché de l'électricité
- Optimisation de la production

## ➤ Opérations en mer (accessibilité)


- Estimation des Operational Expenditures (OPEX)
- Optimisation des opérations
- Sécurité des opérations

## ➤ Design des structures (charges sur la structure)

- Dimensionnement en fatigue des composants
- Maintenance prédictive – jumeaux numériques
- Contrôle actif

## ➤ Impacts prédictifs sur l'environnement

- Passages migratoires avifaune

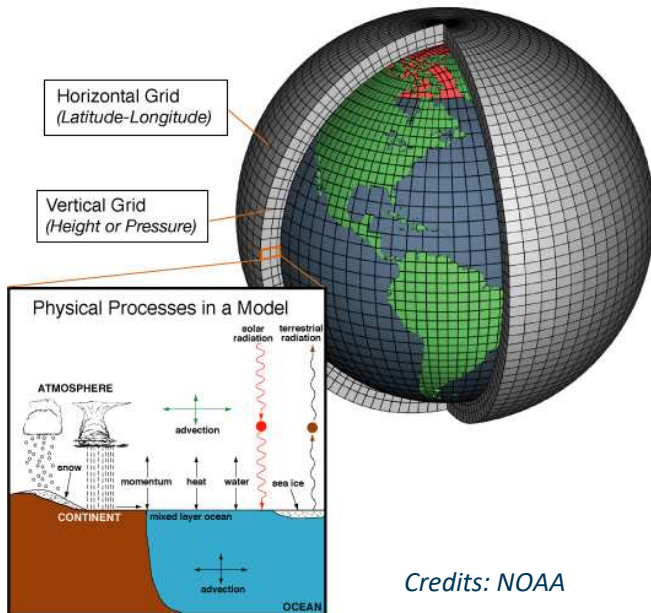


(Dykes et al. (2010))


# Prévisions météorologiques en mer

## Prévision en mer:

- ▲ Couplage entre modèles océaniques et modèles atmosphériques
- ▲ Paramétrisation du couplage vent/vagues
- ▲ Difficultés liées à l'acquisition de données



Credits: NOAA

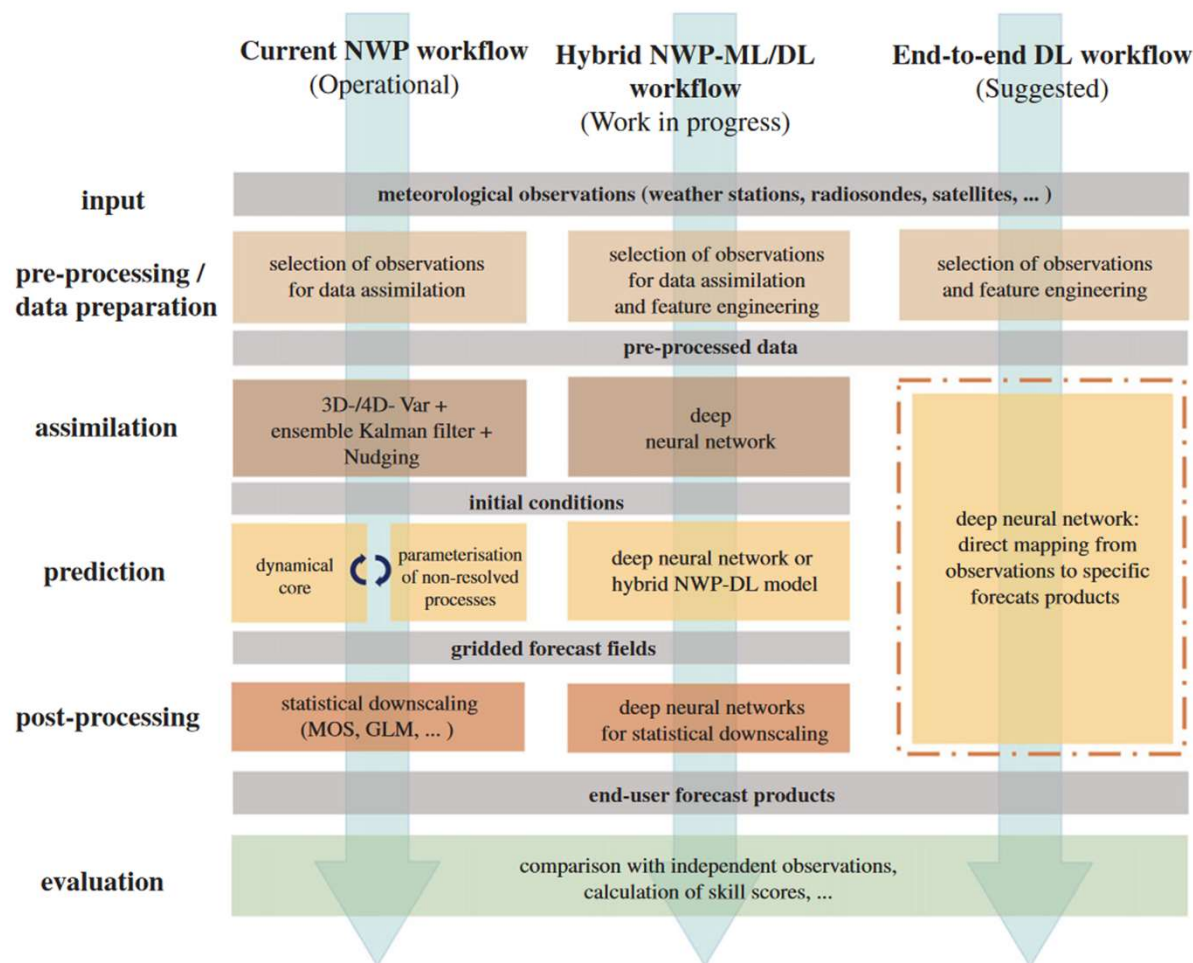


(Bauer et al. (2015))

# Deep Learning et prévisions météorologiques

- ✓ Reduction du temps de calcul en opérationnel
- ✓ Optimisation pour chaque application
- ✓ Lien direct entre les données d'entrées et les prévisions

- ⚠ Peu interprétable
- ⚠ Pas forcément généralisable
- ⚠ Dépendant des données
- ⚠ Evènements extrêmes




(Schultz et al. (2021))

# Placement optimal de capteurs pour le dérisquage des projets éoliens en mer

---

*Marcille, R., Thiébaud, M., Tandeo, P., and Filipot, J.-F.: Gaussian mixture models for the optimal sparse sampling of offshore wind resource, Wind Energ. Sci., 8, 771–786, 2023.*





# Contexte

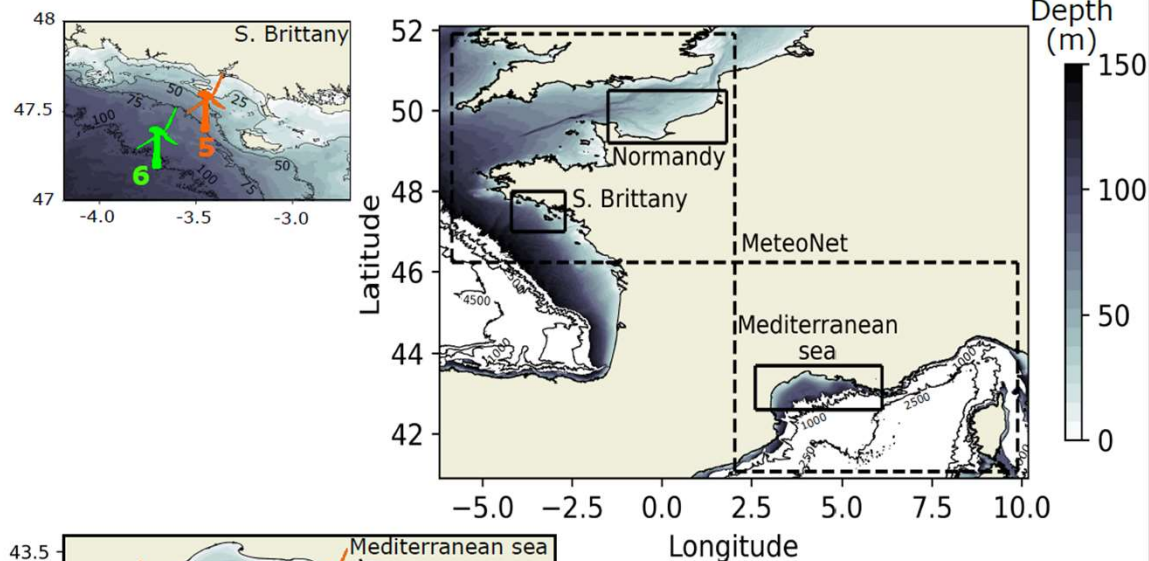

Sur une zone d'intérêt:

- Combien de points de mesures sont nécessaires pour caractériser la ressource en vent ?
- Où installer ces capteurs ?

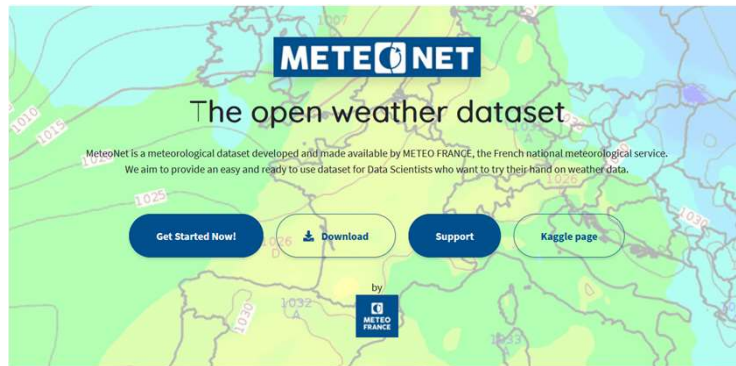
**Problème d'échantillonnage**

Étude menée sur les futures zones d'appel d'offres pour l'éolien en mer

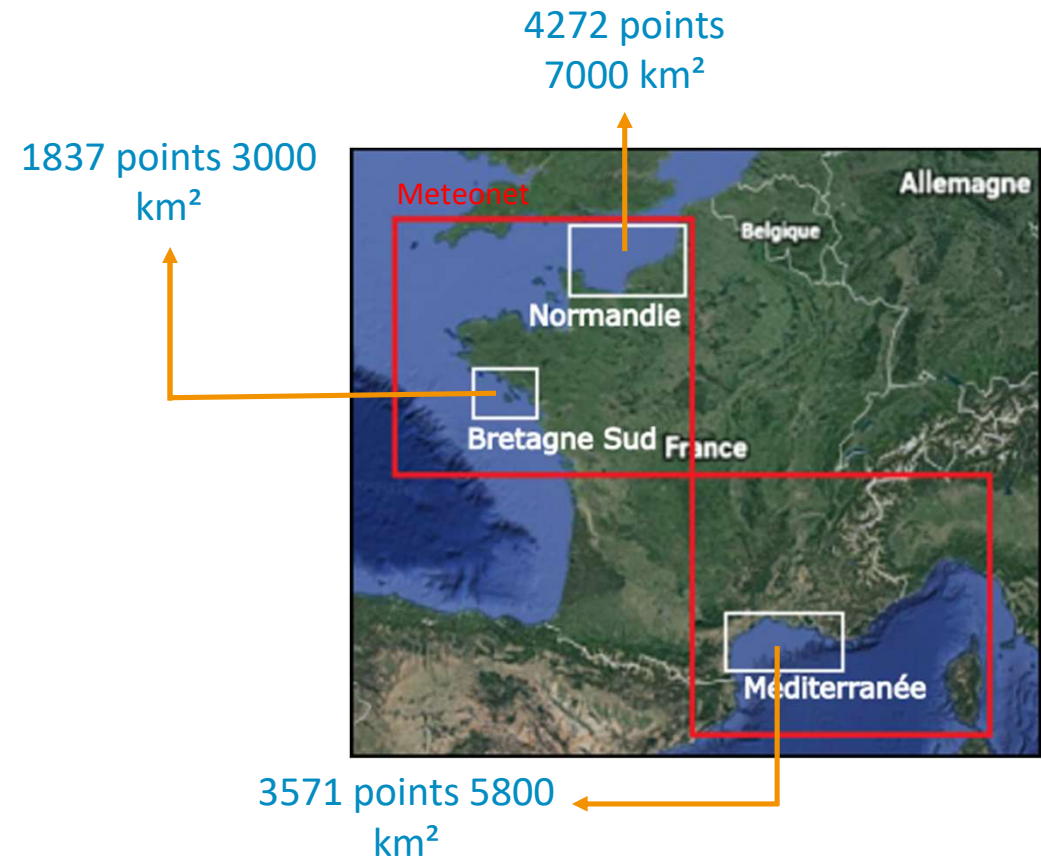
- Normandie
- Bretagne Sud
- Golfe du Lion



(Larvor et al. (2020))



- Prévisions du modèle haute résolution AROME
- Vent horaire zonal (O-E) et méridional (S-N) à 10m
- 3 ans de données (2016-2018)
- Grille régulière 1,3km



## Formulation du problème

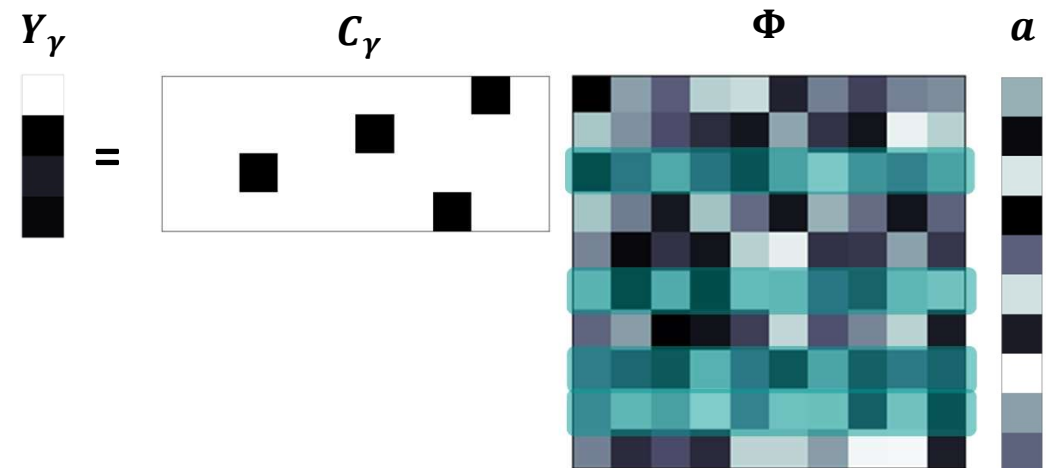
Pour un nombre  $D$  de capteurs, quelles sont les  $D$  positions  $\gamma$  qui permettent de reconstruire au mieux l'état du système ?

→ Système décomposé en composantes principales (PC)  $X(t) = \sum_{k=1}^K a_k(t) \phi_k$

→ Etat mesuré obtenu avec une matrice d'échantillonnage  $Y_\gamma(t) = C_\gamma X(t)$

→ Reconstruction à partir de mesures  $\hat{X}_\gamma = \Phi \hat{a} = \Phi \hat{\beta} Y_\gamma$

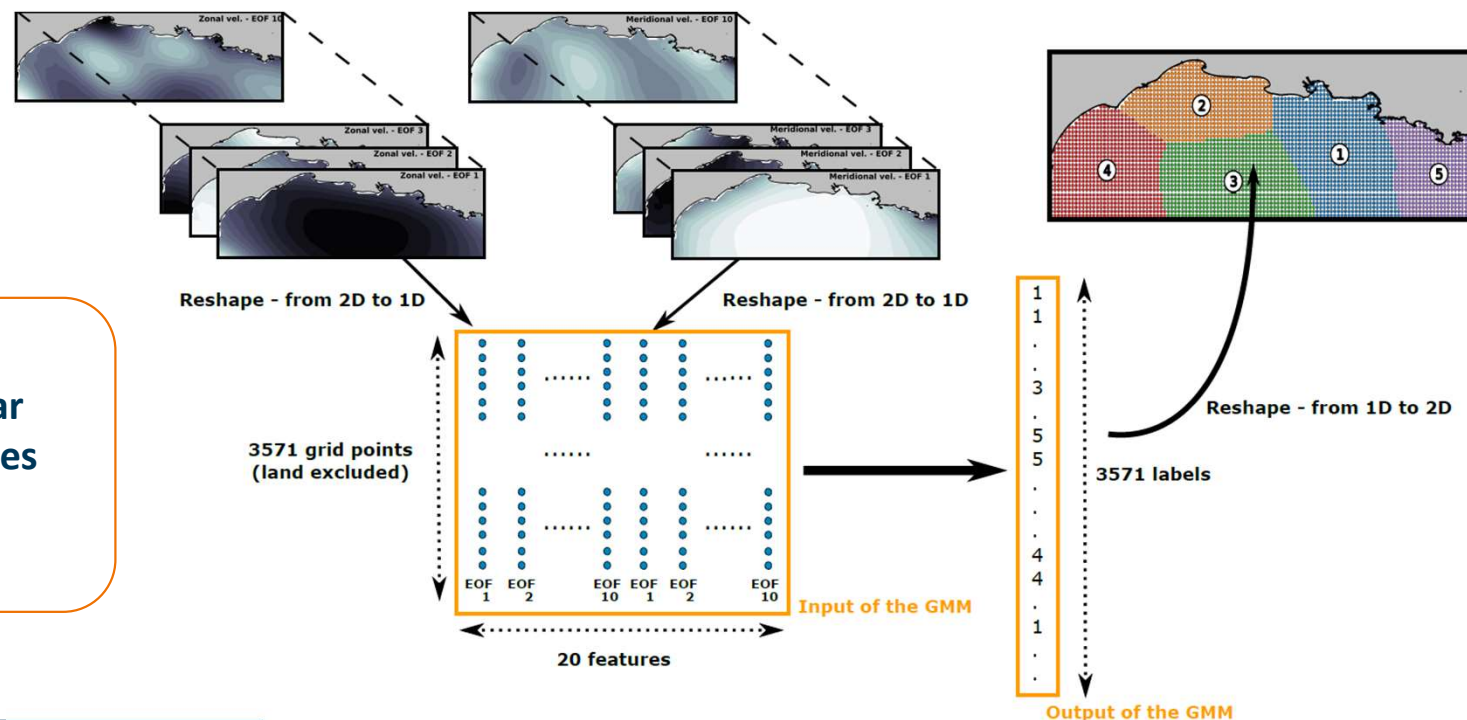
On cherche la combinaison  $D, \gamma$  qui minimise l'erreur de reconstruction



# Méthode proposée

- Les bons candidats sont les points de grille qui “portent” le plus d’information
  - Extrema des PC (*Yildirim et al. (2009)*)
  - Pivots pour la factorisation QR de la matrice (*Manohar et al. (2018)*)
  - **Centroïdes de clusters**

Obtention de points ‘saillants’ par clustering non-supervisé des PC des prévisions météorologiques



# Clustering non-supervisé – Gaussian Mixture Model

Modèle = superposition de Gaussiennes multivariées (Gaussian Mixture Model, *Reynolds (2009)*)


$$p(x) = \sum_{j=1}^D \pi_j N(x|\mu_j, \Sigma_j)$$


Convergence du modèle par Expectation-Maximisation (EM) (*Wu (1983)*)

Définition du nombre optimal de capteurs → BIC score

$$BIC = -2 \log \mathcal{L} + G \log K$$

↙ ↘  
Vraisemblance      Complexité






Area	Method	Max wind speed RMSE [ $\text{m s}^{-1}$ ]	Mean wind speed RMSE [ $\text{m s}^{-1}$ ]	RMSE [ $\text{m s}^{-1}$ ]
Mediterranean Sea	GMM	<b>0.94</b>	<b>0.17</b>	<b>0.9</b>
	QR pivoting	1.42	0.42	1.77
	EOF extrema	1.28	0.2	1.37
	Monte Carlo	1.28	0.35	1.41
Normandy	GMM	2.0	<b>0.1</b>	<b>0.85</b>
	QR pivoting	1.84	0.56	1.83
	EOF extrema	<b>0.89</b>	0.42	1.44
	Monte Carlo	1.4	0.23	1.08
Southern Brittany	GMM	1.32	<b>0.09</b>	<b>0.7</b>
	QR pivoting	2.04	0.29	1.33
	EOF extrema	<b>0.89</b>	0.16	0.96
	Monte Carlo	1.87	0.17	0.93

- Méthode simple et robuste pour l'échantillonnage de données météo-océaniques
- Intégration d'autres contraintes physiques (vagues, courant) / économique (distance à la côte, profondeur) ?

# Prévision court-terme pour les opérations de maintenance

---

*R. Marcille, M. Thiébaud, P. Tandeo, R. Fablet, P. Pinson  
2023 - Submitted @ Artificial Intelligence for Earth Systems*



# Projet FLOWTOM

## Floating Offshore Wind Turbines Operations and Maintenance (FLOWTOM)

- Eaux profondes
- Levages lourds flottant à flottant
- Operations dépendantes des conditions météo-océaniques





Image: Equinor

*Credits: Equinor*

- Accompagner le développement de solutions de levage lourd pour l'éolien flottant
- Développer un modèle de prévision basé données sur le Golfe du Lion pour l'optimisation des opérations de maintenance




# Prévision météo et opérations de maintenance



(Guintautas and Sorensen (2017))

LRFD Alpha Factors (ref: DNVGL-ST-N001) – With Environmental Monitoring				
Planned Operation period (hours)	Operational limiting significant wave height			
	$H_s=1$	$H_s=2$	$H_s=4$	$H_s \leq 6$
$\leq 12$	0.78	0.91	0.95	0.96
$\leq 24$	0.72	0.84	0.87	0.90
$\leq 36$	0.68	0.78	0.80	0.84

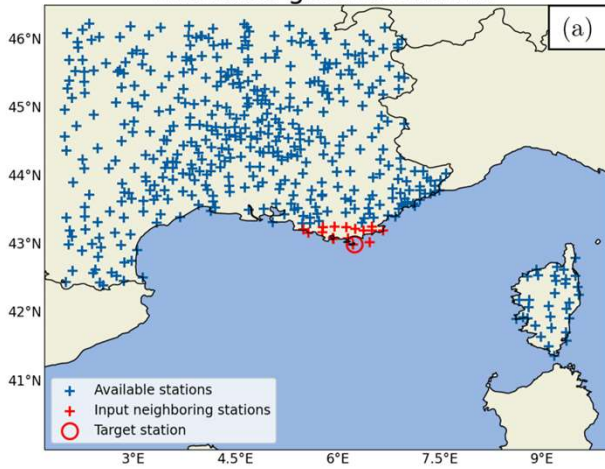
(DNV (2011))





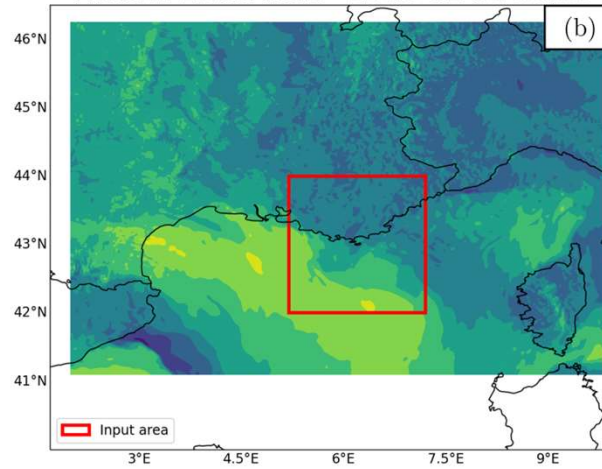
- Prise en compte empirique des incertitudes → conservatisme
- Impact des prévisions météorologiques dans la prise de décision ?
- Réponses des structures aux états de mer ?

# Jeu de données - MétéoNet

Available ground stations



AROME zonal wind - 2018-01-01 00:00



## Baseline déterministe

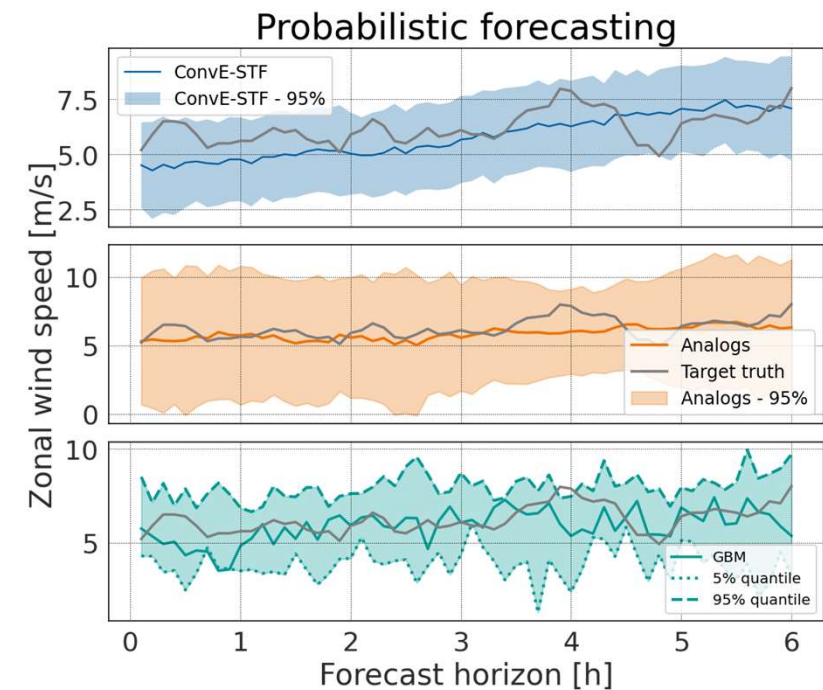
- Sortie AROME débiaisée au point de grille le plus proche – **AROME**

## Baselines probabilistes (Jeu de données réduit)

- Analogues – **Analogs** (*Lguensat et al. (2017)*)
- Gradient Boosting Machine (*Gilbert et al. (2020)*) – **GBM**
- ConvE-STF sur jeu de données réduit – **ConvE-STF - reduced**

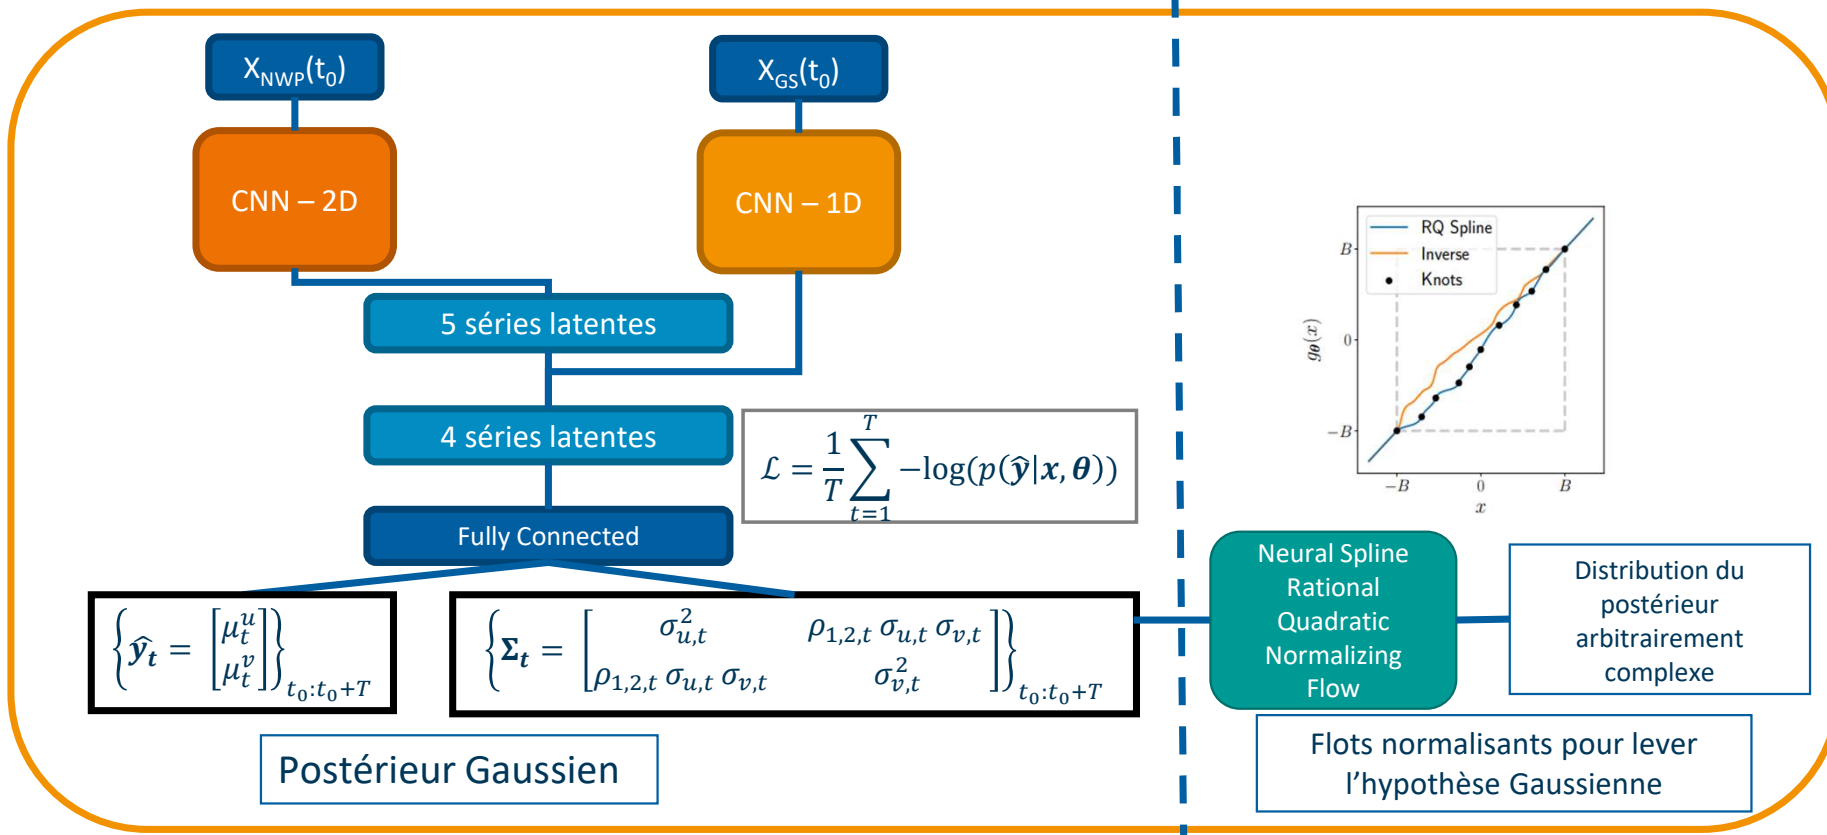
## Modèle proposé

- ConvE-STF sur jeu de données complet – **ConvE-STF**
- ConvE-STF avec flots normalisants – **ConvE-STF - NF**

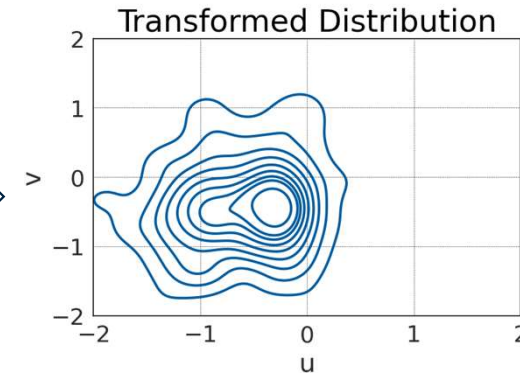

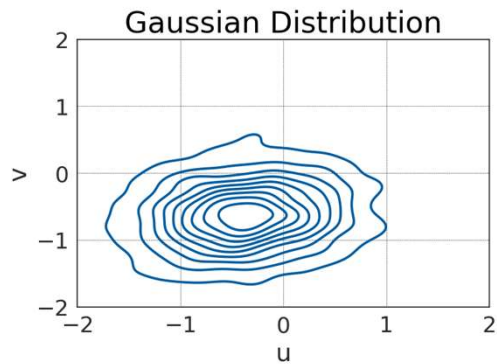


## ConvE-STF

## NF (*Dinh et al. (2017); Durkan et al. (2019)*)



# Flots normalisants



Transforme une distribution paramétrique en une distribution arbitrairement complexe grâce à une composition de transformation inversibles.

$$\log(p(X)) = \log(p_{Z_0}(Z_0)) - \sum_{i=1}^K \log \left| \det \frac{\partial T_i}{\partial Z_i} \right|$$

Changement de variable

- Echantillonnage facile
- Transfert explicite de la vraisemblance → entraînement end-to-end en vraisemblance
- Estimation de la densité du postérieur





# Evaluation prévision probabiliste

“The goal of probabilistic forecast is to maximize the sharpness of the predictive distributions subject to calibration” (Gneiting and Raftery (2007))

- Continuous Ranked Probabilistic Score (Messner et al. (2020)):

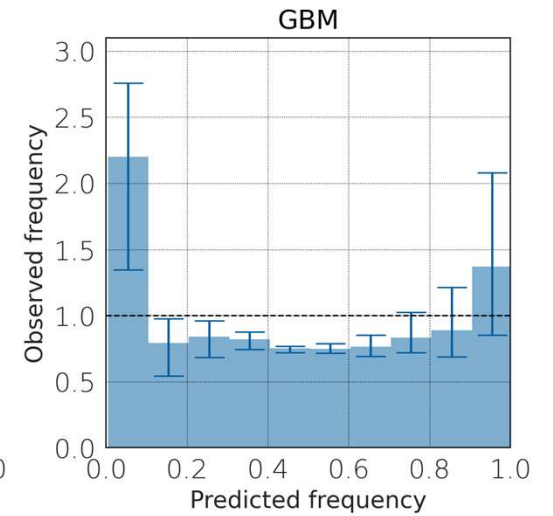
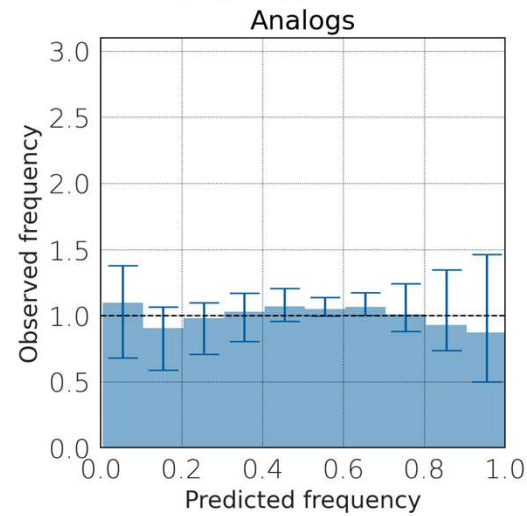
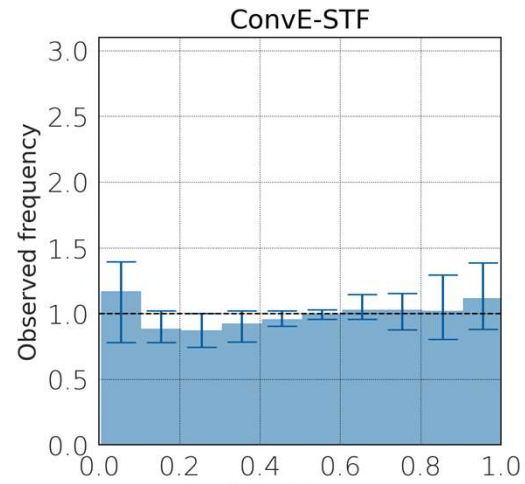
$$CRPS = \frac{1}{N} \sum_{t=1}^N \int_{-\infty}^{+\infty} \left( \hat{F}_t(x) - \mathbf{1}(x \geq y_t) \right)^2 dx$$


- Multivariate Rank Histogram (Gneiting and Raftery (2007))



# Résultats


Model	RMSE [ $m.s^{-1}$ ]	CRPS [ $m.s^{-1}$ ] (MAE [ $m.s^{-1}$ ])
AROME	$2.18 \pm 0.04$	$(1.97 \pm 0.05)$
Analogs	$1.83 \pm 0.09$	$1.18 \pm 0.05$
GBM	$1.63 \pm 0.04$	$1.07 \pm 0.03$
ConvE-STF - reduced	$1.67 \pm 0.04$	$1.08 \pm 0.02$
ConvE-STF	$1.33 \pm 0.05$	$0.87 \pm 0.03$
ConvE-STF - NF	<b><math>1.32 \pm 0.08</math></b>	<b><math>0.86 \pm 0.05</math></b>





- Flots normalisants: hypothèse Gaussienne relâchée pour un coût de calcul relativement faible
- Discrétisation de la cible capturée. Peu d'impact sur les scores.





- Amélioration de la prévision pour les vents soufflant de la côte → impact des stations de mesure côtières
- Problèmes de généralisation aux situations de vent rares (SO et NE)

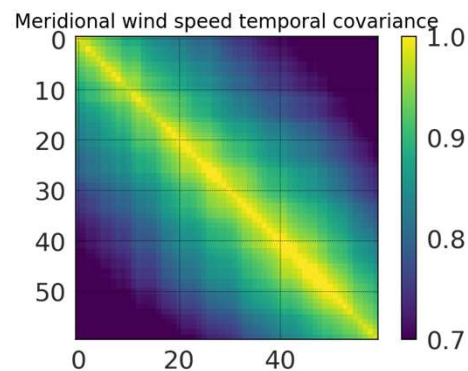
# Prévision de fenêtres météorologiques

D'une distribution postérieure par pas de temps à un ensemble de trajectoires pour le calcul de fenêtres météorologiques

→ Copules Gaussiens (*Pinson et al. (2007)*)

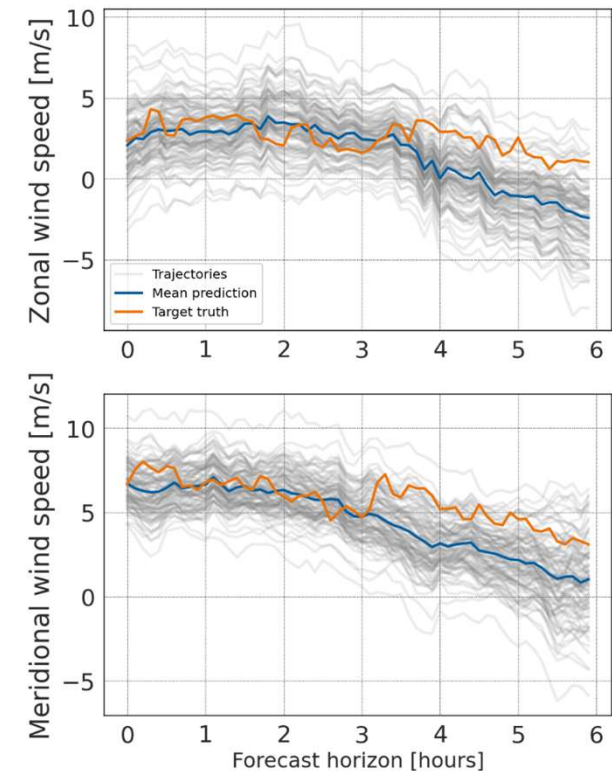
$$X = (X_0, \dots, X_T) \sim N(\mu_0, \Sigma_{temporal})$$

$$X_0, \dots, X_T \sim N(0, I_2)$$



$$Y_i = A_i X_i + \mu_i \sim N(\mu_i, \Sigma_i)$$
$$\Sigma_i = A_i A_i^T$$

Changement de variables



→ Calcul d'une probabilité de fenêtre météorologique


## Conclusions et futurs travaux

- Deep Learning pour prévision court-terme en mer
    - Coût de calcul opérationnel faible → prévision en direct
    - Données hétérogènes haute dimension en entrée
    - Entraînement end-to-end probabiliste
  - Post-processing efficace des prévisions numériques
  - Estimation de l'incertitude compétitive avec l'état de l'art
- 24h de prévision sur un site marin plus représentatif (île du Planier)
- Prévision jointe vent + vagues
- Valeur de la prévision pour la prise de décision probabiliste
- Prévision instantanée d'évènements extrêmes (bascule de vent / rampe de vent)



# Conclusions

---



## Conclusions et perspectives

---

- Beaucoup d'applications de data science pour la prévision météorologique en mer
  - Enjeux majeurs pour l'éolien en mer
  - Développement d'une méthode d'échantillonnage de la ressource en mer
  - Post-processing probabiliste des prévisions de vent et de vagues en mer avec perspectives encourageantes pour l'exécution des opérations de maintenance
- Thématique en développement chez France Energies Marines
- Turbulence en mer
  - Profils de vent
  - Production d'énergie
  - ... ?
- Enjeux de recherche important à fort impact industriel

- *K. Dykes and R. Meadows. 2010, Applications of Systems Engineering to the Research, Design, and Development of Wind Energy Systems – NREL Technical Report NREL/TP-5000-52616.*
- *Bauer et al. The quiet revolution of Numerical Weather Prediction – 2015*
- *MG. Schultz, C. Betancourt, B. Gong, F. Kleinert, M. Langguth, L.H. Leufen, A. Mozaffari, S. Stadler. 2021, Can deep learning beat numerical weather prediction? Phil. Trans. R. Soc. A 379: 20200097.*
- *G. Larvor, L. Berthomier, V. Chabot, B. Le Pape, B. Pradel, L. Perez. 2020, MeteoNet, an open reference weather dataset by METEO France - 2020*
- *Yildirim, B., Chrysostomidis, C., and Karniadakis, G. E.: Efficient sensor placement for ocean measurements using low-dimensional concepts, Ocean Model., 27, 160–173, 2009.*
- *Manohar, K., Brunton, B. W., Kutz, J. N., and Brunton, S. L.: Data-Driven Sparse Sensor Placement for Reconstruction: Demonstrating the Benefits of Exploiting Known Patterns, IEEE Contr. Syst. Mag., 38, 63–86, 2018*
- *Wu, C. F. J.: On the Convergence Properties of the EM Algorithm, Ann. Stat., 11, 95–103,1983.*
- *Reynolds, D. A.: Gaussian mixture models, Encyclopedia of biometrics, 741, 659–663, 2009.*
- *Stehly, Tyler, Philipp Beiter and Patrick Duffy. 2020. 2019 Cost of Wind Energy Review. Golden, CO: National Renewable Energy Laboratory. NREL/TP-5000-78471.*
- *Gintautas, T., and J. D. Sørensen, 2017: Improved Methodology of Weather Window Prediction for Offshore Operations Based on Probabilities of Operation Failure. Journal of Marine Science and Engineering, 5 (2), 20.*

- DNV, 2011: *DNV-OS-H101: Marine Operations, General*. 55.
- Lguensat, R., Tandeo, P., Aillot, P., Pulido, M., Fablet, R., 2017, *The Analog Data Assimilation*
- C. Gilbert, J. Browell and D. McMillan, *Probabilistic access forecasting for improved offshore operations. International Journal of Forecasting (2020)*.
- Dinh, L., J. Sohl-Dickstein, and S. Bengio, 2017: *Density estimation using Real NVP. arXiv*
- Durkan, C., A. Bekasov, I. Murray, and G. Papamakarios, 2019: *Neural Spline Flows. Advances in Neural Information Processing Systems, Curran Associates, Inc., Vol. 32*
- Gneiting, T., and A. E. Raftery, 2007: *Strictly Proper Scoring Rules, Prediction, and Estimation. Journal of the American Statistical Association, 102 (477), 359–378*.
- Messner, J. W., P. Pinson, J. Browell, M. B. Bjerregård, and I. Schicker, 2020: *Evaluation of wind power forecasts—An up-to-date view. Wind Energy, 23 (6), 1461–1481*
- Pinson, P., Papaefthymiou, G., Klockl, B., Nielsen, H. A., & Madsen, H. (2009). *From probabilistic forecasts to statistical scenarios of short-term wind power production. Wind Energy, 12(1), 51-62*

# Questions ?

