

Analyse des mesures atmosphériques et production de statistiques

Lot 6b - AO6 Méditerranée Zone 1



Version A du 05/05/2025

Client Direction Générale de l'Énergie et du Climat du Ministère de la Transition Énergétique		
Chargé d'affaires Météo-France D2C Toulouse	 christophe.jacolin@meteo.fr	
Chef de projet Météo-France DSM/CS/DC	 Raphael.Legrand@meteo.fr	

- page laissée intentionnellement vide -

Documents de référence antérieurs

	Intitulé	Référence	Date	Version
DR1	Projet de parc éolien off-shore au large de la Méditerranée	AO6_Mediterranée_Zone1_Lot4_Rapport-annuel_V1.odt	07/12/2022	1

Évolutions successives

Référence	Date	Version	Évolution
DGEC_AO6_Méditerranée_Zone1_Lot5_Rapport_V1_20230309	09/03/23	V1	Création
DGEC_AO6_Méditerranée_Zone1_Lot5_Rapport_V2_20230523	15/05/23	V2	Modification suite à la relecture Cerema
DGEC_AO6_Méditerranée_Zone1_Lot6b_Rapport_V1_20241126	26/11/24	V1	Version mise à jour suite au prolongement de la campagne de mesure (lot 6)
AO6_Zone1_Lot6b_Rapport_B1.odt	27/02/25	B1	Intégration des remarques formulées par le Cerema sur un rapport précédent
AO6_Zone1_Lot6b_Rapport_B2.pdf	02/04/25	B2	Correction fautes mineures aux chapitres 7 et 8 Intégration des corrections demandées par relecture Cerema
AO6_Zone1_Lot6b_Rapport_A.pdf	05/05/25	A	Version validée

RÉSUMÉ

L'objectif de ce lot 6b est d'**analyser les mesures atmosphériques** effectuées dans le cadre du lot 4 et du lot 6a, notamment la force et la direction du vent, d'en **produire des statistiques** associées et d'**étendre les séries d'observations horaires** dans le cadre d'une problématique d'éolienne off-shore.

Ce rapport concerne l'étude d'une campagne de mesure réalisée du 10/06/2021 00H TU au 09/07/2022 23H TU et prolongée du 10/07/2022 00H TU au 09/08/2024 23H TU pour le **LiDAR situé dans** la macrozone de la zone 1 de l'AO6 Méditerranée.

L'**extension de série est réalisée sur l'observation horaire du vent à 100 m**, une hauteur qui revêt un caractère important pour la production éolienne. La **période reconstituée est d'environ 21,5 ans** en utilisant les données horaires du **modèle météorologique AROME** (à la résolution horizontale de 2,5 km) sur la période 01/2000-06/2021, permettant de disposer d'un jeu de données dense sur la zone étudiée.

Une étude préliminaire complète réalisée sur deux sites de test est présentée en annexe. Elle détaille les différentes étapes ainsi que la méthodologie adoptée pour le choix du modèle statistique d'extension des séries horaires. Dans cette étude préliminaire, plusieurs modèles statistiques (notamment arbre binaire de décision, modèle linéaire général, modèle linéaire avec anamorphose, forêt aléatoire et réseau de neurones) ont été testés afin de **choisir le modèle capable de restituer au mieux les caractéristiques du vent horaire observé**.

Les scores de qualité suivants sont utilisés pour la recherche du meilleur modèle : le biais, l'écart-type (ECT), l'erreur absolue moyenne (MAE), l'erreur quadratique moyenne (RMSE) et les scores Peirce Skill Score (PSS). En plus de ces scores, la courbe de fiabilité (QQ-Plot), le critère BIC (pour les modèles linéaires), la restitution des cycles diurne et annuel du vent, ainsi que des roses de vent sont utilisées comme indicateurs de qualité.

Après analyse des différents indicateurs, **le modèle de forêt aléatoire s'est révélé comme le meilleur des modèles statistiques**. L'extension des séries horaires dans le cadre des études du lot 5 et 6b sera donc réalisée avec ce dernier.

Pour la zone 1 de l'AO6 Méditerranée, les résultats de l'extension statistique ont été comparés aux données brutes du modèle AROME sur la période d'observation. Selon les indicateurs mentionnés plus haut, calculés pour la force du vent, la direction du vent et la puissance produite par une éolienne, **nous privilégions l'utilisation d'un modèle différent selon des plages spécifiques pour la force du vent**. En effet, il a été vérifié que l'extension statistique est de meilleure qualité pour les forces du vent comprises entre 4 et 20 m/s ; et le modèle AROME est meilleur pour les forces du vent inférieures à 4 m/s et supérieures ou égales à 20 m/s. Pour la direction du vent, c'est l'extension statistique qui s'est révélée de meilleure qualité. Les séries intégrales (force et direction) des deux modèles (extension statistique et AROME) seront mises à disposition des porteurs de projets.

Table des matières

1 Contexte de l'étude	16
1.1 Livrables	16
2 Méthodologie d'extension de la série temporelle d'observations horaires	17
2.1 Méthodologie	17
2.2 Phase exploratoire des données d'entrée	19
2.2.1 Identification du point AROME de référence	19
2.2.2 Traitement des données douteuses	20
2.2.3 Identification des variables explicatives	21
2.3 Modélisation statistique par forêt aléatoire	22
2.3.1 Description du modèle de forêt aléatoire	23
2.3.2 Les étapes de l'apprentissage	23
2.3.3 Choix des échantillons d'apprentissage et de test	24
2.3.4 Estimation de l'erreur des modèles statistiques sur ces échantillons	24
2.4 Qualification de l'extension par forêt aléatoire	26
3 Principaux résultats sur la modélisation de FF et DD à 100 m	28
3.1 Phase exploratoire	28
3.1.1 Choix du point AROME de référence	28
3.1.2 Sélection des variables explicatives de la force du vent	29
3.1.3 Sélection des variables explicatives de la direction du vent	32
3.2 Résultat d'échantillonnage	34
3.3 Modélisation de la force du vent à 100 m	36
3.4 Modélisation de la direction du vent à 100 m	41
3.4.1 La modélisation de U et V à 100 m	42
3.4.2 Reconstitution de DD à 100 m	48
4 Principaux résultats sur l'extension de la série temporelle d'observations horaires	51
4.1 Restitution des cycles	51
4.2 Restitution des roses des vents	54
4.3 Scores complémentaires pour FF	56
4.3.1 Scores par classe de FF	58
4.4 Choix du modèle pour la livraison	61
5 Livraison de l'extension de la série temporelle d'observations horaires	63
6 Bilan de l'apport de l'extension des données observées pour l'apprentissage de l'AO6	65
6.1 Bilan des données d'apprentissages	65
6.2 Quelques résultats de modélisation pour FF	65
6.3 Caractéristiques du vent	67
7 Annexe 1 : Description des modèles statistiques	69
7.1 Arbre binaire de décision	69
7.2 Forêt aléatoire	69
7.3 Modèle linéaire général	69
7.4 Modèle linéaire avec anamorphose	69
7.5 Réseau de neurones	70
7.5.1 Réseau multicouche	70

7.5.2 Entraînement du réseau	72
8 Annexe 2 : Étude d'optimisation de la méthode d'extension	74
8.1 Préambule	74
8.2 Protocole pour les stations d'études	74
8.3 Identification du point AROME de référence	74
8.4 Modélisation de la force du vent à 100 m	76
8.4.1 Sélection des variables explicatives	76
8.4.1.1 Paramètres calendaires	76
8.4.1.2 Paramètres météorologiques en sortie AROME	77
8.4.1.2.1 Résultats de l'analyse en composantes principales	77
8.4.1.2.2 Sélection finale des paramètres accessibles en sortie AROME	81
8.4.2 Échantillonnage	84
8.4.3 Études des modèles statistiques	85
8.4.3.1 Les arbres binaires de décision	85
8.4.3.2 AROME brut et les modèles linéaires	87
8.4.3.3 Les forêts aléatoires	91
8.4.3.3.1 Comparaison du modèle de forêt aléatoire avec et sans ACP	94
8.4.3.4 Les réseaux de neurones	96
8.4.3.4.1 Configuration du modèle retenu	97
8.4.3.4.2 Courbes d'entraînement du modèle de réseau de neurones	98
8.4.3.4.3 Scores de validation croisée pour la prédiction de FF	100
8.4.3.5 Modèle linéaire avec anamorphose	103
8.4.4 Comparaison inter-modèles sur l'échantillon de test	103
8.4.4.1 Test des prédicteurs de régimes de temps	106
8.5 Modélisation de la direction du vent à 100 m	110
8.5.1 Sélection des variables explicatives	110
8.5.2 Études des modèles statistiques	113
8.5.2.1 Scores de test pour la prédiction de U et V	113
8.5.2.1.1 Scores pour la composante U	113
8.5.2.1.2 Scores pour la composante V	116
8.5.2.1.3 Roses des vents après reconstitution de DD à partir de U et V	118
8.6 Synthèse du choix des modèles	120
8.7 Limites de l'extension	122
8.8 Conclusion de l'étude d'optimisation	123

Liste des illustrations

Illustration 2.1: Schéma récapitulatif de la méthodologie employée	18
Illustration 2.2: Courbe de charge théorique d'une éolienne de 10MW	27
Illustration 3.1: AO6 Méditerranée zone 1 – Choix du point AROME de référence – Roses des vents du point d'observation (en double au milieu) et des 4 points AROME voisins calculées pendant la période de mesure	28
Illustration 3.2: Localisation du site de la zone 1 de l'AO6 Méditerranée - Point d'observation LiDAR (en magenta) et points AROME (en jaune)	29
Illustration 3.3: AO6 Méditerranée zone 1 – FF – Corrélation entre la variable à expliquer FFmFFARO et les variables explicatives. En haut : sous forme de bulles. En bas : chiffré (0 : absence de corrélation, 1 ou -1 : forte corrélation)	30
Illustration 3.4: AO6 Méditerranée zone 1 – FF – Distribution du vent permettant de déterminer le cycle saisonnier (gauche) et le cycle diurne (droite)	31
Illustration 3.5: AO6 Méditerranée zone 1 – FF – cycle annuel climatologique (AROME 2000 à 2023)	32
Illustration 3.6: AO6 Méditerranée zone 1 – DD – Corrélation entre les variables à expliquer UmUARO et VmVARO et les variables explicatives. En haut : sous forme de bulles. En bas : chiffré (0 : absence de corrélation, 1 ou -1 : forte corrélation).	33
Illustration 3.7: AO6 Méditerranée zone 1 – DD – Distribution du vent permettant de déterminer le cycle saisonnier (graphique à gauche) et cycle diurne (graphique à droite)	34
Illustration 3.8: AO6 Méditerranée zone 1 – Distribution de FF (première ligne) et DD (deuxième ligne) pour les échantillons d'apprentissage et de test comparée à celle de l'observation sur la période d'apprentissage (période d'observation)	35
Illustration 3.9: AO6 Méditerranée zone 1 Corrélation des échantillons d'apprentissage	36
Illustration 3.10: AO6 Méditerranée zone 1 Corrélation des échantillons de test	36
Illustration 3.11: AO6 Méditerranée zone 1 – FF – Modèle de forêt aléatoire à 200 arbres - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon d'apprentissage. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.	37
Illustration 3.12: AO6 Méditerranée zone 1 – FF – Modèle de forêt aléatoire à 200 arbres - Box-plot PSS (première ligne PSS, PSS , PSSet PSS) et FA (deuxième ligne FA, FA , FAet FA) pour l'échantillon d'apprentissage. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.	37
Illustration 3.13: AO6 Méditerranée zone 1 – FF – Modèle de forêt aléatoire - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.	38
Illustration 3.14: AO6 Méditerranée zone 1 – FF – Modèle de forêt aléatoire - Box-plot PSS et FA pour l'échantillon de test. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.	38
Illustration 3.15: AO6 Méditerranée zone 1 – FF – Contribution des variables à l'ACP (une figure pour chaque dimension)	40
Illustration 3.16: AO6 Méditerranée zone 1 – FF – QQ-Plots sur l'échantillon de test concaténé.	41

Illustration 3.17: AO6 Méditerranée zone 1 – U – Modèle de forêt aléatoire à 200 arbres - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon d'apprentissage. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.	42
Illustration 3.18: AO6 Méditerranée zone 1 – U – Modèle de forêt aléatoire à 200 arbres - Box-plot PSS (première ligne PSS, PSS, PSS et PSS) et FA (deuxième ligne FA, FA, FA et FA) pour l'échantillon d'apprentissage. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.	43
Illustration 3.19: AO6 Méditerranée zone 1 – U – Modèle de forêt aléatoire à 200 arbres - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.	43
Illustration 3.20: AO6 Méditerranée zone 1 – U – Modèle de forêt aléatoire à 200 arbres - Box-plot PSS et FA pour l'échantillon de test. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.	44
Illustration 3.21: AO6 Méditerranée zone 1 – V – Modèle de forêt aléatoire à 200 arbres - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon d'apprentissage. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.	45
Illustration 3.22: AO6 Méditerranée zone 1 – V – Modèle de forêt aléatoire à 200 arbres - Box-plot PSS (première ligne PSS, PSS, PSS et PSS) et FA (deuxième ligne FA, FA, FA et FA) pour l'échantillon d'apprentissage. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.	45
Illustration 3.23: AO6 Méditerranée zone 1 – V – Modèle de forêt aléatoire à 200 arbres - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.	46
Illustration 3.24: AO6 Méditerranée zone 1 – V – Modèle de forêt aléatoire à 200 arbres - Box-plot PSS et FA pour l'échantillon de test. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.	46
Illustration 3.25: AO6 Méditerranée zone 1 – DD – Contribution des variables à l'ACP (une figure pour chaque dimension)	48
Illustration 3.26: AO6 Méditerranée zone 1 – DD – QQ-Plots de la reconstitution de DD avec combinaison de U et V sur l'échantillon de test concaténé.	50
Illustration 4.1: AO6 Méditerranée zone 1 – FF – Restitution des cycles de FF sur la période d'observation (du 10/06/2021 00H au 09/08/2024 23H). Sur la première ligne on retrouve le cycle annuel et sur la deuxième ligne le cycle diurne. La ligne discontinue verte traversant les boxplots désigne la médiane de l'observation sur la période d'observation.	52
Illustration 4.2: AO6 Méditerranée zone 1 – DD – Restitution des cycles de DD sur la période d'observation (du 10/06/2021 00H au 09/08/2024 23H). Sur la première ligne on retrouve le cycle annuel et sur la deuxième ligne le cycle diurne. La ligne discontinue verte traversant les boxplots désigne la médiane de l'observation sur la période d'observation.	53
Illustration 4.3: AO6 Méditerranée zone 1 – Roses des vents sur la période d'observation (du 10/06/2021 00H au 09/08/2024 23H) : sur la 1ère colonne (de haut en bas) on retrouve la rose AROME et celle de l'extension ; sur la 2ème colonne on retrouve la rose de l'observation. Les deux vignettes de cette colonne sont identiques et ont été dupliquées par soucis de lisibilité ; et sur la 3ème colonne (de haut en bas) on retrouve respectivement les roses issues de FF Extension et DD AROME, FF AROME et DD Extension	54
Illustration 4.4: AO6 Méditerranée zone 1 – QQPlots FF et DD sur la période d'observation.	56

Illustration 4.5: AO6 Méditerranée zone 1 – QQ-Plot des données de puissances sur la période d'observation pour l'extension statistique (bleu) et AROME (rouge).	58
Illustration 4.6: AO6 Méditerranée zone 1 – Roses des vents partielles sur la période d'observation (du 10/06/2021 00H au 09/08/2024 23H) : sur la 1ère colonne (de haut en bas) on retrouve la rose AROME et celle de l'extension ; sur la 2ème colonne on retrouve la rose de l'observation. Les deux vignettes de cette colonne sont identiques et ont été dupliquées par soucis de lisibilité ; et sur la 3ème colonne (de haut en bas) on retrouve respectivement les roses issues de FF Extension et DD AROME, FF AROME et DD Extension	60
Illustration 4.7: AO6 Méditerranée zone 1 – Roses des vents sur la période d'extension du 01/01/2000 00H TU au 09/06/2021 23H TU : à gauche on retrouve la rose de l'extension statistique et à droite la rose d'AROME.	62
Illustration 6.1: AO6 Méditerranée zone 1 – Roses des vents du point d'observation – de gauche à droite on retrouve respectivement les roses de la campagne 1 (10/06/2021 00H TU au 30/09/2022 23 TU) et de la campagne « 1 et 2 » (du 10/06/2021 00H TU au 09/08/2024 23H TU).	67
Illustration 6.2: AO6 Méditerranée zone 1 – Roses des vents de l'extension – campagne 1 (du 01/01/2000 00H TU au 09/06/2021 23H TU)	68
Illustration 6.3: AO6 Méditerranée zone 1 – Roses des vents de l'extension – campagne « 1 et 2 » (du 01/01/2000 00H TU au 09/06/2021 23H TU)	68
Illustration 7.1: Réseau de neurones multi-couches	70
Illustration 7.2: Processus de fonctionnement de la fonction de perte et de la mise à jour des paramètres du réseau	72
Illustration 8.1: Station de test 1 – Roses des vents du point d'observation (doublé sur la colonne du centre) et des 4 points AROME voisins (colonne de gauche et droite) sur la période du 01/01/2017 00H TU au 31/12/2020 23H TU	75
Illustration 8.2: Station de test 1 – Cycle diurne de la force du vent observée (bleu) et AROME (rouge) de 2017 à 2020.	76
Illustration 8.3: Station de test 1 – Part de variance expliquée de l'ACP	78
Illustration 8.4: Station de test 1 – FF – Contribution des variables à l'ACP (une figure pour chaque dimension)	79
Illustration 8.5: Station de test 1 – FF – Représentation des variables sur les plans factoriels de l'ACP (première partie des plans) : première ligne dimension 1-2, dimension 1-3 et dimension 1-4 ; deuxième ligne dimension 1-5, dimension 2-3, et dimension 1-2 (à nouveau)	80
Illustration 8.6: Station de test 1 – FF – Représentation des variables sur les plans factoriels de l'ACP (deuxième partie des plans) : première ligne dimension 2-4, dimension 2-5 et dimension 3-4 ; deuxième ligne dimension 3-5, dimension 4-5, et dimension 1-2	80
Illustration 8.7: Station de test 1 – Premier groupe (variables explicatives conservées pour la sélection finale) pour la prédiction de FF	82
Illustration 8.8: Station de test 1 – Deuxième groupe (variables de l'ACP) pour la prédiction de FF	83
Illustration 8.9: Station de test 1 – Variables explicatives finales (avec les composantes principales de l'ACP) pour la prédiction de FF	84
Illustration 8.10: Station de test 1 – FF –Modèle d'arbre de décision (arbre optimal)	86
Illustration 8.11: Station de test 1 – FF – Modèles linéaires et AROME.BRUT - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon d'apprentissage	88
Illustration 8.12: Station de test 1 – FF – Modèles linéaires et AROME.BRUT - Box-plot PSS (première ligne pss > 3 m/s, pss > 9 m/s et pss > 12 m/s noté respectivement pss1, pss2 et pss3)	

et FA (deuxième ligne $fa > 3$ m/s, $fa > 9$ m/s et $fa > 12$ m/s notée respectivement fa1, fa2 et fa3) pour l'échantillon d'apprentissage	88
Illustration 8.13: Station de test 1 – FF – Modèles linéaires et AROME.BRUT - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test	89
Illustration 8.14: Station de test 1 – FF – Modèles linéaires et AROME.BRUT - Box-plot PSS et FA pour l'échantillon de test	89
Illustration 8.15: Station de test 1 – FF – Modèles de forêt aléatoire à 20, 50, 100, 200 et 500 arbres - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon d'apprentissage	91
Illustration 8.16: Station de test 1 – FF – Modèles de forêt aléatoire à 20, 50, 100, 200 et 500 arbres - Box-plot PSS (première ligne $pss > 3$ m/s, $pss > 9$ m/s et $pss > 12$ m/s) et FA (deuxième ligne $fa > 3$ m/s, $fa > 9$ m/s et $fa > 12$ m/s) pour l'échantillon d'apprentissage	92
Illustration 8.17: Station de test 1 – FF – Modèles de forêt aléatoire - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test	92
Illustration 8.18: Station de test 1 – FF – Modèles de forêt aléatoire - Box-plot PSS et FA pour l'échantillon de test	93
Illustration 8.19: Station de test 1 – FF – Modèles de forêt aléatoire à 100 arbres avec et sans ACP - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon d'apprentissage	94
Illustration 8.20: Station de test 1 – FF – Modèles de forêt aléatoire à 100 arbres avec et sans ACP - Box-plot PSS (première ligne $pss > 3$ m/s, $pss > 9$ m/s et $pss > 12$ m/s) et FA (deuxième ligne $fa > 3$ m/s, $fa > 9$ m/s et $fa > 12$ m/s) pour l'échantillon d'apprentissage	95
Illustration 8.21: Station de test 1 – FF – Modèles de forêt aléatoire à 100 arbres avec et sans ACP - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon de test	95
Illustration 8.22: Station de test 1 – FF – Modèles de forêt aléatoire à 100 arbres avec et sans ACP - Box-plot PSS (première ligne $pss > 3$ m/s, $pss > 9$ m/s et $pss > 12$ m/s) et FA (deuxième ligne $fa > 3$ m/s, $fa > 9$ m/s et $fa > 12$ m/s) pour l'échantillon de test	96
Illustration 8.23: Station de test 1 – Architecture du réseau conservé pour la modélisation de FF	98
Illustration 8.24: Station de test 1 – FF – Courbe d'entraînement - modèles RNA avec l'optimizer SGD	98
Illustration 8.25: Station de test 1 – FF – Courbe d'entraînement - modèles RNB avec l'optimizer Adam	99
Illustration 8.26: Station de test 1 – FF – Courbe d'entraînement - modèles RNC avec l'optimizer RAdam	99
Illustration 8.27: Station de test 1 – FF – Réseau de neurones - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon d'apprentissage	100
Illustration 8.28: Station de test 1 – FF – Réseau de neurones - Box-plot PSS et FA pour l'échantillon d'apprentissage	101
Illustration 8.29: Station de test 1 – FF – Réseau de neurones - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test	101
Illustration 8.30: Station de test 1 – FF – Réseau de neurones - Box-plot PSS et MAE pour l'échantillon de test	102
Illustration 8.31: Station de test 1 – FF – Comparaison inter-modèles - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon de test	103
Illustration 8.32: Station de test 1 – FF – Comparaison inter-modèles - Box-plot PSS (première ligne $pss > 3$ m/s, $pss > 9$ m/s et $pss > 12$ m/s) et FA (deuxième ligne $fa > 3$ m/s, $fa > 9$ m/s et $fa > 12$ m/s) pour l'échantillon de test	104

Illustration 8.33: Station de test 1 – FF – QQ-Plot de FF pour les modèles GLM, GLM_MIXTE.STEP, RF_100, RNA et AROME	105
Illustration 8.34: Station de test 1 – FF – Cycle diurne des modèles statistiques (bleu) superposé aux observations (rouge)	105
Illustration 8.35: Station de test 1 – FF – Cycle annuel des modèles statistiques (bleu) superposé aux observations (rouge)	106
Illustration 8.36: Station de test 2 – FF – Modèles de forêt aléatoire à 100 arbres avec et sans prédictors de régimes de temps - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon d'apprentissage	108
Illustration 8.37: Station de test 2 – FF – Modèles de forêt aléatoire à 100 arbres avec et sans prédictors de régimes de temps - Box-plot PSS (première ligne pss > 3 m/s, pss > 9 m/s et pss > 12 m/s) et FA (deuxième ligne fa > 3 m/s, fa > 9 m/s et fa > 12 m/s) pour l'échantillon d'apprentissage	108
Illustration 8.38: Station de test 2 – FF – Modèles de forêt aléatoire à 100 arbres avec et sans prédictors de régimes de temps - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon de test	109
Illustration 8.39: Station de test 2 – FF – Modèles de forêt aléatoire à 100 arbres avec et sans prédictors de régimes de temps - Box-plot PSS (première ligne pss > 3 m/s, pss > 9 m/s et pss > 12 m/s) et FA (deuxième ligne fa > 3 m/s, fa > 9 m/s et fa > 12 m/s) pour l'échantillon de test	109
Illustration 8.40: Station de test 1 – Premier groupe (variables explicatives conservées pour la sélection finale) pour la prédiction de DD	111
Illustration 8.41: Station de test 1 – Deuxième groupe (variables de l'ACP) pour la prédiction de DD	112
Illustration 8.42: Station de test 1 – Variables explicatives finales (avec les composantes principales de l'ACP) pour la prédiction de DD	113
Illustration 8.43: Station de test 1 – U – Réseau de neurones - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test	114
Illustration 8.44: Station de test 1 – U – Réseau de neurones - Box-plot PSS et FA pour l'échantillon de test	114
Illustration 8.45: Station de test 1 – U – Modèles linéaires, forêt et AROME - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test	115
Illustration 8.46: Station de test 1 – U – Modèles linéaires, forêt et AROME - Box-plot PSS et FA pour l'échantillon de test	115
Illustration 8.47: Station de test 1 – V – Réseau de neurones - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test	116
Illustration 8.48: Station de test 1 – V – Réseau de neurones - Box-plot PSS et FA pour l'échantillon de test	117
Illustration 8.49: Station de test 1 – V – Modèles linéaires, forêt et AROME - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test	117
Illustration 8.50: Station de test 1 – V – Modèles linéaires, forêt et AROME - Box-plot PSS et FA pour l'échantillon de test	118
Illustration 8.51: Station de test 1 – Roses des vents issues des combinaisons de U et V des modèles statistiques: sur la 1ère colonne l'observation ; sur la 2ème colonne (de haut en bas) on retrouve DD AROME brut (U.BRUT et V.BRUT), DD GLM (U.GLM et V.GLM), U.GLM et V.RF_200, U.BRUT et V.GLM; et sur la 3ème colonne on retrouve DD RF_200 (U.RF_200, V.RF_200), DD GLM_MIXTE.STEP (U.GLM_MIXTE.STEP, V.GLM_MIXTE.STEP), U.RF_200 et V.GLM, U.BRUT et V.RF_200	119

Illustration 8.52: Station de test 1 – Roses des vents finales de l'extension entre l'année 2018 et 2020	121
Illustration 8.53: Station de test 2 – Roses des vents finales de l'extension entre l'année 2017 et 2020 (sans les données d'apprentissage de l'année 2018)	121
Illustration 8.54: Station de test 1 – Histogrammes de FF par classe de vent par pas de 5 m/s pour les années 2018 à 2020. En haut, observations (bleu) comparées à AROME (rouge). En bas, observations comparées à l'extension (vert).	122
Illustration 8.55: Station de test 2 – Histogrammes de FF par classe de vent par pas de 5 m/s pour les années 2017 à 2020 (sans les données d'apprentissage de l'année 2018). En haut, observations (bleu) comparées à AROME (rouge). En bas, observations (bleu) comparées à l'extension (vert).	123

Liste des tableaux

Tableau 2.1 : Caractéristiques de la courbe de charge théorique utilisée.	26
Tableau 3.1 : AO6 Méditerranée zone 1 – Choix du point AROME de référence – Scores B95+ des quatre points AROME voisins de l'observation	28
Tableau 3.2: AO6 Méditerranée zone 1 – Choix du point AROME de référence – Scores RMSE, ECT, BIAIS, MAE PSS et FA des quatre points AROME voisins de l'observation	29
Tableau 3.3 : AO6 Méditerranée zone 1 – FF et DD – Tableau de présence de mesure pour chaque mois de la campagne de mesure LiDAR de juin 2021 à août 2024	31
Tableau 3.4: AO6 Méditerranée zone 1 – FF – Modèles de forêt aléatoire – Scores de validation croisée sur l'échantillon d'apprentissage (en vert, le modèle choisi)	39
Tableau 3.5: AO6 Méditerranée zone 1 – FF – Modèles de forêt aléatoire – Scores de validation croisée sur l'échantillon de test (en vert, le modèle choisi)	39
Tableau 3.6 : AO6 Méditerranée zone 1 – FF – Importance des variables explicatives pour le modèle de forêt aléatoire avec 200 arbres	39
Tableau 3.7: AO6 Méditerranée zone 1 – Quartiles observation pour les composantes U et V du vent	42
Tableau 3.8: AO6 Méditerranée zone 1 – U – Modèle de forêt aléatoire à 200 arbres – Scores de validation croisée sur l'échantillon d'apprentissage (en vert, le modèle choisi)	44
Tableau 3.9: AO6 Méditerranée zone 1 – U – Modèle de forêt aléatoire à 200 arbres – Scores de validation croisée sur l'échantillon de test (en vert, le modèle choisi)	44
Tableau 3.10: AO6 Méditerranée zone 1 – V – Modèle de forêt aléatoire à 200 arbres – Scores de validation croisée sur l'échantillon d'apprentissage (en vert, le modèle choisi)	47
Tableau 3.11: AO6 Méditerranée zone 1 – V – Modèle de forêt aléatoire à 200 arbres – Scores de validation croisée sur l'échantillon de test (en vert, le modèle choisi)	47
Tableau 3.12 : AO6 Méditerranée zone 1 – U – Importance des variables explicatives pour le modèle de forêt aléatoire avec 200 arbres	47
Tableau 3.13 : AO6 Méditerranée zone 1 – V – Importance des variables explicatives pour le modèle de forêt aléatoire avec 200 arbres	47
Tableau 3.14 : AO6 Méditerranée zone 1 – DD – Scores RMSE de DD (en °) par secteur de direction sur l'échantillon de test concaténé (en vert, le modèle choisi)	49
Tableau 4.1 : AO6 Méditerranée zone 1 – Scores B95+ des roses des vents de l'extension statistique sur la période d'observation (du 10/06/2021 00H au 09/08/2024 23H)	54
Tableau 4.2: AO6 Méditerranée zone 1 – Tableau des quartiles de la force du vent sur la période d'observation	55

Tableau 4.3 : AO6 Méditerranée zone 1 – Scores RMSE de FF (en m/s) par secteur de direction sur la période d'observation (en vert les meilleurs scores)	57
Tableau 4.4 : AO6 Méditerranée zone 1 – Scores de qualité des données de puissances électriques sur la période d'observation (en gras les meilleurs scores)	57
Tableau 4.5: AO6 Méditerranée zone 1 – Quantiles en mega watt (mw) des données de puissances sur la période d'observation	57
Tableau 4.6: AO6 Méditerranée zone 1 – Scores par classe de FF sur la période d'observation	59
Tableau 4.7: AO6 Méditerranée zone 1 – Suite des scores par classe de FF sur la période d'observation	59
Tableau 4.8 : AO6 Méditerranée zone 1 – Scores B95+ des roses partielles des vents de l'extension statistique sur la période d'observation (du 10/06/2021 00H au 09/08/2024 23H)	61
Tableau 6.1: AO6 Méditerranée zone 1 – Comparaison livraison – inventaire des données d'apprentissages pour FF	65
Tableau 6.2: AO6 Méditerranée zone 1 – Comparaison apprentissage des différentes campagnes – Scores de test de validation croisée du modèle AROME	66
Tableau 6.3: AO6 Méditerranée zone 1 – Comparaison apprentissage des différentes campagnes – Scores de test de validation croisée du modèle statistique RF_200	66
Tableau 6.4: AO6 Méditerranée zone 1 – Comparaison apprentissage des différentes campagnes – scores d'extension (Puissance théorique) du modèle AROME	66
Tableau 6.5: AO6 Méditerranée zone 1 – Comparaison apprentissage des différentes campagnes – scores d'extension (Puissance théorique) du modèle statistique RF_200	66
Tableau 8.1: Station de test 1 – Scores B95+ des 4 points AROME voisins du point d'observation (en vert les scores décisifs)	75
Tableau 8.2: Station de test 1 – Tableau des variances expliquées par l'ACP (en vert les composantes conservées)	78
Tableau 8.3: Station de test 1 – FF – Importance des variables explicatives pour l'arbre binaire de décision	86
Tableau 8.4: Station de test 2 – FF – Importance des variables explicatives pour l'arbre binaire de décision	86
Tableau 8.5: Station de test 1 – FF – Modèles linéaires et AROME.BRUT - Scores de validation croisée sur l'échantillon d'apprentissage (en bleu les modèles avec les meilleurs scores)	90
Tableau 8.6: Station de test 1 – Modèles linéaires et AROME.BRUT - Scores de validation croisée sur l'échantillon de test (en bleu et vert, les modèles avec les meilleurs scores)	90
Tableau 8.7: Station de test 1 – FF – Modèles de forêt aléatoire - Scores de validation croisée sur l'échantillon d'apprentissage (en vert, le modèle choisi)	93
Tableau 8.8: Station de test 1 – FF – Modèles de forêt aléatoire - Scores de validation croisée sur l'échantillon de test (en vert, le modèle choisi)	93
Tableau 8.9 : Station de test 1 – FF – Importance des variables explicatives pour le modèle de forêt aléatoire avec 100 arbres	94
Tableau 8.10: Station de test 1 – FF – Modèles de forêt aléatoire avec et sans ACP – Scores de validation croisée sur l'échantillon d'apprentissage (en vert, le modèle choisi)	96
Tableau 8.11: Station de test 1 – FF – Modèles de forêt aléatoire avec et sans ACP – Scores de validation croisée sur l'échantillon de test (en vert, le modèle choisi)	96
Tableau 8.12: Station de test 1 – FF – Tableau récapitulatif du processus d'entraînement du réseau	97
Tableau 8.13: Station de test 1 – FF – Réseau de neurones - Scores de validation croisée sur l'échantillon d'apprentissage	102

Tableau 8.14: Station de test 1 – FF – Réseau de neurones - Scores de validation croisée sur l'échantillon de test	102
Tableau 8.15: Station de test 1 – FF – Scores de comparaison inter-modèles sur l'échantillon de test (en vert le modèle sélectionné)	104
Tableau 8.16: Table de pondération utilisée pour lier les régimes de temps 2 à 2	107
Tableau 8.17: Station de test 2 – FF – Modèles de forêt aléatoire avec et sans prédicteurs de régimes de temps - Scores de validation croisée sur l'échantillon d'apprentissage (en vert, le modèle choisi)	109
Tableau 8.18: Station de test 2 – FF – Modèles de forêt aléatoire avec et sans prédicteurs de régimes de temps - Scores de validation croisée sur l'échantillon de test (en vert, le modèle choisi)	110
Tableau 8.19 : Station de test 1 – U – Modèles linéaires, forêt, Réseau de neurones – Scores de validation croisée sur l'échantillon de test	116
Tableau 8.20 : Station de test 1 – V – Modèles linéaires, forêt, Réseau de neurones – Scores de validation croisée sur l'échantillon de test	118
Tableau 8.21: Station de test – Scores B95+ des roses de vents issues de la combinaison de U et V des modèles statistiques (en vert le modèle choisi)	120

Glossaire

Abréviation	Signification
FF	Force du vent (en m/s)
DD	Direction du vent (en °)
B95+	Indicateur permettant de qualifier la qualité d'une rose des vents
ACP	Analyse en composantes principales, utilisée pour décorréler les variables explicatives

1 Contexte de l'étude

Le lot 6b s'intéresse à l'analyse des mesures atmosphériques et à la production de statistiques sur le paramètre vent à 100 m.

Le domaine couvert par cette étude est la zone 1 de l'AO6 Méditerranée, zone sur laquelle un projet d'implantation d'éoliennes off-shore est prévu.

Ce rapport traite plus particulièrement de la méthode d'extension de la série d'observations horaires et des principaux résultats de la campagne de mesures réalisée du 10/06/2021 00H TU au 09/07/2022 23H, et prolongée du 10/07/2022 00H au 09/08/2024 23H TU pour le LiDAR situé dans la zone 1 de l'AO6 Méditerranée. C'est une mise à jour de la version 2 du rapport¹ précédemment livré.

La période reconstituée est d'environ 21,5 années (01/01/2000 00H TU au 09/06/2021 23H TU), calée sur la profondeur de la base climatologique AROME 2,5 km. À noter que la date du 09/06/2021 23H TU est fixée pour correspondre à la date de début effective de la campagne de mesure.

1.1 Livrables

Type de données	Paramètres	Caractéristiques	Format
Série horaire complète à 100 mètres sur la période de la campagne de mesures	Vitesse et direction du vent horizontal	- Période : campagne de mesures - Hauteur : 100 m - Fréquence temporelle : horaire	CSV (avec en entête les métadonnées associées aux données) (date/valeur)
Statistiques de la série horaire complète à 100 mètres sur la période de campagne de mesures	- Vent moyen horizontal - distribution statistique associée (quantiles de force de vent) - variation diurne horaire de la force du vent sur la période - roses de vent horizontal fréquentielles - gradients verticaux de vent	Hauteur : 100 m	CSV (avec en entête les métadonnées associées aux données) (date/valeur)
Chronique longue durée	Vitesse et direction du vent horizontal	- Période : à minima 20 ans - Hauteur : 100 mètres - Fréquence temporelle : horaire	CSV (avec en entête les métadonnées associées aux données) (date/valeur)
Rapport de fin de campagne		Extension de la série d'observations horaires	.PDF

À noter que « la série horaire complète à 100 mètres sur la période de la campagne de mesures » ainsi que les « statistiques de la série horaire complète à 100 mètres sur la période de campagne de mesures » ont été transmises lors de la livraison finale du lot 6a de la zone 1 de ce présent AO.

¹ DGEC_AO6_Méditerranée_Zone1_Lot5_Rapport_V2_20230523

2 Méthodologie d'extension de la série temporelle d'observations horaires

2.1 Méthodologie

Pour étendre la série temporelle d'observation de la force de vent sur une période plus longue, on procède de la manière suivante :

- tout d'abord, on quantifie la différence entre la force du vent issue de la série temporelle LiDAR et la force du vent issue du modèle AROME sur un point de grille proche du LiDAR et qui est choisi comme référence ;
- ensuite, on explique cette différence à l'aide d'autres paramètres atmosphériques provenant du modèle AROME. Un lien statistique est alors établi entre la force du vent du LiDAR, la force du vent du modèle AROME et d'autres paramètres météorologiques significatifs du modèle AROME ;
- le lien statistique est validé à l'aide des différents scores statistiques puis appliqué sur une série temporelle passée pour reconstituer la force du vent.

Le processus est le même pour la direction du vent que l'on décompose en deux paramètres – le vent zonal U et méridien V – sur lesquels le processus est appliqué.

Le schéma de l'illustration 2.1 présente la méthodologie complète adoptée pour la réalisation de l'extension de série.




Illustration 2.1: Schéma récapitulatif de la méthodologie employée

2.2 Phase exploratoire des données d'entrée

La modélisation statistique est précédée d'une phase d'exploration des données dans laquelle on analyse les liens entre les variables afin d'aboutir à un sous-ensemble de données pertinentes pour la mise en place des modèles statistiques.

Pour les travaux de ce rapport, il s'agit notamment :

- d'identifier le point de grille AROME de référence dont les caractéristiques du vent (force et direction) se rapprochent au mieux de celles du point d'observation LiDAR,
- d'identifier les paramètres pouvant expliquer les variations de la force et de la direction du vent au cours du temps, pour ensuite les intégrer dans les modèles statistiques.

À l'issue de cette analyse, on dispose d'une sélection de variables (dites variables explicatives), qui sont utilisées par la suite pour ajuster les modèles statistiques aux données d'observation.

2.2.1 Identification du point AROME de référence

Le choix du point AROME de référence s'effectue en s'appuyant sur les indicateurs de qualité (B95+) des roses de vent. Ces indicateurs de qualité concernent notamment quatre critères notés C1, C2, C3 et C4 présentés ci-dessous. Ils permettent de comparer deux roses des vents entre-elles sur des critères comme la distribution de la force du vent par classe ou la direction du vent par secteur.

Soit f_0^i la rose des vents climatologiques de référence et f_m^i la rose des vents du modèle AROME. Ces roses fréquentielles sont composées de 18 secteurs (tous les 20 degrés) et 4 classes de vent ($[0 ; 3[$, $[3 ; 9[$, $[9 ; 12[$ et >12 m/s).

- **Le critère C1** est le critère principal où la comparaison se fait sur l'ensemble des classes. Il permet d'étudier la qualité de la modélisation des fréquences de **force et direction du vent simultanément** :

$$C1 = 100 - 0.5 \times \sum_{i=1}^{18 \times 4} |f_0^i - f_m^i|$$

- **Le critère C2** est celui pour lequel les classes de vitesse sont regroupées et les vents calmes (<3 m/s, pour lesquels on sait qu'il y a de grosses incertitudes instrumentales sur la direction) ne sont pas pris en compte. Le critère C2 permet d'étudier la qualité de la modélisation des fréquences de **direction du vent** :

$$C2 = 100 - 0.5 \times \sum_{i=1}^{18} \left| \sum_{cl=1}^3 f_0^i - \sum_{cl=1}^3 f_m^i \right|$$

- **Le critère C3** est celui pour lequel les classes de direction sont regroupées. Il permet d'étudier la qualité de la modélisation des fréquences de **force du vent** :

$$C3 = 100 - 0.5 \times \sum_{i=1}^4 \left| \sum_{\text{secteur}=1}^{18} f_0^i - \sum_{\text{secteur}=1}^{18} f_m^i \right|$$

Ces critères de qualité (C1, C2 et C3) varient entre 0 et 100, 100 étant le meilleur score. Ils ont pour principal avantage leur simplicité d'interprétation, en particulier si le critère global est mauvais, on peut rapidement détecter si l'erreur vient d'un biais en direction ou d'un biais en force du vent. Par contre, ils présentent le défaut d'être fortement dépendants du nombre de classes : plus on a de classes, plus le critère est sévère. Dans notre cas, nous travaillons sur 18 classes en direction, et 4 classes en force du vent. Ceci rend le critère de direction très exigeant : un biais de 20° dans la direction du vent modèle, donnera un critère de direction (C2) nul.

- Enfin le dernier **critère C4** est la corrélation circulaire. Il est appliqué uniquement sur la **direction du vent**. Le coefficient de corrélation est calculé comme la corrélation de Pearson pour deux variables

linéaires X et Y . Dans la formule de calcul, $(x_i - \bar{x})$ et $(y_i - \bar{y})$ sont remplacés par $\sin(x_i - \bar{x})$ et $\sin(y_i - \bar{y})$ car les deux variables X et Y sont circulaires, où :

- x_i et y_i sont les valeurs de directions pour X et Y .
- $\bar{x}$ et $\bar{y}$ sont les directions moyennes des échantillons

$$C4 = \frac{\sum_{i=1}^n \sin(x_i - \bar{x}) \times \sin(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n \sin^2(x_i - \bar{x})} \times \sqrt{\sum_{i=1}^n \sin^2(y_i - \bar{y})}}$$

2.2.2 Traitement des données douteuses

Dans les travaux du lot 4 et 6a, des codes qualités sont attribués aux mesures (observations) DD et FF du vent à 100 m afin de les caractériser au mieux au regard de la modélisation AROME. On rencontre les codes qualités suivants :

- '1' : la donnée est validée.
- '2' : la donnée est estimée par interpolation linéaire.
- '21' : la donnée est estimée par une donnée modèle (AROME).
- '3' : la donnée est douteuse (car elle s'écarte des seuils fixés). Pour cette qualification, une donnée horaire FF ou DD d'observation à 100 m est qualifiée de douteuse si respectivement :
 $|FF_{\text{observation}} - FF_{\text{modèle}}| > 5 \text{ m/s}$ ou $|DD_{\text{observation}} - DD_{\text{modèle}}| > 30^\circ$.
- '31' : la donnée est douteuse, car elle a un taux de validité inférieur à 30 %. Le taux de validité correspond au nombre de données secondes disponibles pour obtenir une valeur moyennée sur une période de 10 minutes (Les données horaires étant celles des 10 minutes moyennées). On affectera le code 3 si cette donnée s'écarte également des seuils fixés.
- '99' : la donnée est douteuse, car elle ne peut être comparée avec le modèle (donnée modèle absente pour le point AROME référent du lot 4 et 6a). Ces données très peu nombreuses (parfois inexistantes) sont soit requalifiées avec la méthode du lot 6b (codes 1, 3 et 32 décrits ci-dessous), soit éliminées de la base d'apprentissage au cas où l'on ne peut comparer avec des données modèles. On note que pour cette zone 1 de l'AO6 Méditerranée seulement trois données étaient concernées par le code 99, et elles ont toutes été requalifiées code 1.

Cependant, dans la mise en place d'une base de données d'apprentissage pour le lot 6b, nous réadaptions ces codes qualités en réduisant légèrement le critère de qualification de donnée douteuse. Cela permet de **recupérer certaines données qualifiées de douteuses mais qui peuvent être utilisées dans l'apprentissage statistique selon deux objectifs**. Le 1^{er} objectif est d'augmenter la taille des échantillons d'apprentissage pour certaines catégories de données. Le 2^e objectif est de prendre en compte l'incertitude sur la modélisation AROME pour certains phénomènes de petites échelles et d'éventuellement permettre un apprentissage sur ces épisodes pour espérer une plus-value de l'extension.

On s'affranchit également des données AROME dans l'observation (les données avec le code « 21 » ne sont pas utilisées) pour la mise en place de cette base d'apprentissage.

On note, par ailleurs, que le point AROME utilisé pour qualifier les données douteuses peut être différent pour le lot 6a et 6b. Celui du lot 6b étant toujours le point AROME choisi comme référence.

Ainsi les codes qualités sont réassignés pour FF et DD en utilisant les données du point AROME de référence. Ils sont définis de cette façon :

- '1' : la donnée est validée, $|FF_{\text{observation}} - FF_{\text{modèle}}| \leq 5 \text{ m/s}$ pour FF, et $|DD_{\text{observation}} - DD_{\text{modèle}}| \leq 30^\circ$ pour DD.
- '2' : la donnée est estimée par interpolation linéaire,
- '21' : la donnée est estimée par une donnée modèle (AROME),

- '3' : la donnée est potentiellement de faible qualité, $5\text{ m/s} < |FF_{\text{observation}} - FF_{\text{modèle}}| \leq 7\text{ m/s}$ pour FF, et $30^\circ < |FF_{\text{observation}} - FF_{\text{modèle}}| \leq 42^\circ$ pour DD.
- '31' : la donnée est potentiellement de faible qualité, car elle a un taux de validité inférieur à 30 %,
- '32' : la donnée est douteuse (car elle s'écarte des seuils fixés). $|FF_{\text{observation}} - FF_{\text{modèle}}| > 7\text{ m/s}$ pour FF, et $|DD_{\text{observation}} - DD_{\text{modèle}}| > 42^\circ$ pour DD.

Finalement nous introduisons une nouvelle variable de code qualité notée **QDDFF** qui nous permet d'indexer les données éligibles dans la base d'apprentissage. La valeur de ce code qualité est le maximum de celles associées à DD et FF selon les critères mentionnés au-dessus :

- '1' : les données DD et FF sont valides toutes les deux.
- '2' : au moins l'une des données DD ou FF est estimée par interpolation (mais non potentiellement de faible qualité ni douteuse).
- '21' : au moins l'une des données DD ou FF est issue du modèle AROME. Elles sont **supprimées** de la base d'apprentissage.
- '3' : au moins l'une des données DD ou FF est potentiellement de faible qualité (mais non douteuse). Ces données peu nombreuses sont utilisées dans la base d'apprentissage.
- '31' : au moins l'une des données DD ou FF est potentiellement de faible qualité (mais non douteuse). Ces données peu nombreuses sont également utilisées dans la base d'apprentissage.
- '32' : au moins l'une des données DD ou FF est douteuse. Elles sont **supprimées** de la base d'apprentissage.

2.2.3 Identification des variables explicatives

Le processus détaillé de la sélection des variables explicatives est décrit dans la section 8.4 de l'annexe 2.

Le choix des variables explicatives est guidé par la connaissance météorologique de l'origine du vent. Les variables ci-dessous ont été pré-sélectionnées pour participer à la modélisation statistique. Celles présentant une trop forte covariance entre elles ont été séparées et intégrées dans une analyse en composante principale (ACP). **Le détail de la sélection des variables explicatives est présenté dans la section 3.1.2 pour la force du vent et la section 3.1.3 pour la direction du vent.**

- Prise en compte du paramètre à prédire :
 - Pour la force du vent :
 - **FF** : la force du vent AROME aux niveaux 10, 50, 100, 250 et 500 m – variable quantitative notée FFARO_10, FFARO_50, FFARO_100, FFARO_250 et FFARO_500 dans la suite du rapport, et
 - **SECTEUR** : la direction du vent AROME à 100 m par secteur de 20° – variable catégorielle à 18 facteurs – notée SECTEURARO_100 dans la suite du rapport,
 - Pour la direction du vent :
 - **U** : le vent zonal AROME aux niveaux 10, 100, 250 et 500 m – variable quantitative notée UARO_10, UARO_100, UARO_250 et UARO_500 dans la suite du rapport, et
 - **V** : le vent méridien AROME aux niveaux 10, 100, 250 et 500 m – variable quantitative notée VARO_10, VARO_100, VARO_250 et VARO_500 dans la suite du rapport,
- Prise en compte de la situation météorologique générale :
 - **PMER** : la pression AROME réduite au niveau de la mer – variable quantitative notée PMERARO dans la suite du rapport,

- **TPW850**: la température pseudo-adiabatique potentielle du thermomètre mouillé AROME à 850 hPa. Cette variable caractérise une masse d'air. C'est une variable quantitative – notée TPWARO_850 dans la suite du rapport,
- **HU2M** : l'humidité AROME relative à 2 m – variable quantitative notée HUARO_2 dans la suite du rapport,
- Prise en compte d'éléments de stabilité de l'atmosphère :
 - **T** : la température AROME à 2, 50, 100, 250 et 500 m – variable quantitative notée TARO_2, TARO_50, TARO_100, TARO_250, TARO_500 dans la suite du rapport.
 - **TKE et SQRTTKE** : la turbulence AROME et sa racine carrée à 10, 50, 100 et 160 m. On exploite la racine carrée de cette variable, de manière à privilégier un lien linéaire avec la force du vent de l'observation. Ce sont des variables quantitatives – noté TKEARO_10, TKEARO_50, TKEARO_100, TKEARO_160, SQRTTKEARO_10, SQRTTKEARO_50, SQRTTKEARO_100 et SQRTTKEARO_160 dans la suite du rapport,
- Prise en compte des cycles diurne et annuel du vent :
 - cycle diurne **HH** : variable catégorielle à plusieurs facteurs, fonction de la variable d'intérêt (FF ou DD), constitué à partir des heures de la journée – notée respectivement **RegHH_FF** et **RegHH_DD** dans la suite du rapport,
 - cycle saisonnier **MM** : variable catégorielle à plusieurs facteurs, fonction de la variable d'intérêt (FF ou DD), constitué à partir des mois de l'année – notée respectivement **RegMM_FF** et **RegMM_DD** dans la suite du rapport. Cette variable est notamment sujette au taux de disponibilité de la mesure LiDAR au long de la campagne de mesures.

2.3 Modélisation statistique par forêt aléatoire

La modélisation statistique permet d'établir un lien statistique robuste entre les variables explicatives X^i et les observations réelles de la force du vent à 100 m correspondant à la **variable Y à expliquer** :

$$Y = f(X^1, \dots, X^i, \dots, X^n) .$$

Le type des variables statistiques diffère selon l'espace dans lequel elles prennent leurs valeurs.

Elles peuvent être qualitatives à valeurs dans un ensemble de cardinal fini ou quantitatives à valeurs réelles voire fonctionnelles (à valeurs dans un espace de dimension infinie). Certaines méthodes de modélisation s'adaptent à tout type de variables explicatives tandis que d'autres sont spécialisées.

Si la variable Y à expliquer est qualitative, on parle de discrimination, classement ou reconnaissance de forme tandis que si la variable Y est quantitative comme pour cette étude, on parle d'un problème de régression.

Certaines méthodes sont dites spécifiques (régression linéaire, analyse discriminante), c'est-à-dire qu'elles sont soumises à des hypothèses de travail qu'il s'agit de vérifier, tandis que d'autres s'utilisent sans hypothèses contraignantes (arbres de décision, forêt aléatoire, réseau de neurones, etc).

Compte tenu du problème à résoudre (estimation de la force du vent à 100 m) et de l'expérience de Météo-France en matière de famille de modèles pouvant répondre au besoin, nous avons pré-sélectionné les types de modèles suivants : **arbre binaire de décision, modèle linéaire général, forêt aléatoire, modèle linéaire avec anamorphose et réseau de neurones** (descriptions faites en annexe au paragraphe 7). Suite à l'étude approfondie de l'ensemble de ces méthodes statistiques présentées en annexe au paragraphe 8 , **c'est le modèle de forêt aléatoire qui a été sélectionné pour réaliser les extensions des séries horaires dont celle de la zone 1 de l'AO6 Méditerranée.**

2.3.1 Description du modèle de forêt aléatoire

La méthode consiste à utiliser le hasard pour améliorer les performances des algorithmes ayant une faible capacité de classification. Une part d'aléatoire est ajoutée au cours de la construction des différents arbres qui seront alors agrégés ensemble pour former une forêt ('Genuer and Poggi, 2017')².

La forêt aléatoire se construit en concevant n arbres de décisions dont les échantillons d'observations sont tirés aléatoirement (c'est le tree bagging). Pour chacun des arbres à construire, un sous-ensemble de $q \leq P$ variables explicatives est sélectionné aléatoirement et servira à leur élaboration respective (c'est le feature sampling). En résumé : forêt aléatoire = tree bagging + feature sampling. L'objectif de cette approche est de rendre les arbres construits plus indépendants entre eux, ce qui offre de meilleures performances lors de l'agrégation en forêt.

La prédiction du modèle est donnée par la moyenne des prévisions obtenues par l'ensemble des estimations des arbres décisionnels de la forêt aléatoire.

L'approche possède l'avantage d'être très fructueuse en grande dimension et d'être simple à mettre en œuvre. L'utilisation de la forêt aléatoire permet également de s'affranchir de toute phase d'élagage et de tout problème lié à la multicollinéarité des variables.

Comme pour tout modèle construit par agrégation, il n'y a pas d'interprétation directe. Néanmoins des informations pertinentes sont obtenues par le calcul et la représentation graphique d'indices proportionnels à l'importance de chaque variable dans le modèle agrégé et donc de sa participation à la régression ou à la discrimination.

Deux critères sont ainsi proposés pour évaluer l'importance de la j -ème variable.

- Le premier (Mean Decrease Accuracy) repose sur une permutation aléatoire des valeurs de cette variable. Plus la qualité de la prévision est dégradée par la permutation des valeurs de cette variable, plus celle-ci est importante. Une fois le b -ème arbre construit, l'échantillon out-of-bag (celui n'ayant pas pris part à la construction de l'arbre) est prédit par cet arbre et l'erreur estimée enregistrée. Les valeurs de la j -ème variable sont aléatoirement permutées dans l'échantillon out-of-bag et l'erreur à nouveau calculée. La décroissance de la qualité de prévision est moyennée sur tous les arbres et utilisée pour évaluer l'importance de la variable j dans la forêt. Il s'agit donc d'une mesure globale mais indirecte de l'influence d'une variable sur la qualité des prévisions.
- Le deuxième (Mean Decrease Gini) est local et basé sur la décroissance d'entropie ou encore la décroissance de l'hétérogénéité définie à partir du critère de Gini. L'importance d'une variable est alors une somme pondérée des décroissances d'hétérogénéité induites lorsqu'elle est utilisée pour définir la division associée à un nœud.

Le paramètre le plus important à fixer est celui du nombre d'arbres à générer. Après plusieurs études de sensibilité (Annexe 2 : Étude d'optimisation de la méthode d'extension, précédents AO, thèse³ sur les adaptations statistiques de vent opérationnelles à Météo-France), il a été décidé de garder le nombre de 200 arbres de façon fixe dorénavant.

2.3.2 Les étapes de l'apprentissage

Les traitements s'enchaînent selon le schéma suivant :

1. Extraction des données.
2. Exploration des données pour la détection de valeurs aberrantes ou seulement atypiques, d'incohérences, pour l'étude des distributions des structures de corrélation, et pour la sélection des variables explicatives.

² Robin Genuer, Jean-Michel Poggi. Arbres CART et Forêts aléatoires, Importance et sélection de variables. 2017. hal-01387654v2

³ Michaël Zamo. Statistical Post-processing of Deterministic and Ensemble Wind Speed Forecasts on a Grid. Earth Sciences. Université Paris Saclay (COMUE), 2016. English.

3. Partition de l'échantillon en fonction de sa taille et des techniques qui seront utilisées pour estimer une erreur de prévision en vue des étapes de choix de modèle, puis de choix et certification de méthode.
4. Pour la forêt aléatoire, le modèle est estimé selon les valeurs des paramètres de complexité. Les valeurs de ces paramètres ont été obtenues à l'issue de nombreux tests et sont conservées dans toutes les études :
 - a) le nombre d'arbres est fixé à 200
 - b) le paramètre du feature sampling est fixé à la partie entière de $p/3$ (p étant le nombre total de prédicteurs). Cette valeur vaut 5, car dans les études il y a 15 prédicteurs pour FF et 16 pour U et V.
 - c) le paramètre nodesize permettant de limiter le nombre d'éléments dans les feuilles est fixé à 5.

Le modèle est ensuite évalué par validation croisée en comparaison avec le modèle AROME. Cette comparaison avec AROME n'est possible que sur la période à laquelle les observations sont disponibles. Elle permet également de calculer l'importance de variables utilisées dans l'apprentissage.
5. Ré-estimation du modèle de forêt aléatoire à l'étape précédente sur l'ensemble des données.
6. Comparaison du modèle obtenu avec le modèle AROME sur l'ensemble des données. Une précision est donnée sur cette comparaison dans le paragraphe 4 .

2.3.3 Choix des échantillons d'apprentissage et de test

Pour la validation du modèle statistique sur la période d'observation, nous devons séparer la série d'observation initiale en deux échantillons :

- l'échantillon d'apprentissage (on prend 70 % de la série initiale) pour ajuster les modèles statistiques,
- l'échantillon de test (on prend les 30 % restants) pour vérifier la robustesse du modèle.

L'échantillon initial étant petit, nous avons mis en place une stratégie nous permettant de séparer de façon itérative (20 itérations) la série d'observation initiale en deux échantillons (apprentissage et test). Les données seront alors tour à tour dans l'échantillon d'apprentissage et dans l'échantillon de test. Ainsi, au bout des 20 itérations, nous aurons utilisé toutes les observations à la fois en apprentissage et en test, mais jamais simultanément.

En effet, pour chaque itération la part des données d'apprentissage et de test sont sélectionnées aléatoirement de manière distincte. L'objectif principal de cette technique est d'avoir au bout des 20 itérations, un échantillon d'apprentissage et de test représentatifs de l'ensemble des données disponibles. Le résultat de cet échantillonnage est présenté dans le paragraphe 3.2 . À noter que pour ne pas diminuer de façon trop importante la taille des échantillons, aucune zone tampon n'est introduite autour des périodes de test et d'apprentissage. Les corrélations entre les différents échantillons sont également présentées en 3.2 .

2.3.4 Estimation de l'erreur des modèles statistiques sur ces échantillons

Un ensemble de critères définis comme suit est utilisé pour mesurer la qualité d'estimation de notre erreur de modélisation :

- **RMSE** : l'erreur quadratique moyenne mesure la distance entre le modèle et la référence. Plus il est proche de 0, plus le modèle est proche de la référence.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2}$$

Également calculé par classes de direction de vent de 20°.

- **BIAIS** : il caractérise l'erreur systématique du modèle ; plus il est proche de 0, plus le modèle est proche en moyenne des observations. Un BIAIS positif (négatif), signifie que le modèle surestime (sous-estime) le paramètre considéré.

$$BIAIS = \frac{1}{N} \sum_{i=1}^N (P_i - O_i)$$

- **ECT** : l'écart type donne la précision du modèle. Plus il est proche de 0, meilleur est le modèle.

$$ECT = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2 - \left(\frac{1}{N} \sum_{i=1}^N (P_i - O_i) \right)^2}$$

à noter que $RMSE$, $BIAIS$ et ECT sont liés par la relation suivante: $RMSE^2 = BIAIS^2 + ECT^2$

- **MAE** : L'erreur absolue moyenne mesure l'ampleur moyenne des erreurs dans un ensemble de prédictions, sans tenir compte de leur direction. Plus il est proche de 0, meilleur est le modèle.

$$MAE = \frac{1}{N} \sum_{i=1}^N |P_i - O_i|$$

- **PSS** : Peirce Skill Score

Soit un événement E (par exemple $FF > 5$ m/s), un échantillon d'observations et un modèle offrant la possibilité de prévoir cet événement, il est possible de construire la table de contingence suivante :

		observations	
		E est vrai sur l'observation	E est faux sur l'observation
prévisions	E est vrai sur la prévision	$n_{11}(s)$	$n_{10}(s)$
	E est faux sur la prévision	$n_{01}(s)$	$n_{00}(s)$

Taux de bonnes prévisions : $H = n_{11}(s) / (n_{11}(s) + n_{01}(s))$

Taux de fausses alertes : $FA = n_{10}(s) / (n_{10}(s) + n_{00}(s))$

PSS = H - FA

Le score PSS est compris entre -1 et 1. Si ce score est supérieur à 0, le taux de bonnes prévisions est supérieur à celui des fausses alertes. Plus il est proche de 1, meilleur est le modèle. Il est particulièrement adapté, pour évaluer la capacité du modèle à prévoir les valeurs extrêmes.

Ces critères lorsqu'ils sont appliqués à l'échantillon qui a été utilisé pour construire le modèle statistique (échantillon d'apprentissage) ne peuvent être qu'une estimation biaisée, car trop optimiste, de l'erreur de prévision puisqu'elle est liée aux données qui ont servi à l'ajustement du modèle.

Il est alors possible d'effectuer une validation dite croisée dont l'idée est d'itérer l'estimation de l'erreur sur plusieurs échantillons de validation puis d'en calculer la moyenne. Cette méthode a l'intérêt de réduire la variance des erreurs d'échantillonnages et ainsi améliorer la précision des scores lorsque la taille de l'échantillon initial est trop réduite pour en extraire des échantillons de validation et test de taille suffisante.

ALGORITHME DE LA VALIDATION CROISÉE :

```

1: Découper aléatoirement l'échantillon d'apprentissage en K parts (K-
fold) de tailles approximativement égales selon une loi uniforme ;
2: pour k allant de 1 à K do
    3: mettre de côté l'une des parties,
    4: estimer le modèle sur les K- 1 parties restantes,
    5: calculer l'erreur sur chacune des observations qui n'ont pas
    participé à l'estimation
6: fin boucle
7: moyenner toutes ces erreurs pour aboutir à l'estimation par validation
croisée.

```

Cet algorithme correspond à la version classique de l'algorithme de validation croisée. Celui-ci est adapté à notre étude comme décrit en 2.3.3 .

En plus, du calcul de la moyenne des scores précédents sur les 20 échantillons tests, deux scores supplémentaires sont réalisés. Ils sont calculés sur la série contenant les prédictions des 20 échantillons de test concaténés, noté « échantillon test concaténé » par la suite :

- Corrélation : score permettant de tester l'association entre des échantillons appariés, en utilisant le coefficient de corrélation de Spearman⁴.
- La courbe de fiabilité (**QQ-Plot**) : technique graphique qui vise à comparer deux fonctions de répartition en traçant les quantiles de l'une en fonction de ceux de l'autre (par exemple, le FF observé versus le FF estimé par le modèle statistique). Elle peut être utilisée afin de déterminer si deux séries de données obéissent à la même loi de probabilité, pour comparer les fonctions de répartition entre elles ou pour vérifier qu'un ensemble de données empiriques suit une certaine loi de probabilité théorique. La distribution générant le QQ-Plot le plus proche d'une ligne droite de pente 1 peut alors être considérée comme le meilleur choix.

2.4 Qualification de l'extension par forêt aléatoire

Une fois le calcul des scores réalisé avec les modèles échantillonnés sur la période d'observation, l'apprentissage est à nouveau réalisé sur l'ensemble de la période d'observation (l'intégralité des données d'apprentissage en une fois). Le modèle établi permet de faire des prédictions sur toute la période pour laquelle les prédictors sont disponibles : c'est l'extension statistique de la série horaire d'observation. La qualité de cette extension est enfin comparée au modèle AROME notamment pour vérifier l'amélioration de la restitution des cycles diurne et saisonnier et des roses de vent (dont B95+) uniquement sur la période d'observation. L'extension est en effet réalisée sur la période d'observation, ce qui est susceptible de l'avantager par rapport au modèle AROME, mais cela n'affecte que très peu les cycles et les roses.

A ce stade, nous disposons de la force du vent (FF) et de la direction du vent (DD) issues du modèle de forêt aléatoire et issues d'AROME. La combinaison entre ces deux sources de données sera également étudiée pour la restitution des roses des vents.

Enfin, le lien entre vitesse de vent et puissance produite par une éolienne étant non-linéaire, nous réalisons des ultimes scores (biais, RMSE, PSS...) en exploitant une courbe de charge théorique pour la conversion vent/puissance. La courbe de fiabilité (**QQ-Plot**) est également considérée ici.

Afin de calculer la puissance théorique, nous utilisons la courbe de charge présenté en illustration 2.2. La puissance suit les formules du tableau 2.1. Pour plus de détail sur les caractéristiques de l'éolienne choisie, le lecteur pourra se référer au lien suivant <https://github.com/IEAWindTask37/IEA-10.0-198-RWT>.

Tableau 2.1 : Caractéristiques de la courbe de charge théorique utilisée.

Force du vent (m/s)	FF < 4	4 ≤ FF ≤ 10,7	10,7 < FF ≤ 25	>25
Puissance (MW)	0	$P(FF)$	10	0

où
$$P(FF) = a_3 \times FF^3 + a_2 \times FF^2 + a_1 \times FF + a_0$$

⁴ D. J. Best & D. E. Roberts (1975). Algorithm AS 89: The Upper Tail Probabilities of Spearman's rho. *Applied Statistics*, 24, 377–379.

avec a_3 , a_2 , a_1 et a_0 valant respectivement 0.009808327 , -0.04421503 , 0.36130470 , et -0.9848518 déterminés à partir de l'ajustement de la courbe de charge théorique de l'illustration 2.2.




Illustration 2.2: Courbe de charge théorique d'une éolienne de 10MW

3 Principaux résultats sur la modélisation de FF et DD à 100 m

3.1 Phase exploratoire

3.1.1 Choix du point AROME de référence

Les variables explicatives des modèles statistiques sont issues des données du point de grille du modèle AROME servant de référence. Ce point de référence est choisi à travers la capacité de sa rose des vents à être le plus proche possible de la rose des vents du point d'observation. L'illustration 3.1 présente les roses des vents du point d'observation et des quatre points AROME voisins.




Illustration 3.1: AO6 Méditerranée zone 1 – Choix du point AROME de référence – Roses des vents du point d'observation (en double au milieu) et des 4 points AROME voisins calculées pendant la période de mesure

Globalement les roses des quatre points AROME ont des formes très similaires. Visuellement aucun des points AROME ne se démarque concrètement. Les roses étant proches les unes des autres, ce sont les scores de qualité B95+ (présentés au paragraphe 2.2.1) et les critères de qualité RMSE, ECT, BIAIS, MAE... (décrits au paragraphe 2.3.4) qui ont permis d'appuyer le choix du point de référence. La disposition spatiale réelle des points AROME se trouve sur la carte de l'illustration 3.2.

Tableau 3.1 : AO6 Méditerranée zone 1 – Choix du point AROME de référence – Scores B95+ des quatre points AROME voisins de l'observation

	Latitude	Longitude	C1 (DD&FF)	C2 (DD)	C3 (FF)	C4 (Corrélation circulaire)
Point AROME 1	43	3.55	86.92	88.88	95.26	0.94
Point AROME 2	43	3.525	85.87	87.72	95.51	0.93
Point AROME 3	43.025	3.55	83.53	87.55	93.53	0.94
Point AROME 4	43.025	3.525	82.52	86.42	93.49	0.94

Tableau 3.2: AO6 Méditerranée zone 1 – Choix du point AROME de référence – Scores RMSE, ECT, BIAIS, MAE PSS et FA des quatre points AROME voisins de l'observation

	RMSE	ECT	BIAIS	MAE	PSS FF € [1,3[m/ s	PSS FF € [3,9[m/ s	PSS FF € [9,12[m/s	PSS FF € [12,.. [m/s	FA FF € [1,3[m/s	FA FF € [3,9[m/s	FA FF € [9,12[m/s	FA FF € [12,.. [m/s
Point AROME 1	1.734	1.733	-0.054	1.365	0.433	0.697	0.477	0.809	0.024	0.123	0.111	0.062
Point AROME 2	1.755	1.754	-0.052	1.378	0.436	0.697	0.477	0.808	0.025	0.122	0.11	0.063
Point AROME 3	1.754	1.745	-0.179	1.39	0.438	0.698	0.472	0.794	0.024	0.128	0.116	0.056
Point AROME 4	1.766	1.756	-0.189	1.396	0.443	0.697	0.478	0.793	0.025	0.129	0.117	0.054

Dans l'ensemble les scores B95+ et les scores de qualité RMSE, BIAIS,..., PSS, FA sont en faveur du point 1. Par conséquent, **le choix du point AROME de référence porte sur le point 1 situé au Sud du point d'observation** (Illustration 3.2). Pour rappel, c'est aussi ce point 1 qui a été choisi comme référence dans l'étude précédente⁵ du lot 5.



Illustration 3.2: Localisation du site de la zone 1 de l'AO6 Méditerranée - Point d'observation LiDAR (en magenta) et points AROME (en jaune)

3.1.2 Sélection des variables explicatives de la force du vent

Pour mieux modéliser les valeurs extrêmes (retour d'expérience des tests d'extension de série d'observations précédents), nous avons cherché à **ajuster** des modèles statistiques, non pas sur la force FF du vent observé, mais sur **l'écart de cette force du vent avec la force du vent AROME**. Ainsi, la variable à prédire est définie par :

⁵ DGEC_AO6_Méditerranée_Zone1_Lot5_Rapport_V2_20230523

$$Y = FF_{OBS} - FF_{AROME} = FFmFFARO$$

L'ensemble des variables identifiées au paragraphe 2.2.3 est analysé. On examine en effet les liens entre la variable à expliquer Y et les variables explicatives X^i , ou entre les variables explicatives. Cette analyse permet de s'assurer qu'il y ait assez de corrélation entre chaque X^i et Y , et éviter toute corrélation forte entre variables X^i .

Certaines variables explicatives sont fortement corrélées entre elles et notamment au sein des nombreux niveaux disponibles pour les paramètres vent, température et turbulence. Nous avons donc choisi de garder un ou deux niveaux par paramètres avec des coefficients de corrélations avec $FFmFFARO$ élevés mais inférieurs ou égale à 0.96 entre-eux. Les autres niveaux sont utilisés dans l'ACP.

L'ACP a permis de sélectionner 5 nouvelles variables explicatives (notées respectivement **PC1_FF**, **PC2_FF**, **PC3_FF**, **PC4_FF** et **PC5_FF**) combinant les paramètres FFARO_10, FFARO_50, FFARO_250, TARO_2, TARO_50, TARO_250, TARO_500, TKEARO_50, TKEARO_100, TKEARO_160, SQRTTKEARO_50, SQRTTKEARO_100 et SQRTTKEARO_160.

L'illustration 3.3 présente la corrélation entre les variables qui ont été définitivement sélectionnées pour la mise en place du modèle statistique, et leurs corrélations avec la variable à prédire $FFmFFARO$.




Illustration 3.3: AO6 Méditerranée zone 1 – FF – Corrélation entre la variable à expliquer $FFmFFARO$ et les variables explicatives. En haut : sous forme de bulles. En bas : chiffré (0 : absence de corrélation, 1 ou -1 : forte corrélation)

Le graphique des corrélations montre que la variable à expliquer est faiblement corrélée linéairement avec les **14 variables explicatives choisies** auxquelles s'ajoutent les variables liées aux cycles de FF qui sont détaillées ci-dessous. Cette faible corrélation avec les variables explicatives découle de la façon de choisir la variable à expliquer. Celle-ci est une variable transformée (normalisée) qui est mieux appréciée par le modèle statistique que la variable à expliquer d'origine qui est FF_{OBS} . Cette dernière a bien une corrélation forte avec les variables explicatives dans l'ensemble (entre autres, en moyenne la corrélation est de 0.89 pour les FF, et 0.84 pour les TKE et SQRTTKE aux différents niveaux).

En effet, une dernière étape consiste en la définition des variables explicatives des cycles saisonnier et diurne pour la force du vent. Ces cycles sont déterminés à partir de la distribution du vent (illustration 3.4) en fonction des mois pour le cycle saisonnier et des heures pour le cycle diurne. Il faut tenir également compte du taux de présence de données d'observation au cours de la campagne de mesure (tableau 3.3) pour ajuster la variable de prise en compte du cycle saisonnier. L'utilisation de ce tableau permet de vérifier que les mois associés dans un cycle ont des nombres de données relativement proches les uns des autres.

Tableau 3.3 : AO6 Méditerranée zone 1 – FF et DD – Tableau de présence de mesure pour chaque mois de la campagne de mesure LiDAR de juin 2021 à août 2024

	Janv.	Fév.	Mars	Avril	Mai	Juin	Juillet	Août	Sept.	Oct.	Nov.	Déc.	Année
2021	0	0	0	0	0	460	630	583	299	639	690	654	3955
2022	691	615	705	678	599	602	578	628	649	609	573	586	7513
2023	707	604	660	566	668	608	691	600	617	554	531	45	6851
2024	630	646	671	639	658	651	636	202	0	0	0	0	4733
Somme	2028	1865	2036	1883	1925	2321	2535	2013	1565	1802	1794	1285	23052




Illustration 3.4: AO6 Méditerranée zone 1 – FF – Distribution du vent permettant de déterminer le cycle saisonnier (gauche) et le cycle diurne (droite)

La distribution de FF le long des mois a permis de définir un cycle annuel selon les quatre saisons météorologiques dont les plages de mois sont définies comme suit : **[décembre à février]** pour l'hiver où la force du vent est globalement forte, **[mars à mai]** pour le printemps où la force du vent diminue, et **[juin à août]** où la force du vent reste globalement faible, en dessous de la médiane de l'intégralité des données

(traits rouges en pointillés sur les graphiques), et [septembre à novembre] où la force du vent est faible mais s'accroît progressivement au fil des mois. Cette tendance saisonnière est également confirmée par le cycle annuel climatologique (AROME 2000 à 2023) après vérification de celui-ci (illustration 3.5). Par conséquent, la variable factorielle notée **RegMM** est définie pour prendre en compte le cycle saisonnier. Elle est composée de 4 facteurs (**Été, Automne, Hiver et Printemps**) constitués par les plages de mois évoquées ci-dessus.

Pour le cycle diurne, la distribution de FF fait ressortir trois plages de valeurs : [07H à 15H] où la force du vent est faible dans l'ensemble (FF en dessous de la médiane intégrale), [16H à 22H] où la force du vent augmente et reste au-dessus de la médiane, et [23H à 06H] où la force du vent diminue. La variable **RegHH_FF** définissant le cycle diurne de FF est donc une variable catégorielle à trois facteurs constituée par les associations d'heures ci-dessus.




Illustration 3.5: AO6 Méditerranée zone 1 – FF – cycle annuel climatologique (AROME 2000 à 2023)

3.1.3 Sélection des variables explicatives de la direction du vent

Comme pour la force du vent, le modèle statistique est ajusté sur l'écart de la direction du vent observé avec la direction du vent AROME. La direction du vent étant une variable circulaire, nous ne pouvons pas l'étudier directement. Nous devons donc élaborer un modèle statistique pour chacune des composantes U et V (calculés à l'aide de l'équation (1) situé page 42) :

$$Y = U_{OBS} - U_{AROME} = UmUARO \quad \text{et} \quad Y = V_{OBS} - V_{AROME} = VmVARO \quad .$$

De la même façon que pour la force du vent, il s'agit d'examiner les liens entre la variable à expliquer Y et les variables explicatives X^i .

En suivant la même méthode que précédemment (paragraphe 3.1.2), nous avons choisi de garder au maximum deux niveaux par paramètres (avec des coefficients de corrélations inférieurs ou égaux à 0.96), les autres étant dans l'ACP.

L'ACP a permis de sélectionner 5 nouvelles variables explicatives (notées respectivement **PC1_DD**, **PC2_DD**, **PC3_DD**, **PC4_DD** et **PC5_DD**) combinant cette fois les variables UARO_10, UARO_250, VARO_10, VARO_250, TARO_2, TARO_50, TARO_250, TARO_500, TKEARO_50, TKEARO_100, TKEARO_160, SQRTTKEARO_50, SQRTTKEARO_100 et SQRTTKEARO_160.

L'illustration 3.6 présente la corrélation avec la variable à prédire et entre les variables qui ont été définitivement sélectionnées pour la mise en place de chaque modèle statistique en regroupant *UmUARO* et *VmVARO* sur le même graphique.

Ce graphique montre que les variables à expliquer *UmUARO* et *VmVARO* sont faiblement corrélées linéairement avec les **15 variables explicatives choisies** auxquelles s'ajoutent les variables liées aux cycles de DD qui sont détaillées ci-dessous. Comme pour *FFmFFARO*, cette faible corrélation avec les variables explicatives découle de la transformation des variables à expliquer d'origines U_{OBS} et V_{OBS} qui ont globalement une corrélation forte avec les variables explicatives (par exemple entre 0.90 et 0.96 pour U et V aux différents niveaux).




Illustration 3.6: AO6 Méditerranée zone 1 – DD – Corrélation entre les variables à expliquer *UmUARO* et *VmVARO* et les variables explicatives. En haut : sous forme de bulles. En bas : chiffré (0 : absence de corrélation, 1 ou -1 : forte corrélation).

La dernière étape consiste en la définition des variables explicatives des cycles saisonnier et diurne pour la direction du vent. Comme pour FF, les cycles de DD sont déterminés à partir du taux de présence de données d'observation (tableau 3.3) et de la distribution du vent le long des mois pour le cycle saisonnier, et tout au long des heures pour le cycle diurne (illustration 3.7).




Illustration 3.7: AO6 Méditerranée zone 1 – DD – Distribution du vent permettant de déterminer le cycle saisonnier (graphique à gauche) et cycle diurne (graphique à droite)

Comme pour FF (illustration 3.4), la distribution de DD permet de définir les cycles. Pour le cycle annuel, la distribution de DD selon les mois ne fait pas ressortir un cycle particulier. Par conséquent, la saison météorologique (avec les plages de mois identiques à celles de FF) a été conservée. **La variable de prise en compte du cycle saisonnier reste identique à celle définie pour FF** (variable factorielle notée RegMM).

Pour le cycle diurne, la distribution de DD fait apparaître un cycle selon le changement de direction du vent (qui reste majoritairement de nord-ouest) à travers les 2 plages horaires suivantes : **[21 H à 11 H]** où dans l'ensemble la direction du vent est proche du nord-ouest (secteur 300°), **[12 H à 20 H]** où le vent tourne en direction du sud-est. Ainsi, la variable de prise en compte du cycle diurne est une variable catégorielle notée RegHH_DD avec deux facteurs constitués par les plages horaires ci-dessus.

3.2 Résultat d'échantillonnage

Le paragraphe 2.3.3 présente la manière dont sont construits les échantillons de test et d'apprentissage. Dans notre étude, nous adaptons cette méthode pour construire des échantillons de test et d'apprentissage les plus représentatifs de la mesure du LIDAR et des caractéristiques de la série de mesure de la zone 1 de l'AO6 Méditerranée.

En effet, nous avons créé une variable année-mois noté AAAAMM avec comme donnée l'année et le mois correspondant à la date. Par conséquent, de 06/2021 à 08/2024 la variable AAAAMM est une variable à 39 facteurs.

Ainsi, pour chacune des 20 itérations de l'échantillonnage, 70 % des données correspondant à chaque année-mois est sélectionné aléatoirement pour constituer l'échantillon d'apprentissage, et les 30 % restant pour constituer l'échantillon de test.

Le nombre d'itérations de l'échantillonnage est indépendant du nombre de facteurs de la variable nous permettant de faire notre échantillonnage (AAAAMM).

L'illustration 3.8 présente le résultat de cet échantillonnage où la distribution des échantillons d'apprentissage et de test est comparée à celle de l'observation initiale.




Illustration 3.8: AO6 Méditerranée zone 1 – Distribution de FF (première ligne) et DD (deuxième ligne) pour les échantillons d'apprentissage et de test comparée à celle de l'observation sur la période d'apprentissage (période d'observation)

Dans l'ensemble, les trois distributions ont le même type de profil pour FF et pour DD. Cela montre que les échantillons d'apprentissage et de test sont bien représentatifs de la distribution de l'observation.

Les profils de restitution des cycles diurne et saisonnier ont également été vérifiés pour les échantillons d'apprentissage et de test. Ils sont conformes à celui de l'observation.

Par ailleurs, la corrélation entre les différents échantillons a été vérifiée, et elle est très faible 2 à 2 entre les échantillons de test (les corrélations vont de 0.03 à 0.09). Quant aux échantillons d'apprentissage, ils sont relativement corrélés entre eux (de 0.66 à 0.73), ce qui découle de leur construction. Les échantillons de test sont donc suffisamment indépendants pour valider le choix du modèle sans introduire de zone tampon.




Illustration 3.9: AO6 Méditerranée zone 1
Corrélation des échantillons d'apprentissage




Illustration 3.10: AO6 Méditerranée zone 1
Corrélation des échantillons de test

3.3 Modélisation de la force du vent à 100 m

La force du vent FF a été estimée avec le modèle de forêt aléatoire à 200 arbres.

On rappelle que la variable à expliquer est : $Y = FF_{OBS} - FF_{AROME} = FFmFFARO$.

Les variables explicatives qui ont été sélectionnées sont : RegMM, RegHH_FF, SECTEURARO_100, FFARO_100, FFARO_500, TARO_100, TKEARO_10, SQRTTKEARO_10, HUARO_2, PMERARO, TPWARO_850, PC1_FF, PC2_FF, PC3_FF, PC4_FF, PC5_FF.

Les figures suivantes (illustrations 3.11 à 3.14) présentent les scores de validation croisée (apprentissage puis test) du modèle optimal (forêt à 200 arbres notée RF_200) comparé à AROME.




Illustration 3.11: AO6 Méditerranée zone 1 – FF – Modèle de forêt aléatoire à 200 arbres - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon d'apprentissage. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.




Illustration 3.12: AO6 Méditerranée zone 1 – FF – Modèle de forêt aléatoire à 200 arbres - Box-plot PSS (première ligne PSS $FF \in]., 3[\text{ m/s}$, PSS $FF \in [3, 9[\text{ m/s}$, PSS $FF \in [9, 12[\text{ m/s}$ et PSS $FF \in [12, .[\text{ m/s}$) et FA (deuxième ligne FA $FF \in]., 3[\text{ m/s}$, FA $FF \in [3, 9[\text{ m/s}$, FA $FF \in [9, 12[\text{ m/s}$ et FA $FF \in [12, .[\text{ m/s}$) pour l'échantillon d'apprentissage. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.




Illustration 3.13: AO6 Méditerranée zone 1 – FF – Modèle de forêt aléatoire - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.




Illustration 3.14: AO6 Méditerranée zone 1 – FF – Modèle de forêt aléatoire - Box-plot PSS et FA pour l'échantillon de test. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.

Ces scores de validation croisée pour FF (scores moyens des 20 échantillonnages représentés avec des textes en magenta sur les graphiques des boxplots), portant sur l'échantillon d'apprentissage puis de test, sont repris dans les tableaux 3.4 et 3.5 ci-dessous.

Tableau 3.4: AO6 Méditerranée zone 1 – **FF** – Modèles de forêt aléatoire – Scores de validation croisée sur l'échantillon d'apprentissage (en vert, le modèle choisi)

	RMSE	ECT	BIAIS	MAE	PSS FF ∈], 3[m/s	PSS FF ∈ [3, 9[m/s	PSS FF ∈ [9, 12[m/s	PSS FF ∈ [12, .[m/s	FA FF ∈], 3[m/s	FA FF ∈ [3, 9[m/s	FA FF ∈ [9, 12[m/s	FA FF ∈ [12, .[m/s
RF_200	0.715	0.715	0.003	0.534	0.632	0.878	0.775	0.921	0.002	0.077	0.044	0.021
AROME	1.885	1.883	-0.065	1.453	0.428	0.665	0.461	0.801	0.031	0.144	0.109	0.058
Part de données utilisées en %					7	4	18	34				

Tableau 3.5: AO6 Méditerranée zone 1 – **FF** – Modèles de forêt aléatoire – Scores de validation croisée sur l'échantillon de test (en vert, le modèle choisi)

	RMSE	ECT	BIAIS	MAE	PSS FF ∈], 3[m/s	PSS FF ∈ [3, 9[m/s	PSS FF ∈ [9, 12[m/s	PSS FF ∈ [12, .[m/s	FA FF ∈], 3[m/s	FA FF ∈ [3, 9[m/s	FA FF ∈ [9, 12[m/s	FA FF ∈ [12, .[m/s
RF_200	1.686	1.686	0.003	1.29	0.303	0.718	0.489	0.819	0.011	0.16	0.092	0.054
AROME	1.878	1.877	-0.07	1.45	0.439	0.67	0.46	0.799	0.029	0.143	0.109	0.059
Part de données utilisées en %					7	41	18	34				

À l'exception du PSS de test de la classe des vents faibles ($FF \in], 3]$ m/s) et FA de la classe $FF \in [3, 9[$ m/s , l'ensemble des scores d'apprentissage et de test sont favorables au modèle de forêt aléatoire à 200 arbres RF_200. Par conséquent, il a été décidé de choisir celui-ci pour réaliser l'estimation de la force du vent (**reconstitution de FF avec RF_200**).

Pour ce modèle, l'importance des variables est donnée par le tableau 3.6. C'est la moyenne de l'importance des variables pour chacun des 20 échantillonnages décrits dans la section 3.2 .

Tableau 3.6 : AO6 Méditerranée zone 1 – **FF** – **Importance des variables explicatives** pour le modèle de forêt aléatoire avec 200 arbres

Variable	Reg MM	RegHH _FF	SQRTT KEARO _10	TKEAR O_10	PC1_FF	PC2_FF	TARO_ 100	TPWAR O_850	FFARO _500	PC3_FF	HUARO _2	FFARO _100	PC4_FF	PMERA RO	SECTE URARO _100	PC5_FF
Importance	925	1097	2788	2799	3002	3264	3391	3485	3485	3781	3831	3885	4078	4216	4570	5697

La variable PC5_FF apparaît comme la variable ayant la plus grande importance pour le modèle RF_200. Elle résume l'information de FFARO_10, FFARO_50, FFARO_250 à travers l'ACP. Cependant, à l'exception des deux variables de prise en compte des cycles saisonnier et diurne, le reste des variables ont des poids relativement proches et importants pour le modèle de forêt aléatoire.

On rappelle en effet que les variables PC1_FF à PC5_FF résument l'information des autres paramètres AROME (FF, T, TKE et SQRTTKE) pour les niveaux non sélectionnés directement dans les variables explicatives. L'illustration 3.15 présente la contribution de chaque variable pour l'élaboration des composantes principales de l'ACP. Pour plus de détails sur la contribution des variables dans l'ACP, voir la section 8.4.1.2.1 de l'annexe 2.




Illustration 3.15: AO6 Méditerranée zone 1 – FF – Contribution des variables à l'ACP (une figure pour chaque dimension)

D'autre part, on note déjà sur les scores de qualité de ces échantillons, l'apport de la forêt aléatoire par rapport à AROME. Les scores de corrélation entre **l'échantillon de test concaténé et les mesures** vont également dans ce sens :

- pour FF issue de RF_200, la corrélation entre l'échantillon de test concaténé et les mesures est de 0.942,
- pour FF issue de AROME, la corrélation entre l'échantillon de test concaténé et les mesures est de 0.929.

Cependant, la courbe de fiabilité (QQ-Plot - illustration 3.16) est moins favorable au modèle RF_200 pour certaines plages de force du vent sur l'échantillon de test concaténé. En effet, visuellement le modèle RF_200 sur-estime les forces faibles jusqu'à 3 m/s d'une part, et d'autre part il sous-estime relativement les forces élevées à partir de 20 m/s environ. Le modèle AROME aussi a tendance à sous-estimer FF à partir de 20 m/s environ, mais pas plus que RF_200.

L'illustration 3.16 permet de visualiser les quantiles des deux modèles ; 80 % des données (entre le quantile 10 et le quantile 90) ont un comportement similaire entre les deux jeux de données. Les deux modèles s'écartent principalement pour les forces du vent inférieures au quantile q10 et supérieures au quantile q90.

À l'issue de cette modélisation, les modèles AROME et RF_200 présentent chacun de très bons résultats. Les illustrations 3.11 à 3.14 donnent cependant l'avantage à RF 200 sur la phase de test. La visualisation des QQ-plots (illustration 3.16) est la seule pouvant donner l'avantage à AROME ; l'ajout des quantiles sur le graphique permet de mettre en perspective les divergences des deux modèles. Cet affichage permet également de valider une livraison des deux modèles selon la plage de force de vent.

Le paragraphe 4.3 présente des scores complémentaires pour les deux modèles sur l'échantillon d'observation afin notamment de mettre en évidence les plages de forces.




Illustration 3.16: AO6 Méditerranée zone 1 – FF – QQ-Plots sur l'échantillon de test concaténé.

3.4 Modélisation de la direction du vent à 100 m

La méthodologie reste la même que celle employée précédemment pour la force du vent à 100 m.

La différence majeure se situe dans la caractéristique de la variable Y à expliquer (DD à 100 m), qui est une variable circulaire (modulo 360°). Pour tenir compte de cette caractéristique, la régression est effectuée selon les deux composantes du vent : zonale U et méridienne V puis la direction du vent DD est estimée à partir des estimations de U et V.

Le passage de (DD, FF) à (U, V) s'effectue de la façon suivante :

$$U = \sin\left(DD \times \frac{\pi}{180}\right) \times FF$$

$$V = \cos\left(DD \times \frac{\pi}{180}\right) \times FF \quad (1)$$

3.4.1 La modélisation de U et V à 100 m

Chacune des composantes U et V du vent a été estimée avec le modèle de forêt aléatoire.

Les variables à expliquer sont : $Y_1 = U_{OBS} - U_{AROME} = UmUARO$ et $Y_2 = V_{OBS} - V_{AROME} = VmVARO$.

Les variables explicatives choisies sont : RegMM, RegHH_DD, UARO_100, UARO_500, VARO_100, VARO_500, TKEARO_10, SQRTTKEARO_10, TARO_100, HUARO_2, PMERARO, TPWARO_850, PC1_DD, PC2_DD, PC3_DD, PC4_DD, PC5_DD.

Comme pour FF, les scores RMSE, ECT, MAE, BIAIS, PSS et FA ont permis de sélectionner le modèle de **forêt aléatoire avec 200 arbres** (RF_200) comme meilleur modèle statistique pour la prédiction de U et de V, comme le montrent les graphiques et tableaux de ces scores : illustrations 3.17 à 3.20, tableaux 3.8 et 3.9 pour la composante U et illustrations 3.21 à 3.24, tableaux 3.10 et 3.11 pour la composante V.

Les seuils des scores PSS et FA pour U et V correspondent respectivement aux trois quartiles (q1, q2 et q3) de l'observation de chacune des composantes U et V. Dans le calcul de ces scores, les seuils sont utilisés de la façon suivante pour U : PSS $U \in]-, q_1[$ m/s, PSS $U \in [q_1, q_2[$ m/s, PSS $U \in [q_2, q_3[$ m/s et PSS $U \in [q_3, +\infty[$ m/s ; FA $U \in]-, q_1[$ m/s, FA $U \in [q_1, q_2[$ m/s, FA $U \in [q_2, q_3[$ m/s et FA $U \in [q_3, +\infty[$ m/s. La même utilisation est faite pour V. Les valeurs des seuils sont présentées dans le tableau 3.7.

Tableau 3.7: AO6 Méditerranée zone 1 – Quartiles observation pour les composantes U et V du vent

	min	q1	q2	q3	max
Quantiles U	-25.6	-10.21	-3.67	2.78	20.89
Quantiles V	-26.15	-2.13	4	7.06	19.2




Illustration 3.17: AO6 Méditerranée zone 1 – U – Modèle de forêt aléatoire à 200 arbres - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon d'apprentissage. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.




Illustration 3.18: AO6 Méditerranée zone 1 – **U** – Modèle de forêt aléatoire à 200 arbres - Box-plot PSS (première ligne PSS $U \in] , q_1[$ m/s , PSS $U \in [q_1, q_2[$ m/s , PSS $U \in [q_2, q_3[$ m/s et PSS $U \in [q_3, .[$ m/s) et FA (deuxième ligne FA $U \in] , q_1[$ m/s , FA $U \in [q_1, q_2[$ m/s , FA $U \in [q_2, q_3[$ m/s et FA $U \in [q_3, .[$ m/s) pour l'échantillon d'apprentissage. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.




Illustration 3.19: AO6 Méditerranée zone 1 – **U** – Modèle de forêt aléatoire à 200 arbres - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.




Illustration 3.20: AO6 Méditerranée zone 1 – U – Modèle de forêt aléatoire à 200 arbres - Box-plot PSS et FA pour l'échantillon de test. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.

Ces scores de validation croisée pour la composante U (scores moyens des 20 échantillonnages représentés avec des textes en magenta sur les graphiques des boxplots), portant sur l'échantillon d'apprentissage puis de test, sont repris dans les tableaux 3.8 et 3.9 ci-dessous.

Tableau 3.8: AO6 Méditerranée zone 1 – U – Modèle de forêt aléatoire à 200 arbres – Scores de validation croisée sur l'échantillon d'apprentissage (en vert, le modèle choisi)

	RMSE	ECT	BIAIS	MAE	PSS U ∈], q1[m/s	PSS U ∈ [q1, q2[m/s	PSS U ∈ [q2, q3[m/s	PSS U ∈ [q3, .[m/s	FA U ∈], q1[m/s	FA U ∈ [q1, q2[m/s	FA U ∈ [q2, q3[m/s	FA U ∈ [q3, . [m/s
RF_200	0.714	0.714	0.001	0.532	0.929	0.886	0.882	0.946	0.016	0.033	0.024	0.016
AROME	1.927	1.903	-0.302	1.483	0.829	0.669	0.659	0.816	0.059	0.09	0.07	0.037
Part de données utilisées en %					25	25	25	25				

Tableau 3.9: AO6 Méditerranée zone 1 – U – Modèle de forêt aléatoire à 200 arbres – Scores de validation croisée sur l'échantillon de test (en vert, le modèle choisi)

	RMSE	ECT	BIAIS	MAE	PSS U ∈], q1[m/s	PSS U ∈ [q1, q2[m/s	PSS U ∈ [q2, q3[m/s	PSS U ∈ [q3, .[m/s	FA U ∈], q1[m/s	FA U ∈ [q1, q2[m/s	FA U ∈ [q2, q3[m/s	FA U ∈ [q3, . [m/s
RF_200	1.691	1.69	0.006	1.29	0.817	0.71	0.704	0.862	0.041	0.082	0.061	0.043
AROME	1.924	1.901	-0.3	1.48	0.825	0.671	0.66	0.817	0.059	0.091	0.07	0.037
Part de données utilisées en %					25	25	25	25				




Illustration 3.21: AO6 Méditerranée zone 1 – V – Modèle de forêt aléatoire à 200 arbres - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon d'apprentissage. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.




Illustration 3.22: AO6 Méditerranée zone 1 – V – Modèle de forêt aléatoire à 200 arbres - Box-plot PSS (première ligne PSS $V \in]q_1, q_2[$ m/s , PSS $V \in [q_2, q_3[$ m/s et PSS $V \in [q_3, .[$ m/s) et FA (deuxième ligne FA $V \in]q_1, q_2[$ m/s , FA $V \in [q_2, q_3[$ m/s et FA $V \in [q_3, .[$ m/s) pour l'échantillon d'apprentissage. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.




Illustration 3.23: AO6 Méditerranée zone 1 – V – Modèle de forêt aléatoire à 200 arbres - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.




Illustration 3.24: AO6 Méditerranée zone 1 – V – Modèle de forêt aléatoire à 200 arbres - Box-plot PSS et FA pour l'échantillon de test. La valeur en magenta sur chaque boîte à moustaches correspond à la moyenne des 20 échantillons.

Ces scores de validation croisée pour la composante V (scores moyens des 20 échantillonnages représentés avec des textes en magenta sur les graphiques des boxplots), portant sur l'échantillon d'apprentissage puis de test, sont repris dans les tableaux 3.10 et 3.11 ci-dessous.

Tableau 3.10: AO6 Méditerranée zone 1 – V – Modèle de forêt aléatoire à 200 arbres – Scores de validation croisée sur l'échantillon d'apprentissage (en vert, le modèle choisi)

	RMSE	ECT	BIAIS	MAE	PSS V ∈], q1[m/s	PSS V ∈ [q1, q2[m/s	PSS V ∈ [q2, q3[m/s	PSS V ∈ [q3, .[m/s	FA V ∈], q1[m/s	FA V ∈ [q1, q2[m/s	FA V ∈ [q2, q3[m/s	FA V ∈ [q3, . [m/s
RF_200	0.68	0.68	0.001	0.504	0.963	0.856	0.83	0.898	0.013	0.025	0.053	0.022
AROME	1.857	1.853	-0.112	1.429	0.871	0.641	0.512	0.647	0.023	0.109	0.154	0.046
Part de données utilisées en %					25	25	25	25				

Tableau 3.11: AO6 Méditerranée zone 1 – V – Modèle de forêt aléatoire à 200 arbres – Scores de validation croisée sur l'échantillon de test (en vert, le modèle choisi)

	RMSE	ECT	BIAIS	MAE	PSS V ∈], q1[m/s	PSS V ∈ [q1, q2[m/s	PSS V ∈ [q2, q3[m/s	PSS V ∈ [q3, .[m/s	FA V ∈], q1[m/s	FA V ∈ [q1, q2[m/s	FA V ∈ [q2, q3[m/s	FA V ∈ [q3, . [m/s
RF_200	1.612	1.612	-0.003	1.22	0.909	0.672	0.582	0.742	0.029	0.063	0.121	0.061
AROME	1.855	1.851	-0.122	1.43	0.874	0.649	0.515	0.648	0.023	0.108	0.153	0.045
Part de données utilisées en %					25	25	25	25				

Pour U et V, les scores d'apprentissage et de test sont dans l'ensemble favorables au modèle de forêt aléatoire à 200 arbres RF_200. Pour le **modèle choisi comme optimal (RF_200) pour U et V**, l'importance des variables est donnée respectivement par les tableaux 3.12 et 3.13.

Tableau 3.12 : AO6 Méditerranée zone 1 – U – Importance des variables explicatives pour le modèle de forêt aléatoire avec 200 arbres

Variable	RegH H_DD	RegM M	TKEA RO_10	SQRTT KEARO _10	PC1_D D	TARO_ 100	PC5_D D	TPWA RO_85 0	PC2_D D	PC3_D D	VARO_ 100	HUAR O_2	VARO_ 500	UARO_ 500	PC4_D D	PMERA RO	UARO_ 100
Importance	592	955	2649	2650	3089	3252	3330	3420	3446	3472	3475	3834	3920	4070	4107	4235	4999

Tableau 3.13 : AO6 Méditerranée zone 1 – V – Importance des variables explicatives pour le modèle de forêt aléatoire avec 200 arbres

Variable	RegH H_DD	RegM MM	SQRTT KEARO _10	TKEAR O_10	TARO_ 100	PC1_D D	PC2_D D	TPWA RO_85 0	PC5_D D	PC3_ DD	PMER ARO	HUARO _2	VARO_ 500	UARO_ 500	VARO_ 100	PC4_D D	UARO_ 100
Importance	367	868	2474	2476	2711	2717	2795	2851	2874	2997	3333	3560	4188	4423	4613	4719	4843

Les variables explicatives les plus importantes pour les modèles de U et V sont U et V du modèle AROME à différents niveaux. En effet, la variable PC4_DD résume l'information de UARO_10, UARO_250, VARO_10 et VARO_250 à travers l'ACP. Les variables PMERARO et HUARO_2 ont aussi une importance élevée pour les deux modèles. Ensuite, à l'exception des variables de prise en compte du cycle diurne (RegHH_DD) et saisonnier (RegMM) qui ont des poids un peu faibles, le reste des variables ont des poids relativement proches et importants pour le modèle de forêt aléatoire.

On rappelle que les variables PC1_DD à PC5_DD résument l'information des autres paramètres AROME (FF, T, TKE et SQRTTKE) pour les niveaux non sélectionnés directement dans les variables explicatives. L'illustration 3.25 présente la contribution de chaque variable pour l'élaboration des composantes principales de l'ACP.




Illustration 3.25: AO6 Méditerranée zone 1 – DD – Contribution des variables à l'ACP (une figure pour chaque dimension)

3.4.2 Reconstitution de DD à 100 m

La direction du vent est reconstituée à partir des estimations des composantes U et V :

$$DD = \left(90 - \frac{180}{\pi} \times \arctan 2(V, U) \right) \% 360 \quad (2)$$

Les scores du paragraphe précédent ont permis de sélectionner le modèle RF_200 comme modèle optimal pour ces deux composantes. Pour choisir la meilleure reconstitution de la direction du vent, nous établissons DD avec une combinaison de U et V issue du modèle RF_200 et AROME à l'aide de la formule (2). Ainsi, en plus de DD RF_200 et DD AROME, les scores sont calculés pour DD issue de U AROME et V RF_200 (noté U.AROME V.RF_200), et pour DD issue de U RF_200 et V AROME (noté U.RF_200 V.AROME). L'ensemble des scores de ce paragraphe est calculé sur l'échantillon de test concaténé.

Pour cela, les RMSE de DD par classe de direction (18 secteurs de 20 degrés) sont présentés dans le tableau 3.14 et analysés.

Tableau 3.14 : AO6 Méditerranée zone 1 – DD – Scores **RMSE de DD (en °) par secteur de direction** sur l'échantillon de test concaténé (en vert, le modèle choisi)

SECTEUR	00	20	40	60	80	100	120	140	160	180	200	220	240	260	280	300	320	340
Intervalle	[350°, 10°[	[10°, 30°[	[30°, 50°[	[50°, 70°[	[70°, 90°[	[90°, 110°[	[110°, 130°[	[130°, 150°[	[150°, 170°[	[170°, 190°[	[190°, 210°[	[210°, 230°[	[230°, 250°[	[250°, 270°[	[270°, 290°[	[290°, 310°[	[310°, 330°[	[330°, 350°[
NB DATA (%)	2.6	2	3	3.3	3	2.9	7	7	5.2	3.5	2.5	1.2	1	1.2	5.8	28.7	15.5	4.7
RF_200	20.67	20.12	16.67	15	18.87	19.24	12.7	11.99	13.68	14.06	15.61	19.54	23.94	23.37	13.54	7.47	11.23	16.96
AROME	21.11	21.11	17.95	17	19.86	20.86	15.74	15.55	16.17	15.56	16.58	19.09	20.09	20.1	11.88	8.4	13.05	18.87
U.RF_200 V.AROME	20.06	19.09	15.69	15.75	19.55	20.59	14.92	14.59	15.32	14.9	16.31	19.91	21.71	21.4	12.62	8.46	12.51	17.72
U.AROME V.RF_200	21.9	22.28	18.79	16.48	19.76	19.93	13.86	13.43	15.1	14.93	16.21	18.98	22.48	22.19	12.72	7.24	11.75	18.38

Ces scores sont majoritairement en faveur de DD reconstituée avec U et V du modèle de RF_200. Ce modèle obtient les meilleures RMSE pour 9 des 18 secteurs de direction, dont la plupart des secteurs les plus venteux.

Cette analyse concorde avec les scores de corrélation, calculés entre l'échantillon de test concaténé et les mesures, qui mettent en avant également le modèle RF_200. Les scores de corrélation sont en effet les suivants :

- 0.883 pour DD issue de RF_200,
- 0.874 pour DD issue de AROME,
- 0.883 pour DD issue de U.RF_200 V.ARO,
- 0.875 pour DD issue de U.ARO V.RF_200.

Enfin les diagrammes de QQ-Plots des différentes combinaisons de U et V pour la reconstitution de DD ont été visualisés (illustration 3.26).




Illustration 3.26: AO6 Méditerranée zone 1 – DD – QQ-Plots de la reconstitution de DD avec combinaison de U et V sur l'échantillon de test concaténé.

Globalement l'aperçu des QQ-Plots montre que le modèle RF_200 (en bleu) est plus proche de l'observation que les autres modèles. Finalement, suite à l'analyse des différents indicateurs de qualité (RMSE par secteur, QQ-Plots, vent dominant, corrélation), **la direction du vent sera reconstituée à partir des paramètres U et V et étendue à l'aide du modèle RF_200.**

4 Principaux résultats sur l'extension de la série temporelle d'observations horaires

Les résultats de modélisation de FF et DD ont permis de valider le choix du modèle de forêt aléatoire à 200 arbres (RF_200) pour établir l'extension des séries temporelles d'observations horaires.

Concrètement pour étendre les séries, l'apprentissage est réalisé avec RF_200 sur l'intégralité des données de la période d'observation. Une fois les paramètres du modèle estimés à travers l'apprentissage, ils sont appliqués aux prédicteurs sélectionnés sur la période de reconstitution des séries horaires (du 01/01/2000 00H au 09/06/2021 à 23H TU) : c'est l'**extension statistique**.

L'extension statistique est ensuite prolongée sur la période d'observation afin d'évaluer sa capacité de restitution des cycles diurne et saisonnier, et des roses des vents par rapport aux observations. Finalement, les scores complémentaires suivants seront examinés :

- un score sur les RMSE de FF (en m/s) par secteur de direction sur la période d'observation
- un score sur les données de puissances électriques sur la période d'observation
- et le QQ-Plot de FF sur la période d'observation.

Ces comparaisons de l'extension statistique avec le modèle AROME n'ont pas pour vocation de choisir le modèle final. Ce choix est élaboré dans la section 3.3 pour FF et 3.4 pour DD. Elles visent surtout à qualifier davantage les modèles (extension statistique et AROME) sur une période où on dispose des observations. En effet, il serait difficile de se faire une idée de la performance des modèles sans observations (en faisant par exemple une comparaison sur la période d'extension depuis 2000). Dans cette approche, l'extension statistique peut être favorisée par rapport à AROME sur les scores de types B95+, BIAIS, RMSE, etc., car calculée par rapport à l'observation. Mais le rendu des cycles diurne et saisonnier, la forme des roses des vents et QQ-Plot ne sont que très peu impactés.

4.1 Restitution des cycles

Les illustrations 4.1 et 4.2 présentent respectivement la restitution des cycles diurne et annuel de l'extension statistique pour FF et DD. Une comparaison avec l'observation et AROME est réalisée sur la période d'observation.




Illustration 4.1: AO6 Méditerranée zone 1 – FF – Restitution des cycles de FF sur la période d'observation (du 10/06/2021 00H au 09/08/2024 23H). Sur la première ligne on retrouve le cycle annuel et sur la deuxième ligne le cycle diurne. La ligne discontinue verte traversant les boxplots désigne la médiane de l'observation sur la période d'observation.

Globalement les deux modèles (extension statistique avec RF_200 et AROME) restituent bien les cycles diurne et annuel pour la force du vent.




Illustration 4.2: AO6 Méditerranée zone 1 – DD – Restitution des cycles de DD sur la période d'observation (du 10/06/2021 00H au 09/08/2024 23H). Sur la première ligne on retrouve le cycle annuel et sur la deuxième ligne le cycle diurne. La ligne discontinue verte traversant les boxplots désigne la médiane de l'observation sur la période d'observation.

Comme pour FF, dans l'ensemble, les deux modèles (extension statistique avec RF_200 et AROME) restituent bien les cycles diurne et annuel pour la direction du vent.

4.2 Restitution des roses des vents

L'illustration 4.3 présente la restitution de rose des vents des modèles : extension statistique, AROME et deux autres modèles issus de la combinaison de force et direction des deux modèles précédents. Une comparaison est faite avec l'observation sur la période d'observation.




Illustration 4.3: AO6 Méditerranée zone 1 – Roses des vents sur la **période d'observation** (du 10/06/2021 00H au 09/08/2024 23H) : sur la 1ère colonne (de haut en bas) on retrouve la rose AROME et celle de l'extension ; sur la 2ème colonne on retrouve la rose de l'observation. Les deux vignettes de cette colonne sont identiques et ont été dupliquées par soucis de lisibilité ; et sur la 3ème colonne (de haut en bas) on retrouve respectivement les roses issues de FF Extension et DD AROME, FF AROME et DD Extension

Le tableau 4.1 présente les scores B95+ associés aux roses de l'illustration 4.3.

Tableau 4.1 : AO6 Méditerranée zone 1 – Scores B95+ des roses des vents de l'extension statistique sur la **période d'observation** (du 10/06/2021 00H au 09/08/2024 23H)

Modèle	C1 (DD&FF)	C2 (DD)	C3 (FF)	C4 (corrélacion circulaire)
Extension statistique	89.53	92.80	94.02	0.97
AROME	88.10	89.60	96.65	0.93
FF.Ext – DD.ARO	86.02	88.92	94.02	0.93
FF.ARO – DD.Ext	91.76	93.82	96.65	0.97

Visuellement les roses des quatre modèles sont similaires deux à deux. En effet, d'une part la rose AROME (haut à gauche sur l'illustration 4.3) et la rose issue de « FF extension statistique et DD AROME » (haut à droite sur l'illustration 4.3) ont des formes similaires ; et d'autre part la rose de l'extension statistique (bas à gauche sur l'illustration 4.3) et celle issue de « FF AROME et DD extension statistique » (bas à droite sur l'illustration 4.3) ont des formes similaires. Dans la forme globale, ces deux derniers ressemblent un peu mieux à la rose de l'observation comparativement aux deux autres, notamment pour les vents dans les secteurs balayant le nord-ouest. Aussi, les scores B95+ confirment cette tendance, notamment pour le couple force direction (score C1). Par ailleurs, les deux roses dont la force est issue de l'extension statistique sous-estiment chacune la fréquence des vents faibles avec un taux légèrement inférieur à celui de l'observation (3 % contre 6 %). Cette sous-estimation de vent faible est beaucoup plus petite (1 % d'écart) pour les roses dont la force est issue du modèle AROME. Cela s'explique par l'ajustement relativement moindre des forces extrêmes (et plus particulièrement en début de distribution) pour le modèle statistique. Ces limites sont celles préalablement identifiées dans le paragraphe 3.3 .

Le tableau 4.2 des quartiles ci-dessous permet d'apprécier également de manière globale la qualité d'ajustement des modèles (AROME et extension statistique) par rapport à l'observation.

Tableau 4.2: AO6 Méditerranée zone 1 – Tableau des quartiles de la force du vent sur la période d'observation

	Minimum	1 ^{er} Quartile	Médiane	Moyenne	3 ^{ème} Quartile	Maximum
FF (m/s) Observation	0.20	5.99	9.71	10.10	13.74	27.88
FF (m/s) Extension statistique	0.95	6.12	9.61	10.08	13.59	26.01
FF (m/s) AROME	0.16	6.13	9.73	10.04	13.54	26.95

Dans l'ensemble, les quartiles des deux distributions (extension statistique et AROME) sont proches de ceux de l'observation. Cependant, la valeur minimum de l'extension statistique est relativement sur-estimée et sa valeur maximum légèrement sous-estimée. D'autre part, la valeur minimum du modèle AROME est légèrement sous-estimée et sa valeur maximum légèrement sous-estimée. Toutefois, les deux modèles sont très proches entre le premier et le troisième quartiles.

L'illustration 4.4 permet de visualiser les distributions ainsi que les quantiles. Pour la force du vent, les deux modèles sont proches sur plus de 80 % des données (entre le quantile 10 et 90). Pour la direction du vent, les deux modèles sont également très proches, ils divergent légèrement entre les quantiles q30, et q50.




Illustration 4.4: AO6 Méditerranée zone 1 – QQPlots FF et DD sur la **période d'observation**.

Par ailleurs, pour apprécier davantage l'extension statistique sur certaines plages de forces du vent, les scores (RMSE, ECT, BIAIS, MAE, PSS et FA) par classes de FF ont été calculés sur des plages de forces spécifiques dans le paragraphe 4.3.1 .

4.3 Scores complémentaires pour FF

Afin de qualifier davantage l'extension statistique, des scores complémentaires sont calculés sur la période d'observation : il s'agit notamment de la RMSE par secteur (RMSE de FF sur les classes de direction par secteur de 20 degrés) qui est présentée dans le tableau 4.3, et les scores de qualité sur la puissance théorique obtenue à l'aide d'une courbe de charge théorique⁶ pour les deux modèles (extension statistique et AROME) présentés dans le tableau 4.4.

⁶ Les caractéristiques de l'éolienne choisie sont disponibles ici : <https://github.com/IEAWindTask37/IEA-10.0-198-RWT>

Tableau 4.3 : AO6 Méditerranée zone 1 – Scores **RMSE de FF (en m/s) par secteur de direction sur la période d'observation** (en vert les meilleurs scores)

SECTEUR	00	20	40	60	80	100	120	140	160	180	200	220	240	260	280	300	320	340
Intervalle	[350°, 10°[	[10°, 30°[	[30°, 50°[	[50°, 70°[	[70°, 90°[	[90°, 110°[	[110°, 130°[	[130°, 150°[	[150°, 170°[	[170°, 190°[	[190°, 210°[	[210°, 230°[	[230°, 250°[	[250°, 270°[	[270°, 290°[	[290°, 310°[	[310°, 330°[	[330°, 350°[
Part de données utilisées en %	2.1	1.8	2.7	3.4	2.7	2.8	6.5	7.3	4.7	3.6	2.3	1.2	0.9	1.1	5.5	31.7	15.1	4.7
RMSE FF EXTENSION STATISTIQUE	1.44	1.5	1.36	1.38	1.28	1.39	1.6	1.58	1.7	1.69	1.58	1.4	1.3	1.45	1.63	1.56	1.59	1.52
RMSE FF AROME	1.7	1.8	1.68	1.68	1.59	1.7	1.78	1.69	1.82	1.85	1.82	1.76	1.66	1.82	1.82	1.7	1.73	1.77

Les scores RMSE de FF par secteur de direction sont tous en faveur de l'extension statistique.

Tableau 4.4 : AO6 Méditerranée zone 1 – **Scores de qualité des données de puissances électriques sur la période d'observation** (en gras les meilleurs scores)

	RMSE	ECT	BIAIS	MAE	PSS P ∈ [0, 2.5[	PSS P ∈ [2.5, 5[	PSS P ∈ [5, 7.5[	PSS P ∈ [7.5, 10[	PSS P ∈ [10, . [	FAP ∈ [0, 2.5[	FAP ∈ [2.5, 5[	FAP ∈ [5, 7.5[	FAP ∈ [7.5, 10[	FAP ∈ [10, . [
Nombre de données					6448	2509	1648	1231	9113					
Part de données (%)					31	12	8	6	44					
EXTENSION	1.59	1.59	-0.01	0.85	0.79	0.36	0.26	0.84	0.84	0.06	0.08	0.06	0.08	0.06
AROME	1.73	1.73	-0.04	0.95	0.75	0.29	0.23	0.82	0.82	0.07	0.09	0.06	0.09	0.08

Les scores de qualité des données de puissances sont dans l'ensemble à l'avantage de l'extension statistique. D'autre part, l'illustration 4.5 montre que le diagramme de QQ-Plot associé aux données de puissances sont globalement proches pour les deux modèles.

On rappelle cependant que le modèle statistique est appris sur la période d'observation, ce qui est susceptible de favoriser l'extension statistique par rapport au modèle AROME.

Le tableau 4.5 montre les quantiles des puissances de chaque modèle et celui de l'observation. Les trois jeux de données sont très proches les uns des autres.

Tableau 4.5: AO6 Méditerranée zone 1 – **Quantiles en mega watt (mw) des données de puissances sur la période d'observation**

	min	q10	q20	q30	q40	q50	q60	q70	q80	q90	max
Observation	0	0	1.1	2.4	4.3	7.3	10.1	10.1	10.1	10.1	10.1
Extension	0	0.5	1.3	2.4	4.2	7.1	10.1	10.1	10.1	10.1	10.1
AROME	0	0	1.3	2.5	4.5	7.4	10.1	10.1	10.1	10.1	10.1




Illustration 4.5: AO6 Méditerranée zone 1 – QQ-Plot des données de puissances sur la **période d'observation** pour l'extension statistique (bleu) et AROME (rouge).

4.3.1 Scores par classe de FF

Les scores globaux (scores sur l'intégralité des données sans distinction de classe de force) de modélisation (paragraphe 3.3) et d'extension (paragraphe 4.2) ont montré que visuellement l'extension statistique avec RF_200 sur-estimait légèrement les FF faibles jusqu'à 3 m/s **environ**, et sous-estimait légèrement les FF fortes à partir de 20 m/s **environ**.

Suite à des tests plus précis et pour apprécier davantage ces scores globaux, les scores RMSE, ECT, BIAIS, MAE, PSS et FA de FF ont été calculés pour le modèle AROME et l'extension statistique pour quatre classes de force : $FF < 4$ m/s , $FF \in [4, 15[$ m/s , $FF \in [15, 20[$ m/s et $FF \geq 20$ m/s ; et des roses de vent partielles (excluant les plages de force du vent inférieure à 4 m/s et supérieure ou égale à 20 m/s) ont été tracées.

Le choix des bornes des classes FF découle d'une part de l'examen visuel des QQ-Plots de modélisation (illustration 3.16) et de l'extension (illustration 4.4), et d'autre part des valeurs de FF auxquelles le score PSS bascule en faveur d'un modèle (AROME ou extension statistique). Ce point de bascule concerne notamment la borne des classes de FF faibles (c'est-à-dire la valeur 4 m/s), et la borne des classes de FF fortes (20 m/s).

Le nombre de données de chaque classe de FF est présent dans le tableau des scores. Ce nombre de données est celui de FF issue de l'observation.

Tableau 4.6: AO6 Méditerranée zone 1 – Scores par classe de FF sur la **période d'observation**

	RMSE					BIAIS					MAE			
Classe FF (m/s)	] ., 4[	[4, 15[	[15, 20[	[20, .[		] ., 4[	[4, 15[	[15, 20[	[20, .[		] ., 4[	[4, 15[	[15, 20[	[20, .[
Nombre de données	2380	14741	3274	554		2380	14741	3274	554		2380	14741	3274	554
Part de données utilisées en %	11	70	16	3		11	70	16	3		11	70	16	3
EXTENSION STATISTIQUE	1.59	1.5	1.66	2.05		1.1	0.01	-0.67	-1.38		1.22	1.16	1.27	1.63
AROME	1.75	1.7	1.81	2.12		0.87	-0.02	-0.67	-1.2		1.36	1.33	1.45	1.74

Tableau 4.7: AO6 Méditerranée zone 1 – Suite des scores par classe de FF sur la **période d'observation**

	ECT					PSS					FA			
Classe FF (m/s)	] ., 4[	[4, 15[	[15, 20[	[20, .[		] ., 4[	[4, 15[	[15, 20[	[20, .[		] ., 4[	[4, 15[	[15, 20[	[20, .[
Nombre de données	2380	14741	3274	554		2380	14741	3274	554		2380	14741	3274	554
Part de données utilisées en %	11	70	16	3		11	70	16	3		11	70	16	3
EXTENSION STATISTIQUE	1.14	1.5	1.52	1.51		0.56	0.66	0.69	0.54		0.02	0.29	0.04	0
AROME	1.52	1.7	1.68	1.74		0.57	0.62	0.63	0.52		0.04	0.29	0.05	0.01

Les scores RMSE, ECT, BIAIS et MAE par classe de force de vent sont majoritairement à l'avantage de l'extension statistique. En effet, seuls les biais des classes de vents faibles $FF < 4$ m/s et forts ($FF > 20$ m/s) lui sont défavorables. Mais il faut noter que les biais positifs et négatifs se compensent.

Un autre indicateur important dans cette analyse est la part de données par classe de FF. En effet, les classes FF ayant le plus grand nombre de données sont $[4, 15[$ m/s et $[15, 20[$ m/s. Ces deux classes totalisent près de 86 % des données de la période d'observation. Et pour ces classes l'extension statistique est meilleure pour tous les scores de qualités ci-dessus.

D'autre part, comme évoqué ci-dessus, le choix des valeurs de bornes de classes FF est également appuyé par les valeurs de FF auxquelles le PSS penche en faveur d'un modèle. Ainsi, l'aspect des roses de vent (illustration 4.6) a donc été visualisé en excluant les classes des forces de vent extrêmes (vents faibles $FF < 4$ m/s et vents forts $FF > 20$ m/s) qui représentent respectivement 11 % et 3 % du vent de la période d'observation.




Illustration 4.6: AO6 Méditerranée zone 1 – Roses des vents partielles sur la période d'observation (du 10/06/2021 00H au 09/08/2024 23H) : sur la 1ère colonne (de haut en bas) on retrouve la rose AROME et celle de l'extension ; sur la 2ème colonne on retrouve la rose de l'observation. Les deux vignettes de cette colonne sont identiques et ont été dupliquées par soucis de lisibilité ; et sur la 3ème colonne (de haut en bas) on retrouve respectivement les roses issues de FF Extension et DD AROME, FF AROME et DD Extension

Tableau 4.8 : AO6 Méditerranée zone 1 – Scores B95+ des **roses partielles** des vents de l'extension statistique sur la **période d'observation** (du 10/06/2021 00H au 09/08/2024 23H)

Modèle	C1 (DD&FF)	C2 (DD)	C3 (FF)	C4 (corrélation circulaire)
Extension statistique	91.97	93.08	98.39	0.97
AROME	85.95	88.19	95.46	0.93
FF.Ext – DD.ARO	87.84	88.49	98.39	0.93
FF.ARO – DD.Ext	89.96	92.79	95.46	0.97

Pour rappel, les roses sont établies uniquement sur les forces du vent des deux classes $[4, 15[$ m/s et $[15, 20[$ m/s (respectivement 70 % et 16 % du vent de la période d'observation) avec les directions associées à ces forces.

L'aperçu des roses démarque la rose de l'extension (RF_200) et celle issue de FF AROME DD extension, qui ont des formes globales un peu plus proche de l'observation que celles des deux autres, notamment dans les secteurs entre 300 et 320°. Aussi, la proportion de vent faible pour les roses ayant la force issue du modèle AROME est de 1 %. Cette proportion est légèrement sur-estimée comparativement à celle de l'observation (0 %). La proportion de vent faible des roses dont la force est issue de l'extension est identique à celle de l'observation.

Par ailleurs, les scores B95+ donnent l'avantage à la rose de l'extension statistique.

4.4 Choix du modèle pour la livraison

En tenant compte des scores présentés dans l'ensemble des chapitres 3 et 4, les recommandations suivantes ont été faites :

- **Pour la force du vent**, l'extension statistique (issue de la forêt aléatoire RF_200) est privilégiée pour les plages de force du vent observé compris entre 4 et 20 m/s ($FF \in [4, 20[$ m/s), et AROME pour les forces du vent observé inférieures à 4 m/s et supérieures ou égales à 20 m/s ($FF < 4$ m/s et $FF \geq 20$ m/s).
- **Pour la direction**, l'**extension statistique** est qualifiée comme modèle le plus approprié pour étendre la série de mesure du LiDAR de la zone 1 de l'AO6 Méditerranée.

Les modèles AROME (FF et DD) et extension statistique (FF et DD) seront mis à disposition des porteurs de projets. Ainsi, en fonction de leurs besoins, ils pourront suivre s'ils le souhaitent les recommandations ci-dessus.

L'illustration 4.7 présente la rose des vents des deux modèles sur la période d'extension, c'est-à-dire du 01/01/2000 00H TU au 09/06/2021 23H TU.





Illustration 4.7: AO6 Méditerranée zone 1 – Roses des vents sur la période d'extension du 01/01/2000 00H TU au 09/06/2021 23H TU : à gauche on retrouve la rose de l'extension statistique et à droite la rose d'AROME.

5 Livraison de l'extension de la série temporelle d'observations horaires

La livraison des données consiste en deux fichiers csv (le séparateur de colonne est « , », le séparateur de décimale est « . ») contenant :

- les données du 01/01/2000 00H TU au 09/06/2021 23H TU,
- une ligne d'en-tête précisant le nom des colonnes,
- les colonnes suivantes :
 - DATE sous la forme AAAAMMJJHH (année, mois, jour, heure TU),
 - FF100 pour la force du vent en m/s à 100 m,
 - DD100 pour la direction du vent en degrés à 100 m,
 - CODE, pour le code qualité associé à la donnée valant :
 - Pour la livraison de l'extension statistique
 - e si les données FF100 et DD100 sont estimées statistiquement
 - b si au moins l'une des données (FF100 ou DD100) est issue du modèle AROME
 - r si au moins l'une des données (FF100 ou DD100) est reconstituée à partir des moyennes horaires des 3 jours précédents et des 3 jours suivants le manque.
 - Pour la livraison AROME
 - b si les deux données (FF100 et DD100) sont issues du modèle AROME
 - br si l'une des données (FF100 ou DD100) est issue du modèle AROME et l'autre (FF100 ou DD100) est reconstituée à partir des moyennes horaires des 3 jours précédents et des 3 jours suivants le manque,
 - r si les deux données (FF100 ou DD100) sont reconstituées à partir des moyennes horaires des 3 jours précédents et des 3 jours suivants le manque.
 - NB : La série horaire étendue doit être complète, c'est-à-dire que pour chaque échéance de la date (AAAAMMJJHH), doit correspondre une force FF100 et une direction DD100. Cependant dans certains cas, les situations suivantes peuvent se présenter :
 - Pour une échéance donnée de la date, la valeur de l'un des prédictors n'est pas disponible⁷ mais la valeur (FF, DD à 100 m) du modèle AROME est disponible. Dans ce cas, le modèle AROME est utilisé pour combler cette échéance de l'extension (c'est le code b).
 - Pour une échéance donnée de la date, la valeur de l'un des prédictors n'est pas disponible et la valeur (FF, DD à 100 m) du modèle AROME n'est pas disponible non plus. Dans ce cas, le comblement de cette échéance de l'extension est fait avec le code r décrit ci-dessus.

Dans le cas de cette livraison :

- pour l'extension statistique, on dénombre 186 700 données estimées statistiquement (code e), 982 données issues du modèle AROME (code b), et 262 données reconstituées (code r) sur la période d'extension.
- Pour AROME, seuls les codes qualité b et r ont été rencontrés. En effet, il y a 262 données reconstituées à partir des moyennes horaires pour FF et DD, et 187 682 données issues du modèle AROME.

Nous avons appliqué les mêmes critères que pour l'observation, à savoir

⁷ Il n'est donc pas possible d'utiliser le modèle statistique pour faire la prédiction (DD ou FF) de cette échéance.

- La force du vent à 100 m est arrondie à la première décimale,
- La direction du vent à 100 m est arrondie à l'entier (entre 1° et 360°).

Le nom des fichiers sont :

- ***AO6_Méditerranée_Zone1_Lot6b_extSerieLidarH100M.csv*** pour l'extension statistique ;
- ***AO6_Méditerranée_Zone1_Lot6b_AROME_extSerieLidarH100M.csv*** pour AROME.

6 Bilan de l'apport de l'extension des données observées pour l'apprentissage de l'AO6

Pour cette zone 1 de l'AO6 Méditerranée, la campagne de mesure a été réalisée en deux parties. La première partie (campagne 1) a déjà fait l'objet d'une étude du lot 5 dont les résultats ont été livrés⁸ en 2022. Les mesures utilisées dans l'étude de la campagne 1 couvrent la période du 10/06/2021 00H TU au 09/07/2022 23H TU. À l'issue de la présente étude, 2 apprentissages ont donc été réalisés pour les différentes campagnes :

- apprentissage campagne 1 (livré en 2022)
- apprentissage campagne « 1 et 2 ». (livraison actuelle 2024)

Les résultats de ces 2 apprentissages ont été comparés pour la modélisation de la force du vent (FF). Ainsi, le bilan des données d'apprentissage, les caractéristiques du vent (roses des vents d'observation et d'extension), ainsi que quelques résultats de modélisation (résultats de test des modèles statistiques) et d'extension sont présentés.

6.1 Bilan des données d'apprentissages

Pour cette livraison 2024, la constitution de la base de données d'apprentissage est décrite dans le paragraphe 2.2.2 où le traitement des données douteuses est détaillé.

Le tableau 6.1 présente un inventaire des données d'apprentissage (code qualité DD et FF des observations prises en compte dans l'apprentissage statistique) pour les différentes campagnes.

Tableau 6.1: AO6 Méditerranée zone 1 – Comparaison livraison – inventaire des données d'apprentissages pour FF

Données	Valides QDDFF = 1	Interpolées QDDFF = 2	Semi- valides QDDFF = 3	Semi-valides QDDFF = 31	Douteuses QDDFF = 32	Total	Total Apprentissage
campagne 1	7430	19	575	0	879	8903	8024
Totale campagne « 1 et 2 »	21138	80	1834	0	2860	25912	23052

Le prolongement de la campagne de mesure a permis de plus que doubler le nombre de données d'apprentissage.

6.2 Quelques résultats de modélisation pour FF

Pour les 2 apprentissages (campagne 1 et campagne « 1 et 2 ») les variables explicatives utilisées sont identiques à l'exception des variables de prise en compte du cycle diurne et saisonnier. Dans tous les cas la sélection de ces variables découle de la phase exploratoire décrite dans ce rapport dans le cadre de cette livraison 2024.

Les tableaux suivants présentent les scores de test de validation croisée du modèle AROME (tableau 6.2) et des modèles statistiques (tableau 6.3) pour les différents apprentissages. On note que le nombre d'échantillons utilisés dans l'apprentissage reste identique (20 échantillons).

⁸ DGEC_AO6_Méditerranée_Zone1_Lot5_Rapport_V2_20230523

Tableau 6.2: AO6 Méditerranée zone 1 – Comparaison apprentissage des différentes campagnes – Scores de test de validation croisée du modèle **AROME**

	RMSE	ECT	BIAIS	MAE	PSS FF ∈], 3[m/s	PSS FF ∈ [3, 9[m/s	PSS FF ∈ [9, 12[m/s	PSS FF ∈ [12, .[m/s	FA FF ∈], 3[m/s	FA FF ∈ [3, 9[m/s	FA FF ∈ [9, 12[m/s	FA FF ∈ [12, .[m/s
AROME campagne 1	1.861	1.855	-0.149	1.43	0.445	0.671	0.487	0.807	0.03	0.136	0.107	0.058
AROME campagne « 1 et 2 »	1.878	1.877	-0.07	1.45	0.439	0.67	0.46	0.799	0.029	0.143	0.109	0.059

Tableau 6.3: AO6 Méditerranée zone 1 – Comparaison apprentissage des différentes campagnes – Scores de test de validation croisée du modèle statistique **RF_200**

	RMSE	ECT	BIAIS	MAE	PSS FF ∈], 3[m/s	PSS FF ∈ [3, 9[m/s	PSS FF ∈ [9, 12[m/s	PSS FF ∈ [12, .[m/s	FA FF ∈], 3[m/s	FA FF ∈ [3, 9[m/s	FA FF ∈ [9, 12[m/s	FA FF ∈ [12, .[m/s
RF_200 campagne 1	1.66	1.659	0.013	1.25	0.311	0.726	0.525	0.825	0.012	0.145	0.091	0.056
RF_200 campagne « 1 et 2 »	1.686	1.686	0.003	1.29	0.303	0.718	0.489	0.819	0.011	0.16	0.092	0.054

Pour le modèle AROME les scores de test sont très proches les uns des autres, mais la campagne 1 a des scores légèrement meilleurs que la campagne intégrale (campagne « 1 et 2 »).

Pour le modèle statistique, dans l'ensemble les meilleurs scores de test reviennent également à la campagne 1 avec plus d'indicateurs en sa faveur. À noter que globalement les scores du modèle statistique sont meilleurs que ceux du modèle AROME pour les différentes campagnes.

Tableau 6.4: AO6 Méditerranée zone 1 – Comparaison apprentissage des différentes campagnes – scores d'extension (Puissance théorique) du modèle **AROME**

	RMSE	ECT	BIAIS	MAE	PSS PW dans [0, 2.5[	PSS PW dans [2.5, 5[	PSS PW dans [5, 7.5[	PSS PW dans [7.5, 10[	PSS PW dans [10, .[	FA PW dans [0, 2.5[	FA PW dans [2.5, 5[	FA PW dans [5, 7.5[	FA PW dans [7.5, 10[	FA PW dans [10, .[
AROME campagne 1	1.71	1.71	0.01	0.94	0.75	0.29	0.24	0.82	0.81	0.07	0.08	0.07	0.09	0.07
AROME campagne « 1 et 2 »	1.73	1.73	-0.04	0.95	0.75	0.29	0.23	0.82	0.82	0.07	0.09	0.06	0.09	0.08

Tableau 6.5: AO6 Méditerranée zone 1 – Comparaison apprentissage des différentes campagnes – scores d'extension (Puissance théorique) du modèle statistique **RF_200**

	RMSE	ECT	BIAIS	MAE	PSS PW dans [0, 2.5[	PSS PW dans [2.5, 5[	PSS PW dans [5, 7.5[	PSS PW dans [7.5, 10[	PSS PW dans [10, .[	FA PW dans [0, 2.5[	FA PW dans [2.5, 5[	FA PW dans [5, 7.5[	FA PW dans [7.5, 10[	FA PW dans [10, .[
RF_200 campagne 1	0.94	0.94	-0.01	0.46	0.88	0.57	0.47	0.92	0.91	0.03	0.05	0.04	0.05	0.04
RF_200 campagne « 1 et 2 »	1.59	1.59	-0.01	0.85	0.79	0.36	0.26	0.84	0.84	0.06	0.08	0.06	0.08	0.06

Pour la puissance théorique, les scores d'extension du modèle AROME sont relativement meilleurs pour la campagne 1. Aussi, les scores du modèle statistique sont relativement favorables à la campagne 1. Cependant dans tous les cas, les scores du modèle statistique sont meilleurs que ceux du modèle AROME lorsqu'on compare les deux campagnes 1 et « 1 et 2 ».

6.3 Caractéristiques du vent

Les caractéristiques du vent, en termes de force et direction sont très similaires entre les deux parties de la campagne de mesures. Tout d'abord les roses des vents sont présentées sur les périodes d'observations (illustration 6.1) de la campagne de mesures (campagne 1, campagne « 1 et 2 »), ensuite ce sont les roses des vents de l'extension finale pour chacune des campagnes (illustrations 6.2 et 6.3) qui sont présentées.




Illustration 6.1: AO6 Méditerranée zone 1 – Roses des vents du point d'observation – de gauche à droite on retrouve respectivement les roses de la campagne 1 (10/06/2021 00H TU au 30/09/2022 23 TU) et de la campagne « 1 et 2 » (du 10/06/2021 00H TU au 09/08/2024 23H TU).

Les deux roses ont des formes très similaires. Aussi la proportion de vent faible reste identique entre la campagne 1 et la campagne « 1 et 2 ». Visuellement, il est difficile de différencier les deux roses.




Illustration 6.2: AO6 Méditerranée zone 1 – Roses des vents de l'extension – campagne 1 (du 01/01/2000 00H TU au 09/06/2021 23H TU)




Illustration 6.3: AO6 Méditerranée zone 1 – Roses des vents de l'extension – campagne « 1 et 2 » (du 01/01/2000 00H TU au 09/06/2021 23H TU)

Concernant les roses des vents des données d'extension, dans l'ensemble elles sont très proches. Visuellement, le secteur 300 à 320° est légèrement différent et la proportion de vents faibles est aussi légèrement inférieure pour la campagne intégrale.

Pour rappel, dans le cadre de **la livraison 2024**, après l'analyse de nombreux indicateurs de qualité, il a été retenu que :

- Pour la force du vent, l'extension statistique (issue de la forêt aléatoire RF_200) est privilégiée pour toutes les plages de force du vent observé compris entre 4 et 20 m/s ($FF \in [4, 20[$ m/s), et AROME pour les forces du vent observé inférieures à 4 m/s et supérieures ou égales à 20 m/s ($FF < 4$ m/s et $FF \geq 20$ m/s).
Donc à l'issue de la campagne intégrale, le seuil de recommandation de la borne inférieure de FF est passé de 3 m/s (pour la campagne 1) à 4 m/s (pour la campagne « 1 et 2 »). D'autre part, le seuil de recommandation de la borne supérieure de FF est passé de 23 m/s (pour la campagne 1) à 20 m/s (pour la campagne « 1 et 2 »). C'est une conséquence de l'augmentation des données (suite au prolongement de la campagne de mesures) qui a une influence sur l'apprentissage. En effet, le modèle statistique RF_200 est légèrement moins ajusté par rapport à l'observation pour les forces du vent extrêmes (forts et faibles) comme mentionné dans le paragraphe 3.3 (au-dessus de l'illustration 3.16).
- Pour la direction, c'est aussi l'extension statistique qui est qualifiée comme modèle le plus approprié pour étendre la série de mesures du LIDAR de la zone 1 de l'AO6 Méditerranée.

7 Annexe 1 : Description des modèles statistiques

Dans cette annexe nous décrivons les modèles statistiques utilisés lors de notre étude préliminaire (cf. Annexe 2 : Étude d'optimisation de la méthode d'extension) : arbre binaire, modèle linéaire général, modèle linéaire avec anamorphose, forêt aléatoire et réseau de neurones.

7.1 Arbre binaire de décision

Cette méthode⁹ statistique est basée sur un découpage, par des hyperplans parallèles aux axes, de l'espace engendré par les variables explicatives. Nommés initialement partitionnement récursif ou segmentation, les développements importants de Breiman et col. (1984) les ont fait connaître sous l'acronyme de CART : Classification and Regression Tree ou encore de C4.5 (Quinlan, 1993) dans la communauté informatique. L'acronyme correspond à deux situations bien distinctes selon que la variable à expliquer, modéliser ou prévoir est qualitative (discrimination ou classification, en anglais) ou quantitative (régression, notre cas).

Les solutions obtenues sont présentées sous une forme graphique simple à interpréter, même pour des néophytes, et constituent une aide efficace pour l'aide à la décision.

Le paramètre de réglage de ce modèle est la règle permettant de décider qu'un nœud est terminal : il devient ainsi une feuille. Ce point est le plus délicat. Il correspond à la recherche d'un modèle parcimonieux. Un arbre trop détaillé, associé à une sur-paramétrisation, est instable et donc probablement plus défaillant pour la prévision d'autres observations.

Un graphique représente la décroissance ou éboulis de la déviance (ou du taux de mal classés) en fonction du nombre croissant de feuilles dans l'arbre. Quand l'amélioration du critère est jugée trop petite ou négligeable, on élague l'arbre au nombre de feuilles obtenues.

Cette méthode ne requière pas d'hypothèse sur les distributions des variables.

Nous utilisons ce modèle essentiellement dans un but exploratoire des données, même si nous proposons une validation de ce modèle.

7.2 Forêt aléatoire

La méthode d'approche est différente et plus coûteuse que celle des arbres binaires de décision. Elle est décrite dans le paragraphe 2.3.1 du corps de ce rapport.

7.3 Modèle linéaire général

Cette méthode¹⁰ cherche à exprimer l'espérance d'une variable réponse Y (qui est équivalente à sa moyenne, ou plus précisément sa moyenne attendue) en fonction d'une combinaison linéaire des variables explicatives X^i et d'un terme d'erreur (*i.e.*, de bruit) non contrôlé qui doit impérativement suivre une distribution normale et de même variance.

7.4 Modèle linéaire avec anamorphose

Cette méthode¹¹ utilise une régression linéaire multiple barycentrique avec les contraintes fortes sur les coefficients du modèle qui doivent être soit tous positifs soit tous négatifs. La routine DLSEI de la librairie

9 Référence : <https://www.math.univ-toulouse.fr/~besse/Wikistat/pdf/st-m-app-cart.pdf>

10 Référence : www.math.univ-toulouse.fr/~besse/Wikistat/pdf/st-m-modlin-mlg.pdf

11 Référence : <https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&ved=2ahUKewjB0qDT1uD0AhWF4YUKHdEYB1kQFnoECAMQAO&url=http%3A%2F%2Fwww.math.u-bordeaux.fr%2F~bbercu%2FEvent%2FEDEFWorkshop%2FTalkEDFFarges.pdf&usq=AOvVaw3Ldkf4XFpK9xCyYHjfFISh>

mathématique SLATEC est utilisée pour résoudre cette contrainte. Le modèle est établi par succession de 2 apprentissages.

Tout d'abord la variable à prédire (l'observation) est transformée en une distribution gaussienne à travers l'application d'une loi de Weibull et d'une loi normale aux données d'observations.

Ensuite, un premier apprentissage est réalisé sur chacune des variables FF, FXI, T et TKE... (une régression par variable) en utilisant comme prédicteur pour une variable donnée, les points de grilles voisins du site considéré comme prédicteur. Parmi des milliers de points à moins de 100 km autour du point central, 16 points sont sélectionnés comme prédicteurs pour participer à la régression de ce premier apprentissage. En effet, les prédicteurs sont classés en utilisant le critère de maximisation du coefficient de corrélation multiple. La sélection des 16 prédicteurs est effectuée en prenant les premiers de ce classement.

Le second apprentissage est réalisé par la suite sur les prédictions du premier apprentissage. Ce sont donc les prédictions issues de la régression de chaque variable FF, FXI, T et TKE... qui sont utilisées comme prédicteurs de cette deuxième régression.

7.5 Réseau de neurones

7.5.1 Réseau multicouche

Le modèle de réseau de neurones est basé sur une représentation schématisée des neurones biologiques. Les neurones font partie d'un réseau structuré organisé en couches tout en ayant un échange d'information entre les couches. Le modèle a pour vocation d'entraîner un réseau avec des données disponibles afin d'avoir la meilleure corrélation possible entre les données d'entrée et celles estimées. Il existe plusieurs modèles de réseaux de neurones, dont le perceptron à une couche et le perceptron multicouche. Pour modéliser des phénomènes complexes, les réseaux les plus utilisés sont les réseaux multicouches. Ce sont ces réseaux qui sont utilisés dans notre cas d'études.




Illustration 7.1: Réseau de neurones multi-couches

La figure de l'illustration 7.1 montre un réseau multicouche. La couche d'entrée est constituée de toutes les données d'entrées du modèle : nombre de neurones égal à nombre de variables d'entrées du modèle (chacun étant connecté à un seul neurone de la couche d'entrée).

Ensuite, chaque neurone j reçoit une série de signaux (sorties) des neurones i situés aux couches précédentes. Le fonctionnement du réseau est dirigé par la formule suivante :

$$Z_j = \sum_{i=1}^{n_i} W_{ij} \cdot X_i + b_j .$$

Les W_{ij} représentent les poids (pondérations) respectifs des connexions entre les neurones i de la couche précédente et les neurones j de la couche actuelle. Les b_j sont des biais additionnés à la somme des pondérations pour produire un résultat intermédiaire. Ce résultat est ensuite modulé par une fonction de transfert f (ou fonction d'activation), puis transmis aux neurones de la couche suivante. La fonction d'activation f permet de relier la sortie O_j d'un neurone donné à la formule de pondération Z_j :

$$O_j = f(Z_j).$$

Il en existe plusieurs types, leurs rôles étant de délinéariser la sortie d'un neurone, permettant ainsi de modifier spatialement la représentation des données et d'avoir par la suite une nouvelle approche sur des données.

Ainsi, ce processus se répète jusqu'à la couche de sortie. Cependant, la couche de sortie comporte toujours autant de neurones que de variables à prédire.

Finalement pour contrôler la sortie du réseau de neurones dans la phase d'apprentissage, la distance entre les valeurs de sortie et les valeurs attendues (valeurs à prédire) est mesurée par la fonction de perte (loss fonction) aussi appelé fonction de coût :

$$E = \frac{1}{2n} \times \sum_{k=1}^n (Y_k - \hat{Y}_k)^2 .$$

où Y_k représente la valeur observée et $\hat{Y}_k$ la valeur estimée, n est le nombre de données et E l'erreur globale mesurée.

L'erreur mesurée est aussitôt propagée dans le réseau pour ajuster les poids W_{ij} . Cette technique couramment utilisée dans la mise en place des réseaux multicouches est connue sous le nom de technique de rétro-propagation du gradient. L'algorithme de descente du gradient de l'erreur a pour but de minimiser la fonction de coût, en convergeant de manière itérative vers une configuration optimale des poids de chaque connexion du réseau.

Il existe plusieurs algorithmes pour réaliser la descente du gradient. On les appelle **Optimizer** dans l'implémentation Keras. Parmi ces algorithmes, nous utilisons notamment les optimiseurs :

- **SGD** : Stochastic Gradient Descent, qui est une méthode de descente de gradient utilisant des échantillons sélectionnés au hasard au lieu de l'ensemble des données pour chaque itération dans le processus de descente.
- **Adam** : qui est aussi une méthode de descente de gradient stochastique basée sur l'estimation adaptative des moments du premier et du second ordre.
- **RAdam** : Rectified Adam, est une variante de l'algorithme Adam introduisant un terme pour rectifier la variance du taux d'apprentissage adaptatif.

Tous ces algorithmes de descente du gradient sont implémentés dans Keras. Cependant, il n'y en a pas vraiment un meilleur que l'autre. Cela dépend surtout du problème à traiter ainsi que de la configuration du réseau dans lequel ils sont utilisés.

Le schéma de la figure 7.2 est une illustration du processus de fonctionnement de la fonction de perte ainsi que de la mise à jour des paramètres du réseau.




Illustration 7.2: Processus de fonctionnement de la fonction de perte et de la mise à jour des paramètres du réseau

7.5.2 Entraînement du réseau

Une fois le prototype du modèle défini, il est important de régler les **hyperparamètres** (paramètres réglés pendant les exécutions successives de l'entraînement du modèle) dans la phase d'apprentissage. Les paramètres les plus importants à ajuster sont entre autres :

- le nombre de couches du modèle ainsi que le nombre de neurones dans chaque couche,
- le choix de la fonction d'activation pour chaque couche,
- le choix de l'Optimizer ainsi que les différents paramètres d'entraînement notamment le taux d'apprentissage (**Learning Rate** ou LR), le nombre d'itérations (ou **Epochs**), et la taille du lot (également appelé le **Batch Size**).

En effet, en pratique la descente du gradient se fait par lot (appelé batch) constitué de mini-lots (aussi appelé mini-batch). Il est bien plus efficace de calculer la perte pour un mini-lot que pour l'ensemble entier des données d'apprentissage.

- **Un Batch (ou lot)** : est l'ensemble d'exemples utilisés dans une itération de l'entraînement du modèle (aussi appelé Epochs), c'est-à-dire pour une mise à jour du gradient. En principe il est constitué de mini-batch qui prennent leurs valeurs dans l'intégralité du jeu de donnée d'entraînement.

- **Un mini-batch (ou mini-lot)** : est un petit sous-ensemble, sélectionné aléatoirement, du lot complet d'exemples (intégralité des données d'apprentissage) exécutés simultanément dans une même itération d'apprentissage. En pratique, on ne le choisit pas directement, il se déduit directement de la taille du lot qu'on aurait défini au préalable.

- **Le Batch Size (ou taille du lot)** : est le nombre d'exemples (échantillon) présenté au modèle. En fonction de la taille définie, chaque lot est constitué de façon aléatoire et propagé dans le réseau.

Par exemple, si on dispose de 3750 données dans le jeu d'entraînement, en configurant un Batch Size égale à 250, pour chaque itération (Epochs), l'algorithme va décomposer les 3750 données en 15 mini-lots puis entraîner le réseau successivement avec chaque mini-lot jusqu'à ce que tous les échantillons se propagent dans le réseau.

- **Epochs (ou itération)** : est le cycle d'apprentissage complet sur l'intégralité de l'ensemble de données de manière à ce que chaque exemple ait été vu une fois par le modèle.

- **Learning Rate (ou taux d'apprentissage)** : est une grandeur scalaire (généralement comprise entre 0 et 1) utilisée pour entraîner le modèle via la descente de gradient. À chaque itération, l'algorithme de descente du gradient multiplie le taux d'apprentissage par le gradient. Le produit ainsi généré est appelé pas de gradient. En pratique, il pilote la vitesse de convergence de la descente du gradient. D'une part, plus sa valeur est faible, plus la convergence est lente (mais sécurisée).

D'autre part, plus sa valeur est élevée, plus la convergence est rapide (mais au risque de diverger). Il faut donc trouver un compromis.

Très concrètement une fois qu'on a fixé le nombre de couches et de neurones dans la couche, on joue sur le Learning Rate, le Batch Size et le nombre d'Epochs pour avoir un réseau optimal (compromis entre convergence, temps de calcul et complexité du modèle) en examinant la courbe d'apprentissage. En effet, la courbe d'apprentissage donne une indication sur l'état d'apprentissage du modèle : modèle bien ajusté, en sur-apprentissage ou en sous apprentissage.

Si l'entraînement ne conduit pas à un modèle bien ajusté, on réajuste les paramètres du modèle jusqu'à trouver le modèle optimal.

8 Annexe 2 : Étude d'optimisation de la méthode d'extension

8.1 Préambule

Pour étudier le potentiel éolien des sites d'implantation, les études réalisées pour la DGEC se font généralement en utilisant 1 an (voire moins d'un an comme le cas de la livraison intermédiaire de l'AO4 Normandie) de données d'observations horaires de vent issue de campagne de mesures. Ces données d'observations sont ensuite étendues (en utilisant des modèles statistiques) sur une période reconstituée autour de 20 ans selon la profondeur de la base de données climatologique AROME de Météo-France.

À travers les expériences des études précédentes pour la DGEC (Dunkerque et Oléron) et de deux nouvelles études élaborées à partir d'une profondeur de données plus longue et décrite ci-dessus, nous cherchons à fiabiliser et optimiser la méthode d'extension à mettre en œuvre pour les futures campagnes de dérisquage éolien off-shore.

En effet, lors des deux premières campagnes de dérisquage pour la DGEC, nous avons pu mettre en évidence l'apport de la modélisation statistique à travers l'utilisation des modèles linéaires généraux et de forêt aléatoire comme méthodes d'extension des séries horaires. Dans cette étude, nous testons un modèle supplémentaire (réseau de neurones), une version du modèle linéaire généralisé par anamorphose gaussienne, une nouvelle méthode de sélection des variables explicatives (ACP) et de nouvelles variables explicatives en ayant comme objectif de pouvoir mettre au point un modèle unique que l'on pourra utiliser dans les études d'extension de série à venir.

8.2 Protocole pour les stations d'études

Pour deux stations de test (dont les noms et les coordonnées resteront confidentiels dans ce rapport mais que l'on nommera « Station de test 1 » et « Station de test 2 » dans la suite), on dispose de plus de 4 ans de mesure (2017-2020) d'observation sodar sur terre. Avec ces données d'observation de vent, on se place dans le même contexte que les études DGEC : on entraîne les modèles statiques uniquement sur 1 an d'observation, ensuite on réalise l'extension (reconstitution de l'observation avec les modèles statistiques grâce aux prédictions des modèles), puis on compare cette extension statistique à l'observation sur la période non apprise. Cela permet ainsi de valider un modèle statistique robuste qui est en mesure d'être au plus proche de l'observation, et d'évaluer par la suite l'erreur commise par ce modèle validé.

L'objectif de cette annexe est de présenter de manière synthétique les résultats des différentes expériences qui ont été faites pour choisir le modèle statistique final pour l'extension.

La plupart des expérimentations ont été réalisées sur les deux stations de test mais pour ne pas alourdir ce rapport, les détails et illustrations sont majoritairement fournis pour la station de test 1 et seul un petit commentaire supplémentaire est ajouté pour la station de test 2.

8.3 Identification du point AROME de référence

Comme décrit dans la méthodologie employée (cf. chapitre 2), avant d'établir les modèles statistiques, on identifie d'abord le point AROME de référence dont les paramètres seront utilisés comme variables explicatives (prédicteurs) des modèles statistiques. Les caractéristiques de vent de ce point doivent donc être les plus proches de celles du point d'observation.

Le choix du point AROME de référence s'effectue en s'appuyant sur les indicateurs de qualité (B95+, voir section 2.2.1 pour la définition) des roses de vent. L'illustration 8.1 présente les roses de vent du point d'observation et des 4 points AROME voisins pour la station de test 1.




Illustration 8.1: Station de test 1 – Roses des vents du point d'observation (doublé sur la colonne du centre) et des 4 points AROME voisins (colonne de gauche et droite) sur la période du 01/01/2017 00H TU au 31/12/2020 23H TU

En visualisant ces roses de vent, globalement, ce sont les points AROME 1 et 4 qui semblent un peu plus proches de l'observation que les points 2 et 3. En effet, les vents du sud sont beaucoup moins bien restitués par les points 2 et 3 que les deux autres points.

Cependant, il est difficile de trancher visuellement la ressemblance des points 1 et 4 par rapport au point d'observation pour les vents du sud. Ce sont donc les scores B95+ qui permettront de faire la différence.

Le tableau suivant présente les scores B95+ des 4 points AROME voisins du point d'observation.

Tableau 8.1: Station de test 1 – Scores B95+ des 4 points AROME voisins du point d'observation (en vert les scores décisifs)

ID	C1	C2	C3	C4 (corrélation circulaire)
Point AROME voisin 1	83.76	85.57	97.62	0.48
Point AROME voisin 2	77.58	80.55	85.03	0.39
Point AROME voisin 3	77.56	78.74	91.79	0.18
Point AROME voisin 4	85.69	86.82	94.72	0.44

On rappelle que le critère C1 est le critère global qui met en contribution les 18 secteurs de la direction du vent (DD) et les 4 classes de la force du vent (FF). Le critère C2 est celui qui permet d'étudier la qualité de la modélisation des fréquences de direction. Il est donc à privilégier pour la mise en évidence de DD. Quant au critère C3, il permet d'étudier la qualité de la modélisation des fréquences de force du vent. C3 est donc favorable pour mettre en évidence FF. Et enfin le critère C4, appliqué uniquement sur la direction du vent, est la corrélation circulaire.

Les points AROME 1 et 4 ont des scores relativement proches l'un de l'autre pour l'ensemble des critères de qualité, ce sont donc les critères favorables à DD (notamment C2) qui ont été décisifs pour le choix du point de référence. Et **c'est le point 4 qui a été choisi comme référence**, car il a un meilleur score C2 que le point 1 avec des corrélations circulaires quasiment identiques.

Le même travail a été réalisé sur la station de test 2, et c'est le point 1 qui a été sélectionné comme référence avec une rose de vent plus proche de l'observation que celle des trois autres points voisins.

Une fois le point AROME de référence sélectionnée, on procède à la modélisation de FF puis de DD.

8.4 Modélisation de la force du vent à 100 m

Les modèles statistiques sont ajustés non pas sur la force du vent FF observé, mais sur son écart avec la force du vent AROME. D'après les expériences antérieures, cela permet de mieux modéliser les valeurs extrêmes qui affectent généralement certains modèles statistiques. Par conséquent, **la variable à prédire est** : $Y = FFmFFARO = FF_{OBS} - FF_{ARO}$.

8.4.1 Sélection des variables explicatives

Une étape importante dans la modélisation de la force du vent (FF) est le choix des variables explicatives. Ce choix est basé sur la connaissance météorologique de l'origine du vent dont plusieurs paramètres sont accessibles en sortie du modèle AROME. Les cycles saisonnier et diurne sont également pris en considération du fait de l'information qu'ils apportent sur la variabilité temporelle du vent.

8.4.1.1 Paramètres calendaires

Du fait de phénomènes météorologiques de plus ou moins grande ampleur (effet de brise, prépondérance des tempêtes en hiver...), la vitesse et la direction du vent varient en fonction de l'heure du jour et du mois de l'année. On cherche donc à établir à partir de l'heure et du mois des observations (et des sorties AROME) des comportements moyens, plus stables sur des plages horaires et saisonnières fixes. Dans le cas des stations de test 1 et 2, nous avons pu dégager les plages suivantes :

- La variable catégorielle notée **RegHH_FF** représente la variable du cycle diurne (illustration 8.2 pour la station de test 1). Elle est composée de 2 facteurs correspondant à 2 plages horaires : [10H – 20H] et [21H – 09H] pour la station de test 1, et [06H – 17H] et [18H – 05H] pour la station de test 2.
- La variable catégorielle notée **RegMM** représente la variable saisonnière. Elle est composée de 4 facteurs correspondants aux 4 saisons météorologiques : Hiver (décembre, janvier, février), Printemps (mars, avril, mai), Été (juin, juillet, août), et Automne (septembre, octobre, novembre). Ce sont les mêmes catégories pour les deux stations.




Illustration 8.2: Station de test 1 – Cycle diurne de la force du vent observée (bleu) et AROME (rouge) de 2017 à 2020.

8.4.1.2 Paramètres météorologiques en sortie AROME

Pour les paramètres accessibles directement en sortie AROME, on examine les liens entre la variable à prédire Y et les variables explicatives X^i , mais aussi entre les variables explicatives. On s'assure donc qu'il y ait assez de corrélation entre Y et chaque X^i , tout en évitant d'avoir une forte corrélation entre les X^i (moins de 0,96). Cela permet d'éviter le problème de colinéarité pour la mise en place des modèles linéaires.

Pour cela, on a donc adopté une technique de sélection des variables explicatives en 2 phases. Tout d'abord on sélectionne toutes les variables explicatives bien corrélées avec la variable à prédire, même si celles-ci sont fortement corrélées entre elles. Ensuite on divise cette première sélection en 2 groupes en dissociant les variables explicatives fortement corrélées entre elles. Le premier groupe de cette dissociation est conservé dans le choix des variables explicatives finales, puis on réalise une analyse en composantes principales (ACP) sur le deuxième groupe afin de réduire sa dimension tout en conservant le maximum d'information, mais aussi de les décorréler avec les variables explicatives du premier groupe déjà admis. Ainsi les variables explicatives finales seront constituées de celles du premier groupe et des composantes principales de l'ACP.

Les variables pré-sélectionnées sont les suivantes :

- **FF** : force du vent AROME à plusieurs niveaux de hauteur. C'est une variable quantitative notée FFARO_NIV où $NIV=\{10, 100, 250, 500\}$ est le niveau de hauteur en mètre auquel elle a été prise en compte,
- **SECTEUR** : direction du vent AROME à 100 mètres par secteur de 20 degrés. C'est une variable catégorielle à 18 facteurs (0, 20, 40... jusqu'à 340, l'intervalle des 20° étant centré sur la valeur des facteurs) notée SECTEURARO_100,
- **T** : température AROME à plusieurs niveaux. Variable quantitative notée TARO_NIV avec $NIV=\{2, 100, 250, 500\}$,
- **PMER** : pression AROME réduite au niveau de la mer. Variable quantitative notée PMERARO,
- **TKE et SQRTKE** : la turbulence AROME au niveau $NIV=\{10, 100, 160\}$. Variable quantitative notée TKEARO_NIV et sa racine carrée notée SQRTKEARO_NIV. On exploite la racine carrée TKE de manière à privilégier un lien linéaire avec la force du vent de l'observation,
- **HU** : humidité AROME relative à 2 mètres. Variable quantitative notée HUARO_2,
- **TPW850** : température pseudo-adiabatique potentielle du thermomètre mouillé AROME à 850 hectopascals. C'est une variable quantitative qui caractérise une masse d'air. Elle est notée TPW850.

8.4.1.2.1 Résultats de l'analyse en composantes principales

Pour la station de test 1, l'ACP a été réalisée sur 11 des variables explicatives préalablement sélectionnées dans le deuxième groupe évoqué ci-dessus. Il s'agit notamment de : FFARO_50, FFARO_500, TARO_50, TARO_100, TARO_250, TKEARO_100, TKEARO_160, SQRTTKEARO_10, SQRTTKEARO_50, SQRTTKEARO_160, et PMERARO. La figure 8.3 montre la part de variance expliquée par l'ACP. Cette figure est associée au tableau 8.2 qui donne le détail pour chaque composante principale.




Illustration 8.3: Station de test 1 – Part de variance expliquée de l'ACP

Tableau 8.2: Station de test 1 – Tableau des variances expliquées par l'ACP (en vert les composantes conservées)

Composante principale	valeur propre	pourcentage de variance (%)	pourcentage de variance cumulative (%)
PC1	5.90673407247875	53.69758247708	53.69758247708
PC2	2.85788353236657	25.9807593851508	79.6783418622308
PC3	1.13247164812364	10.2951968011241	89.9735386633549
PC4	0.656785890026829	5.97078081842577	95.9443194817807
PC5	0.221518742956181	2.01380675414712	97.9581262359278
PC6	0.146704214854232	1.33367468049303	99.2918009164209
PC7	0.0504935297812545	0.459032088920499	99.7508330053414
PC8	0.0147102751125461	0.13372977375042	99.8845627790918
PC9	0.00867267446628389	0.078842495148036	99.9634052742398
PC10	0.00349898393380089	0.0318089448527356	99.9952142190926
PC11	0.000526435899818015	0.00478578090743654	100

Les 5 premières composantes principales expliquent 98 % de la variance des données de l'ACP. À partir de la composante principale 6, la part de variance expliquée est trop faible pour chacun de ces composantes principales. L'analyse a donc retenu les 5 premiers axes factoriels comme dimension intrinsèque des données (les autres dimensions étant considérées comme du bruit). Les composantes principales 1, 2 et 3 sont celles qui résument le maximum d'information avec respectivement 54, 26 et 10 % de la variance des données. Il ne faut cependant pas négliger les composantes 4 et 5 qui, malgré leur part de variance inférieure aux 3 premières, peuvent renfermer de l'information pertinente. Pour cela, il est important de visualiser la contribution de chaque variable pour les axes factoriels de l'ACP. La figure suivante 8.4 montrent la contribution de chaque variable pour chacun des axes factoriels de l'ACP.




Illustration 8.4: Station de test 1 – FF – Contribution des variables à l'ACP (une figure pour chaque dimension)

La figure 8.4 permet d'avoir un aperçu de la contribution de chaque variable sur chacun des axes factoriels. Les contributions des variables dans la définition d'un axe principal donné, sont exprimées en pourcentage. Les lignes en pointillées rouges sur les graphiques de l'illustration 8.4 indiquent la contribution moyenne attendue. **Si la contribution des variables était uniforme, la valeur attendue serait $1/\text{length}(\text{variables})=1/11=9\%$** . Pour une composante donnée, une variable avec une contribution supérieure à ce seuil peut être considérée comme importante pour contribuer à la composante.

On s'aperçoit que la moitié des variables de l'ACP ont une contribution au-delà de la moyenne pour la définition de la première dimension (avec une corrélation plutôt forte pour la turbulence AROME et sa racine carrée). La deuxième dimension montre une bonne corrélation des températures AROME avec cet axe. La troisième dimension est plutôt liée à la force du vent AROME et à la pression AROME réduite au niveau de la mer. Quant à la quatrième dimension, elle est liée uniquement à 2 variables de manière significative : la pression AROME réduite au niveau de la mer (qui contribue à plus de 67 %), et la force du vent AROME au niveau 500 mètres. Plusieurs variables contribuent également à la définition de la cinquième dimension, notamment la force du vent AROME et la turbulence AROME et sa racine carrée. Elle n'est donc pas à négliger, cependant l'interprétabilité de cet axe (ainsi que de tous les autres axes factoriels) dépendra de la qualité de représentation des variables sur celui-ci.

Pour mieux apprécier la qualité de la représentation et la proximité des variables sur chaque axe factoriel, on a représenté chaque variable sur tous les plans factoriels (cercle de corrélation des variables) comme le montre les deux figures suivantes (illustrations 8.5 et 8.6).




Illustration 8.5: Station de test 1 – FF – Représentation des variables sur les plans factoriels de l'ACP (première partie des plans) : première ligne dimension 1-2, dimension 1-3 et dimension 1-4 ; deuxième ligne dimension 1-5, dimension 2-3, et dimension 1-2 (à nouveau)




Illustration 8.6: Station de test 1 – FF – Représentation des variables sur les plans factoriels de l'ACP (deuxième partie des plans) : première ligne dimension 2-4, dimension 2-5 et dimension 3-4 ; deuxième ligne dimension 3-5, dimension 4-5, et dimension 1-2

Sur le cercle de corrélation, la qualité de représentation des variables est donnée par le cosinus carré (noté $\cos^2$) :

- Un $\cos^2$ élevé (proche de 1) indique une bonne représentation de la variable sur les axes principaux en considération. Dans ce cas, la variable est positionnée à proximité de la circonférence du cercle de corrélation.
- Un faible $\cos^2$ (proche de 0) indique que la variable n'est pas parfaitement représentée par les axes principaux. Dans ce cas, la variable est proche du centre du cercle.

Ainsi, en tenant compte de la qualité de représentation des variables et de leurs contributions pour chaque axe factoriel, les plans les plus pertinents à interpréter sont les plans constitués par : l'axe 1 et 2 (Dim1-Dim2), l'axe 1 et 3 (Dim1-Dim3), l'axe 2 et 3 (Dim2-Dim3), l'axe 3 et 4 (Dim3-Dim4).

- Le premier plan (axes factoriels 1 et 2) explique 80 % de la variance des données. Il montre une bonne corrélation entre les TKE et SQRTKE qui sont plutôt liées à l'axe 1, et une bonne corrélation entre les températures AROME qui sont liées aux 2 axes mais un peu plus à l'axe 2 qu'à l'axe 1.
- Le second plan (axes factoriels 1 et 3, avec 64 % de l'inertie des données) confirme toujours la bonne corrélation des TKE et SQRTKE liées à l'axe 1. Par ailleurs, il oppose (en termes de comportement) les forces du vent AROME à la PMER (qui sont tous bien liées aux 2 axes).
- Le plan constitué par l'axe 2 et 3 explique quant à lui 36 % de la variance des données. Il confirme d'une part la bonne corrélation des températures AROME (liées à l'axe 2), d'autre part l'opposition entre PMER et FF.
- Le plan constitué par l'axe 3 et 4 avec 16 % de l'inertie des données, fait ressortir uniquement l'opposition entre les variables FF et PMER. En effet, ces variables ont une liaison plutôt bonne avec les 2 axes.
- Et enfin comme évoqué plus haut, l'axe 5 ne doit pas non plus être négligé malgré ses 2 % de variance expliquée. En effet, dans tous les plans pour lesquels il intervient, les phénomènes que l'on vient d'évoquer se vérifient par rapport à l'axe auquel il est associé, notamment : que les TKE et SQRTKE sont fortement corrélées entre eux (axe 1), que les températures AROME sont fortement corrélées entre elles (axes 2), que FF et PMER ont des comportements opposés (axe 3), que PMER est fortement lié à l'axe 4 (axe 4).

On pourrait se demander si les trois premières composantes principales n'auraient pas suffi pour expliquer les données de l'ACP. Mais l'arbre binaire plus tard, permet de confirmer la pertinence des composantes principales jusqu'au cinquième.

Le travail a été réalisé pour les deux stations de test. Il montre que les deux stations se comportent de façon similaire. **Finalement, nous conservons donc 5 potentielles variables explicatives supplémentaires (PC1 à PC5) qui sont ajoutées aux autres variables explicatives du premier groupe.**

8.4.1.2.2 Sélection finale des paramètres accessibles en sortie AROME

Maintenant qu'on est sûr de récupérer de l'information dans les données à travers l'ACP, on peut donc intégrer les composantes principales (notés PC1_FF, PC2_FF, PC3_FF, PC4_FF et PC5_FF, contenant les coordonnées des individus sur les différents axes factoriels) aux potentielles variables explicatives.

Les figures suivantes (illustrations 8.7 à 8.9) présentent la corrélation entre la variable à prédire et les variables explicatives pour chacune des 2 phases de la sélection préalablement mentionnées.




Illustration 8.7: Station de test 1 – Premier groupe (variables explicatives conservées pour la sélection finale) pour la prédiction de FF




Illustration 8.8: Station de test 1 – Deuxième groupe (variables de l'ACP) pour la prédiction de FF




Illustration 8.9: Station de test 1 – Variables explicatives finales (avec les composantes principales de l'ACP) pour la prédiction de FF

Au final, on se retrouve avec 17 potentielles variables explicatives qui seront utilisées pour établir les modèles statistiques (modèles linéaires, arbre binaire, forêts aléatoires, réseaux de neurones). Il s'agit notamment de 12 variables issues ou calculées du modèle AROME et des 5 composantes principales de l'ACP.

Les potentielles variables explicatives de la station de test 1 sont : RegMM, RegHH_FF, SECTEURARO_100, FFARO_10, FFARO_100, FFARO_250, TARO_2, TARO_500, SQRTTKEARO_100, HUARO_2, TKEARO_10, TPWARO_850, PC1_FF, PC2_FF, PC3_FF, PC4_FF et PC5_FF.

Pour la seconde station, nous avons également 17 potentielles variables explicatives à l'issue de cette sélection : RegMM, RegHH_FF, SECTEURARO_100, FFARO_100, FFARO_250, TARO_2, TARO_50, TKEARO_100, SQRTTKEARO_10, HUARO_2, PMERARO, TPWARO_850, PC1_FF, PC2_FF, PC3_FF, PC4_FF, PC5_FF.

8.4.2 Échantillonnage

L'échantillonnage est très important dans le processus de validation d'un modèle statistique. Pour valider les modèles statistiques définis, nous utilisons la technique de **validation croisée** qui consiste à itérer l'estimation de l'erreur sur plusieurs échantillons de validation puis d'en calculer la moyenne.

Dans la définition des modèles statistiques, **l'année choisie pour l'apprentissage des données est 2017** pour la station de test 1. Le choix de cette année découle de l'analyse de la distribution du vent AROME en

comparaison avec l'observation. L'année 2017 présente aussi beaucoup plus de données que les autres années.

Les données de cet échantillon (2017) sont ainsi séparées en 2 sous-échantillons :

- Un sous-échantillon d'apprentissage constitué par 70 % des données initiales pour ajuster les modèles statistiques. Pour le tirage de ces 70 %, les données initiales sont d'abord séparées en 4 groupes selon leur appartenance aux 4 classes (hiver, printemps, été, automne) de la variable définissant le cycle saisonnier (RegMM). Ainsi, **70 % des données de chaque classe est tirée aléatoirement** (l'idée étant d'avoir les données d'hiver, du printemps, d'été et d'automne à parts égales dans chaque échantillonnage).
- Un sous-échantillon de test constitué par le reste des données non choisies dans le sous-échantillon d'apprentissage. Ces données sont donc constituées de 30 % des données de chaque classe (hiver, printemps, été, automne).

Le processus est itéré 20 fois afin d'avoir un sous-échantillon d'apprentissage et de test différent à chaque itération.

Il en est de même pour la station de test 2 sauf que l'apprentissage a été réalisé sur 2018 pour cette station.

8.4.3 Études des modèles statistiques

Les modèles statistiques sont tous ajustés sur le même échantillon et évalués par validation croisée. Les scores et critères de qualité intervenant dans la validation des modèles sont les suivants : RMSE, ECT, BIAIS, MAE, PSS, FA, BIC¹², les courbes de fiabilité QQ-Plot et les corrélations (cf. section 2.3.4 pour leur définition).

Pour PSS et FA, ces scores sont calculés à 3 niveaux de seuils : PSS1 et FA1 pour la détection des vents faibles ($FF > 3 m/s$), PSS2 et FA2 pour la détection des vents moyens ($FF > 9 m/s$), et PSS3 et FA3 pour la détection des vents forts ($FF > 12 m/s$).

Une fois la 4^e étape de la méthode décrite à la section 2.3.2 appliquée à chaque modèle statistique, 4 nouvelles étapes sont mises en œuvre :

1. Comparaison des modèles optimaux (un par méthode) obtenus par estimation de l'erreur de prévision sur l'échantillon test.
2. Choix de la méthode retenue en fonction de ses capacités de prévision, de sa robustesse mais aussi, éventuellement, de l'interprétabilité du modèle obtenu.
3. Ré-estimation du modèle avec la méthode, le modèle et sa complexité optimisée à l'étape précédente sur l'année entière de données d'observation (au lieu de 70 % de ces données).
4. Exploitation du modèle sur la base complète et de nouvelles données.

On rappelle que **la variable à prédire est : $Y = FFmFFARO = FF_{obs} - FF_{ARO}$** pour tous les modèles statistiques testés. On présente ci-après les résultats des tests d'apprentissages pour toutes nos expérimentations : arbres binaires, forêt aléatoire, modèle linéaires puis réseau de neurones.

8.4.3.1 Les arbres binaires de décision

Tout d'abord, il faut noter que l'arbre binaire ne permet pas d'avoir une prédiction continue de la variable à expliquer. Il permet surtout de comprendre plus ou moins le rôle de chacune des variables explicatives ainsi que la contribution en cascade des éléments de l'arbre. Cela permet donc d'avoir une appréciation supplémentaire concernant le choix des variables explicatives établi dans la phase exploratoire (cf § 8.4.1.2.2). Ce modèle a donc été établi sur l'échantillon tout entier (année d'apprentissage 2017 pour la station de test 1 et 2018 pour la station de test 2).

12 Indicateur permettant de qualifier la qualité d'ajustement d'un modèle linéaire général.




Illustration 8.10: Station de test 1 – FF –Modèle d'arbre de décision (arbre optimal)

Pour la définition du modèle, on part d'un arbre avec le plus de branches possibles, puis on cherche à optimiser sa taille et à l'élaguer par la suite. Le paramètre de complexité de l'arbre (cp) minimisant l'erreur estimée sur l'échantillon d'apprentissage vaut $cp = cp_{optim} = 0.003546972$. Une fois l'arbre élagué à travers l'utilisation de ce paramètre, le modèle final (optimal) est un arbre constitué de 22 nœuds comme le montre le graphique 8.10.

Les données se séparent à plusieurs niveaux de l'arbre autour de la force du vent et de la composante principale 5 de l'ACP. Ces variables ont donc une grande importance. Les variables génératrices de séparation des données dès le haut de l'arbre (tel que HUARO) ont également une grande importance.

L'indice d'importance fournit un classement des variables (de la plus importante à la moins importante). Il permet de ne retenir uniquement les variables explicatives permettant d'obtenir une meilleure prédiction. Le tableau 8.3 ci-dessous présente ainsi l'importance des variables (par ordre croissant d'importance de gauche à droite) fourni par le modèle pour la station de test 1.

Tableau 8.3: Station de test 1 – FF – Importance des variables explicatives pour l'arbre binaire de décision

Variable	RegM M	PC4_F F	PC2_F F	TARO_ 500	TPWA RO_85 0	RegHH _FF	PC3_F F	SECTE URAR O_100	TARO_ 2	TKEAR O_10	SQRTT KEARO _100	HUAR O_2	PC1_F F	PC5_F F	FFARO _10	FFARO _250	FFARO _100
Importance	15.92	60.07	89.58	140.33	153.23	197.13	211.1	220.98	364.02	495.85	537.15	602.28	604.48	622.29	656.89	1029.4 2	1084.7 4

Pour la station de test 2, la force du vent et la composante principale 5 de l'ACP (PC5_FF) s'illustrent à nouveau avec une plus grande importance pour le modèle. Cependant, pour cette station, les autres variables d'importance sont la direction du vent SECTEURARO_100, et la turbulence AROME ainsi que sa racine carrée. Le tableau 8.4 présente l'importance des variables pour la station de test 2.

Tableau 8.4: Station de test 2 – FF – Importance des variables explicatives pour l'arbre binaire de décision

Variable	HUA RO_2	RegHH _FF	TPWA RO_85 0	PC3_F F	TARO_ 50	PC2_F F	TARO_ 2	PMER ARO	PC4_F F	RegM M	PC1_F F	TKEAR O_100	SQRTT KEARO O_10	FFARO _250	FFARO _100	SECTE URAR O_100	PC5_F F
Importance	17.98	35.99	221.48	266.12	322.17	326.4	344.15	374.84	455.26	827.25	836.21	929.64	1045.1 5	1079.7 5	1487.9 7	1744.3 4	2201.4 5

8.4.3.2 AROME brut et les modèles linéaires

Plusieurs modèles linéaires ont été testés afin de sélectionner par la suite celui ou ceux qui donnent les meilleures estimations.

Le modèle **brut** est défini par la force du vent AROME à 100 m noté **AROME.BRUT**.

Quant aux modèles linéaires, 7 modèles ont été définis (avec des niveaux de complexité différents) et ayant tous *FFmFFARO* comme variable à prédire. Ce sont donc les variables explicatives qui diffèrent pour chaque modèle linéaire donné. Il s'agit notamment du LM0, GLM, GLM.STEP, GLM_PCA, GLM_PCA.STEP, GLM_MIXTE et GLM_MIXTE.STEP. Par exemple pour la station de test 1, on a :

- **Modèle nommé LM0** : c'est le modèle linéaire simple qui a seulement la force du vent AROME comme prédicteur. On a donc $FFmFFARO = f(FFARO_100)$.
- **Modèle GLM** : c'est le modèle dont les prédicteurs sont ceux du premier groupe évoqué dans la phase exploratoire (§ 8.4.1.2.2 de la sélection des variables explicatives) associés aux variables de prise en compte de l'heure et du mois (RegHH_FF et RegMM). Ces dernières interviennent dans tous les autres modèles linéaires par la suite. On a donc $FFmFFARO = f(RegHH_FF, RegMM, SECTEURARO_100, FFARO_10, FFARO_100, FFARO_250, TARO_2, TARO_500, SQRTTKEARO_100, HUARO_2, TKEARO_10, TPWARO_850)^2$. Le carré (^2) dans l'expression désigne l'interaction 2 à 2 des prédicteurs.
- **Modèle GLM.STEP** : c'est le modèle établi à partir de la sélection automatique des interactions significatives des prédicteurs du modèle GLM ci-dessus.
- **Modèle GLM_PCA** : c'est le modèle dont les prédicteurs sont uniquement les composantes principales de l'ACP associées aux variables de prise en compte de l'heure et du mois. On a $FFmFFARO = f(RegHH_FF, RegMM, PC1_FF, PC2_FF, PC3_FF, PC4_FF, PC5_FF)^2$.
- **Modèle GLM_PCA.STEP** : comme pour le GLM, il s'agit du modèle établi à partir de la sélection automatique des interactions significatives des prédicteurs de GLM_PCA.
- **Modèle nommé GLM_MIXTE** : c'est le modèle ayant comme prédicteurs ceux du modèle GLM plus les composantes principales de l'ACP. $FFmFFARO = f(RegHH_FF, RegMM, SECTEURARO_100, FFARO_10, FFARO_100, FFARO_250, TARO_2, TARO_500, SQRTTKEARO_100, HUARO_2, TKEARO_10, TPWARO_850, PC1_FF, PC2_FF, PC3_FF, PC4_FF, PC5_FF)^2$.
- **Modèle GLM_MIXTE.STEP** : modèle issu de la sélection automatique des interactions significatives des prédicteurs de GLM_MIXTE.

Les deux modèles GLM_PCA et GLM_PCA.STEP ont été introduits non pas pour être choisis comme modèle d'extension des séries horaires, mais pour constater l'apport d'information des variables issues de l'ACP (notamment par rapport à AROME.BRUT).

Les graphiques 8.11 à 8.14 montrent respectivement les scores de qualité (RMSE, ECT, BIAIS, MAE, PSS et FA) des différents modèles (évalués par validation croisée) sur l'échantillon d'apprentissage et de test. Sur chacun des graphiques, les modèles sont positionnés dans cet ordre : LM0, GLM, GLM.STEP, GLM_PCA, GLM_PCA.STEP, GLM_MIXTE et GLM_MIXTE.STEP.




Illustration 8.11: Station de test 1 – FF – Modèles linéaires et AROME.BRUT - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon d'apprentissage




Illustration 8.12: Station de test 1 – FF – Modèles linéaires et AROME.BRUT - Box-plot PSS (première ligne pss > 3 m/s, pss > 9 m/s et pss > 12 m/s noté respectivement pss1, pss2 et pss3) et FA (deuxième ligne fa > 3 m/s, fa > 9 m/s et fa > 12 m/s notée respectivement fa1, fa2 et fa3) pour l'échantillon d'apprentissage




Illustration 8.13: Station de test 1 – FF – Modèles linéaires et AROME.BRUT - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test




Illustration 8.14: Station de test 1 – FF – Modèles linéaires et AROME.BRUT - Box-plot PSS et FA pour l'échantillon de test

Dans tous les cas (apprentissage, test) les modèles linéaires améliorent AROME.BRUT. Une amélioration plus prononcée pour les modèles GLM, GLM_MIXTE et leur STEP que pour le modèle linéaire simple et les modèles avec ACP.

Le tableau 8.5 récapitule les **scores de validation croisée** sur l'échantillon d'apprentissage.

Tableau 8.5: Station de test 1 – FF – Modèles linéaires et AROME.BRUT - Scores de validation croisée sur l'échantillon d'apprentissage (en bleu les modèles avec les meilleurs scores)

Modèle	RMSE	ECT	BIAIS	MAE	PSS1	FA1	PSS2	FA2	PSS3	FA3
LM0	1.334	1.334	0	1.002	0.728	0.144	0.698	0.027	0.501	0.005
GLM	1.113	1.113	0	0.836	0.77	0.128	0.722	0.023	0.692	0.006
GLM.STEP	1.179	1.179	0	0.879	0.754	0.137	0.702	0.025	0.623	0.006
GLM_PCA	1.253	1.253	0	0.933	0.743	0.137	0.688	0.023	0.535	0.006
GLM_PCA.STEP	1.262	1.262	0	0.939	0.738	0.14	0.685	0.023	0.5	0.006
GLM_MIXTE	1.068	1.068	0	0.806	0.781	0.121	0.721	0.022	0.729	0.005
GLM_MIXTE.STEP	1.151	1.151	0	0.86	0.761	0.134	0.705	0.024	0.631	0.006
AROME.BRUT	1.389	1.36	-0.282	1.038	0.704	0.208	0.694	0.025	0.452	0.004

Les scores d'apprentissage sont plutôt favorables aux modèles GLM et GLM_MIXTE avec un léger avantage pour le GLM_MIXTE. Cependant pour l'apprentissage, les scores sont appliqués à l'échantillon qui a été utilisé pour construire les modèles. Il est donc important de confronter ces scores à ceux des échantillons tests (les modèles n'ayant pas encore vu les données de test).

En examinant les scores de test des illustrations 8.13 et 8.14, l'avantage revient aux 2 modèles GLM et GLM_MIXTE.STEP. Mais il est très difficile de les départager visuellement avec les graphiques (les scores étant du même ordre de grandeur). On note que le GLM_MIXTE.STEP possède un meilleur score que le GLM pour la détection des vents faibles (PSS et FA supérieur à 3 m/s). D'un autre côté, il est moins bon que le GLM pour la détection de vent fort (PSS et FA supérieur à 12 m/s). Ainsi, ces critères ne permettent pas de les départager. La différence va donc se faire au niveau des scores BIC et des scores de corrélation (pearson, kendall et spearman).

Le tableau 8.6 présente les **scores par validation croisée sur l'échantillon de test**, le critère BIC pour chaque modèle linéaire ainsi que les corrélations.

Tableau 8.6: Station de test 1 – Modèles linéaires et AROME.BRUT - Scores de validation croisée sur l'échantillon de test (en bleu et vert, les modèles avec les meilleurs scores)

Modèle	RMSE	ECT	BIAIS	MAE	PSS1	FA1	PSS2	FA2	PSS3	FA3	BIC	Cor Pearson	Cor Kendall	Cor Spearman
AROME.BRUT	1.396	1.366	-0.288	1.047	0.703	0.21	0.699	0.024	0.482	0.005		0.88	0.7	0.87
LM0	1.342	1.341	-0.007	1.011	0.731	0.143	0.705	0.026	0.53	0.006	19614	0.88	0.7	0.87
GLM	1.208	1.207	-0.01	0.9	0.754	0.142	0.7	0.023	0.644	0.008	19614	0.91	0.73	0.9
GLM.STEP	1.205	1.205	-0.008	0.894	0.756	0.14	0.708	0.024	0.582	0.008	17673	0.91	0.73	0.9
GLM_PCA	1.272	1.272	-0.005	0.948	0.745	0.138	0.686	0.022	0.531	0.008	18465	0.9	0.72	0.89
GLM_PCA.STEP	1.278	1.278	-0.005	0.951	0.74	0.141	0.692	0.022	0.503	0.008	18337	0.89	0.71	0.89
GLM_MIXTE	1.217	1.217	-0.007	0.902	0.756	0.14	0.701	0.023	0.621	0.007	20573	0.9	0.73	0.9
GLM_MIXTE.STEP	1.192	1.192	-0.004	0.884	0.76	0.138	0.7	0.024	0.585	0.008	17673	0.91	0.74	0.91

L'analyse du tableau des scores nous permet de dire que le modèle GLM_MIXTE.STEP est le meilleur des modèles linéaires. En effet, il a un meilleur score BIC que le GLM, les scores de corrélation étant quasiment identiques pour les 2 modèles. On rappelle que le score BIC est le critère d'information bayésien. Son calcul dépend de la taille de l'échantillon et du nombre de paramètres du modèle statistique. Plus il est petit, meilleur est le modèle.

Cependant, on garde en tête que le modèle GLM_MIXTE.STEP a un score de détection des vents forts (FF>12 m/s) un peu moins bon que le GLM. Par conséquent **à ce stade, on garde les 2 modèles GLM_MIXTE.STEP et GLM** en attendant la comparaison inter-modèles où l'analyse des courbes de fiabilité QQ-Plot et la restitution des cycles annuels et diurnes pourraient faire la différence entre les modèles.

La même méthode a été appliquée pour la station de test 2 et nous avons obtenu des résultats similaires, c'est-à-dire les deux modèles GLM et GLM_MIXTE.STEP donnent des scores meilleurs dans l'ensemble que les autres modèles linéaires.

8.4.3.3 Les forêts aléatoires

Plusieurs modèles de forêts aléatoires ont été testés avec différents niveaux d'arbres. Pour choisir le modèle optimal, on optimise le nombre d'arbres dans la forêt de sorte que les estimations du modèle soient optimales, tout en restant un modèle parcimonieux.

Pour ces modèles, nous utilisons l'ensemble des 17 variables explicatives (voir section 8.4.1.2.2).

Les figures suivantes (illustrations 8.15 à 8.18) présentent les scores de validation croisée (apprentissage, test) des modèles avec les différents niveaux d'arbres.

Les modèles RFA, RFB, RFC, RFD et RFE correspondent respectivement aux modèles de forêt aléatoire à 20, 50, 100, 200 et 500 arbres.




Illustration 8.15: Station de test 1 – FF – Modèles de forêt aléatoire à 20, 50, 100, 200 et 500 arbres - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon d'apprentissage




Illustration 8.16: Station de test 1 – FF – Modèles de forêt aléatoire à 20, 50, 100, 200 et 500 arbres - Box-plot PSS (première ligne $pss > 3$ m/s, $pss > 9$ m/s et $pss > 12$ m/s) et FA (deuxième ligne $fa > 3$ m/s, $fa > 9$ m/s et $fa > 12$ m/s) pour l'échantillon d'apprentissage




Illustration 8.17: Station de test 1 – FF – Modèles de forêt aléatoire - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test




Illustration 8.18: Station de test 1 – FF – Modèles de forêt aléatoire - Box-plot PSS et FA pour l'échantillon de test

Les scores des modèles RFC, RFD et RFE sont très proches les uns des autres (aussi bien pour l'apprentissage que pour le test). Ils sont meilleurs que ceux des 2 autres modèles (RFA et RFB qui ont un nombre inférieur d'arbres). Sachant que l'évolution des scores est très minime à partir du modèle RFC (100 arbres) malgré l'augmentation importante du nombre d'arbres, **nous avons décidé de conserver le modèle RFC soit 100 arbres pour le choix du modèle de forêt aléatoire**. Les tableaux 8.7 et 8.8 présentent le récapitulatif des scores de validation croisée sur l'échantillon d'apprentissage puis de test pour la station de test 1.

Tableau 8.7: Station de test 1 – FF – Modèles de forêt aléatoire - Scores de validation croisée sur l'échantillon d'apprentissage (en vert, le modèle choisi)

Modèle	RMSE	ECT	BIAIS	MAE	PSS1	FA1	PSS2	FA2	PSS3	FA3
RFA	0.528	0.528	0.002	0.375	0.902	0.05	0.883	0.01	0.883	0.002
RFB	0.506	0.506	0.003	0.362	0.907	0.046	0.891	0.01	0.881	0.002
RFC	0.497	0.497	0.002	0.356	0.908	0.045	0.893	0.01	0.892	0.002
RFD	0.493	0.493	0.002	0.354	0.908	0.045	0.897	0.01	0.889	0.002
RFE	0.49	0.49	0.002	0.352	0.908	0.045	0.899	0.01	0.888	0.002

Tableau 8.8: Station de test 1 – FF – Modèles de forêt aléatoire - Scores de validation croisée sur l'échantillon de test (en vert, le modèle choisi)

Modèle	RMSE	ECT	BIAIS	MAE	PSS1	FA1	PSS2	FA2	PSS3	FA3
RFA (20 arbres)	1.194	1.194	-0.002	0.879	0.758	0.142	0.689	0.023	0.656	0.007
RFB (50 arbres)	1.177	1.177	-0.002	0.865	0.761	0.14	0.697	0.023	0.657	0.007
RFC (100 arbres)	1.173	1.172	-0.003	0.86	0.761	0.14	0.701	0.023	0.676	0.007
RFD (200 arbres)	1.169	1.169	-0.003	0.858	0.761	0.14	0.704	0.023	0.654	0.007
RFE (500 arbres)	1.168	1.167	-0.003	0.856	0.762	0.139	0.706	0.023	0.673	0.007

Pour les deux stations (test 1 et test 2), le modèle sélectionné comme optimal est une forêt à 100 arbres. Pour ce modèle, l'importance des variables est donnée par le tableau 8.9 pour la station de test 1. C'est la moyenne de l'importance des variables pour chacun des 20 échantillonnages.

Tableau 8.9 : Station de test 1 – FF –
Importance des variables explicatives pour le modèle de forêt aléatoire avec 100 arbres

Variable	RegHH_FF	RegMM	TARO_500	TPWARO_850	PC2_FF	TKEARO_10	FFARO_10	PC1_FF	TARO_2	PC3_FF	PC4_FF	SQRTTKEARO_100	HUARO_2	FFARO_250	SECTEURARO_100	PC5_FF	FFARO_100
Importance	71.51	161.47	436.73	449.7	459.29	490.03	510.67	511.67	554.37	609.32	624.89	625.21	730.94	754.4	810.83	933.45	965.36

Comme pour l'arbre binaire de décision, la force du vent AROME, la composante principale 5 de l'ACP ainsi que HUARO_2 ont une importance plus élevée que les autres variables explicatives pour ce modèle. En plus de ces variables, c'est le SECTEURARO_100 qui s'illustre comme variable ayant une grande importance pour le modèle de forêt aléatoire.

8.4.3.3.1 Comparaison du modèle de forêt aléatoire avec et sans ACP

Nous avons également testé les modèles de forêt aléatoire avec les variables explicatives sans les composantes principales de l'ACP, c'est-à-dire avec les variables explicatives suivantes de la station de test 1 : RegMM, RegHH_FF, SECTEURARO_100, FFARO_10, FFARO_100, FFARO_250, TARO_2, TARO_500, SQRTTKEARO_100, HUARO_2, TKEARO_10, TPWARO_850.

Les graphiques des illustrations 8.19 à 8.22, ainsi que les tableaux 8.10 et 8.11 présentent les scores de validation croisée pour le modèle avec ACP (RF_100) et le modèle sans ACP (noté RF_100.SANS.ACP).




Illustration 8.19: Station de test 1 – FF – Modèles de forêt aléatoire à 100 arbres avec et sans ACP - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon d'apprentissage




Illustration 8.20: Station de test 1 – FF – Modèles de forêt aléatoire à 100 arbres avec et sans ACP - Box-plot PSS (première ligne pss > 3 m/s, pss > 9 m/s et pss > 12 m/s) et FA (deuxième ligne fa > 3 m/s, fa > 9 m/s et fa > 12 m/s) pour l'échantillon d'apprentissage




Illustration 8.21: Station de test 1 – FF – Modèles de forêt aléatoire à 100 arbres avec et sans ACP - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon de test




Illustration 8.22: Station de test 1 – FF – Modèles de forêt aléatoire à 100 arbres avec et sans ACP - Box-plot PSS (première ligne pss > 3 m/s, pss > 9 m/s et pss > 12 m/s) et FA (deuxième ligne fa > 3 m/s, fa > 9 m/s et fa > 12 m/s) pour l'échantillon de test

Tableau 8.10: Station de test 1 – FF – Modèles de forêt aléatoire avec et sans ACP – Scores de validation croisée sur l'échantillon d'apprentissage (en vert, le modèle choisi)

Modèle	RMSE	ECT	BIAIS	MAE	PSS1	FA1	PSS2	FA2	PSS3	FA3
RF_100	0.497	0.497	0.002	0.356	0.908	0.045	0.893	0.01	0.892	0.002
RF_100.SANS.ACP	0.514	0.514	0.004	0.368	0.904	0.048	0.89	0.011	0.883	0.002

Tableau 8.11: Station de test 1 – FF – Modèles de forêt aléatoire avec et sans ACP – Scores de validation croisée sur l'échantillon de test (en vert, le modèle choisi)

Modèle	RMSE	ECT	BIAIS	MAE	PSS1	FA1	PSS2	FA2	PSS3	FA3
RF_100	1.173	1.172	-0.003	0.86	0.761	0.14	0.701	0.023	0.676	0.007
RF_100.SANS.ACP	1.188	1.187	-0.001	0.871	0.756	0.143	0.703	0.023	0.671	0.007

L'interprétation des différents scores de la station de test 1 présentée ci-dessus montrent que les modèles sans ACP sont légèrement moins bons. **Nous avons donc décidé de conserver comme meilleur des modèles de forêt aléatoire, le modèle RFC à 100 arbres (noté RF_100) qui possède les composantes principales de l'ACP comme variables explicatives.**

Pour la station de test 2, le même protocole a été appliqué, et c'est aussi le modèle de forêt à 100 arbres qui a été considéré comme meilleur.

8.4.3.4 Les réseaux de neurones

Pour ce nouveau modèle statistique, les variables explicatives sont les mêmes que celles utilisées pour les modèles précédents. Il y a cependant, un traitement préalable à réaliser avant de soumettre les données aux réseaux de neurones. Il s'agit de la **standardisation** des données. En effet, les réseaux de neurones sont très susceptibles aux données ayant des variances élevées. La standardisation permet de ramener la variance de toutes les données à une valeur égale à 1.

D'autre part, les données catégorielles (notamment RegHH_FF, RegMM et SECTEURARO_100) sont aussi soumises à un traitement préalable : l'**encodage**. Il faut en effet les encoder sous un format numérique

reconnaissable par le réseau de neurones. Pour cela, nous utilisons le module OneHotEncoder de scikit-learn, qui code les variables catégorielles sous forme de vecteurs binaires (constitués de 0 et 1).

8.4.3.4.1 Configuration du modèle retenu

Le processus d'entraînement du modèle nous a conduit à utiliser plusieurs configurations du réseau avant de trouver le modèle optimal (moins complexe, avec des prédictions satisfaisantes). Le tableau 8.12 montre les grandes étapes des différentes configurations qui ont été testées :

Tableau 8.12: Station de test 1 – FF – Tableau récapitulatif du processus d'entraînement du réseau

Optimizer	NB Nœud C1	NB Nœud C2	Activation C1	Activation C2	Activation Sortie	Learnig Rate	Epoch	RMSE App	RMSE Test
SGD	38	2*38	sans activation	sans activation	sans activation	0.0013	570	1.175	1.258
SGD	38	2*38	sans activation	sans activation	sans activation	0.013	570	1.174	1.261
SGD	10	2	sans activation	sans activation	sans activation	0.013	570	1.172	1.260
SGD	2*38	2	relu	relu	relu	0.000013	3000	1.327	1.369
SGD	10	2	relu	relu	relu	0.013	570	1.274	1.327
SGD	10	2	softplus	softplus	softplus	0.0013	870	1.320	1.362
SGD	10	2	softplus	softplus	softplus	0.013	570	1.295	1.333
SGD	10	2	elu	elu	elu	0.013	570	1.140	1.233
SGD	10	2	selu	selu	selu	0.013	570	1.120	1.237
SGD	10	2	tanh	tanh	tanh	0.013	570	1.136	1.231
SGD	10	2	tanh	tanh	softplus	0.013	570	1.283	1.331
SGD	2*38	1*38	tanh	tanh	selu	0.013	570	1.065	1.222
SGD	10	2	tanh	tanh	selu	0.013	570	1.112	1.221
SGD	10	2	tanh	tanh	selu	0.013	870	1.100	1.217

Les colonnes NB Nœud C1 et NB Nœud C2 correspondent respectivement au nombre de neurones dans la première et la deuxième couche cachée. RMSE App et RMSE Test désignent respectivement le RMSE sur le jeu de données d'apprentissage et de test par validation croisée.

À la suite du processus d'entraînement du modèle, la configuration suivante a été adoptée pour le choix du réseau final :

- Le nombre de couches intermédiaires (cachées) est égal à 2 couches Dense, avec 10 neurones dans la première couche cachée et 2 neurones dans la deuxième couche cachée. Une couche Dense est une couche de neurones classique, complètement connectée avec la couche précédente et la couche suivante.
- La fonction d'activation tangente hyperbolique

$$\tanh(x) = (\exp(x) - \exp(-x)) / (\exp(x) + \exp(-x))$$

a été utilisée pour la couche d'entrée et les 2 couches cachées, et la fonction d'activation *selu* pour la couche de sortie.

La fonction *selu* (Scaled Exponential Linear Unit) est définie de la façon suivante :

$$\text{selu}(x) = \alpha * x \quad \text{si } x > 0$$

$$\text{selu}(x) = \alpha * \beta * (\exp(x) - 1) \quad \text{si } x < 0$$

avec $\alpha = 1.05070098$, et $\beta = 1.67326324$.

- Les Optimizer SGD, Adam et RAdam ont tous été utilisés à leur tour pour réaliser la descente du gradient avec le paramétrage ci-dessus du modèle. Pour chacun des Optimizers la valeur du taux d'apprentissage (learning rate) conservée vaut 0.013.
- Les autres paramètres d'entraînement du modèle ont été définis comme suit :
 - le nombre d'Epochs conservé à 870,

- le Batch Size conservé à 380.

Le graphique de l'illustration 8.23 présente l'architecture du réseau final conservé.




Illustration 8.23: Station de test 1 – Architecture du réseau conservé pour la modélisation de FF

Sur cette figure, la couche d'entrée reçoit 38 variables. Le nombre de variable explicative (17) n'a pas changé. Il s'agit en effet de 14 variables numériques (paramètres AROME) et des 3 variables catégorielles (RegHH_FF, RegMM et SECTEURARO_100) qui ont été encodées sous forme de vecteurs binaires. C'est cet encodage qui transforme les 3 trois variables catégorielles en 24 vecteurs binaires, conduisant ainsi le nombre de données d'entrée du réseau à 38 variables.

Comme évoqué ci-dessus, le nombre de neurones de la couche d'entrée est toujours égal au nombre de données (variables) d'entrées. Ensuite, il faut regarder l'output de chaque couche qui correspond au nombre de neurones dans cette couche.

8.4.3.4.2 Courbes d'entraînement du modèle de réseau de neurones

Les illustrations 8.24, 8.25 et 8.26 montrent les courbes d'entraînement du modèle sur 1 des 20 échantillons d'apprentissage.




Illustration 8.24: Station de test 1 – FF – Courbe d'entraînement - modèles RNA avec l'optimizer SGD




Illustration 8.25: Station de test 1 – FF – Courbe d'entraînement - modèles RNB avec l'optimizer Adam




Illustration 8.26: Station de test 1 – FF – Courbe d'entraînement - modèles RNC avec l'optimizer RAdam

On analyse la courbe d'entraînement selon la décroissance du MSE (Mean Squared Error ou erreur quadratique moyenne). Pour limiter le risque de sur-apprentissage, on arrête l'apprentissage juste au moment où l'erreur de test ne décroît plus simultanément avec l'erreur d'entraînement (ou du moins lorsque l'erreur de test ne se remet pas à augmenter).

En adoptant cette technique, le modèle RNA est celui qui a été choisi comme modèle final à la suite du processus d'entraînement. Comme on peut le voir, les modèles RNB et RNC ont tous les deux sur-appris lorsqu'on avance le nombre d'Epoch jusqu'à 870. En effet, si on devait arrêter l'apprentissage pour ces deux modèles, le nombre d'Epoch idéal se trouverait autour de 20, et dans ce cas le MSE serait un peu plus élevé pour ces deux modèles que pour le modèle RNA. Par conséquent, avec les réglages appliqués, le meilleur modèle est bien le RNA avec l'Optimizer SGD.

8.4.3.4.3 Scores de validation croisée pour la prédiction de FF

Les illustrations 8.27, 8.28, 8.29 et 8.30 présentent respectivement les distributions des scores de qualité (RMSE, ECT, BIAIS, MAE, PSS et FA) des différents modèles RNA, RNB et RNC sur l'échantillon d'apprentissage puis de test (par validation croisée).




Illustration 8.27: Station de test 1 – FF – Réseau de neurones - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon d'apprentissage




Illustration 8.28: Station de test 1 – FF – Réseau de neurones - Box-plot PSS et FA pour l'échantillon d'apprentissage




Illustration 8.29: Station de test 1 – FF – Réseau de neurones - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test




Illustration 8.30: Station de test 1 – FF – Réseau de neurones - Box-plot PSS et MAE pour l'échantillon de test

Les tableaux 8.13 et 8.14 présentent le récapitulatif des scores de validation croisée sur l'échantillon d'apprentissage et de test.

Tableau 8.13: Station de test 1 – FF – Réseau de neurones - Scores de validation croisée sur l'échantillon d'apprentissage

Modèle	RMSE	ECT	BIAIS	MAE	PSS1	FA1	PSS2	FA2	PSS3	FA3
RNA	1.115	1.114	-0.033	0.827	0.750	0.173	0.634	0.014	0.536	0.002
RNB	1.047	1.046	-0.016	0.782	0.770	0.156	0.665	0.015	0.612	0.002
RNC	1.053	1.052	-0.011	0.785	0.769	0.157	0.658	0.014	0.588	0.002

Tableau 8.14: Station de test 1 – FF – Réseau de neurones - Scores de validation croisée sur l'échantillon de test

Modèle	RMSE	ECT	BIAIS	MAE	PSS1	FA1	PSS2	FA2	PSS3	FA3
RNA	1.182	1.181	-0.023	0.871	0.746	0.172	0.624	0.015	0.452	0.002
RNB	1.276	1.275	-0.005	0.949	0.727	0.180	0.637	0.018	0.503	0.003
RNC	1.271	1.271	-0.006	0.943	0.726	0.183	0.631	0.018	0.502	0.003

Comme on a pu constater à travers les courbes d'entraînements des modèles, les scores d'apprentissages sont meilleurs pour les modèles RNB et RNC que pour le modèle RNA. À l'inverse ce sont les scores de test du modèle RNA qui sont meilleurs et en restant du même ordre de grandeur que ses scores d'apprentissage. En effet, avec les réglages communs définis pour les trois modèles, **le modèle RNA est le seul à être bien ajusté. Les deux autres modèles (RNB et RNC) ont sur-appri.**

Lorsqu'on analyse uniquement les scores du modèle RNA, ils sont très proches des scores du modèle de forêt aléatoire sans pour autant les égaler. La principale faiblesse de ce modèle est sa capacité de prédiction des vents forts. En effet, les scores de test PSS et FA du modèle RNA pour les seuils S2 (FF > 9 m/s) et S3 (FF > 12 m/s) sont beaucoup moins bons que ceux du modèle de forêt aléatoire.

De part la complexité de la mise en œuvre et des résultats recueillis, les réseaux de neurones ont été testés uniquement sur la station de test 1.

8.4.3.5 Modèle linéaire avec anamorphose

Ce modèle linéaire avec anamorphose (noté LM_ANA) a été testé en prenant en compte une loi de Weibull pour l'anamorphose sur FF. Des variables explicatives différentes ont également été utilisées (des FF à différents niveaux de pression).

Lors de nos premiers tests sur la station de test 1, les prédictions de la méthode ont produit des forces de vent uniquement comprises entre 2 m/s et 8 m/s (sachant que les observations vont de 0 à 17 m/s).

De part ces premiers résultats et l'étendu des travaux de R&D restant pour améliorer cette méthode, nous avons décidé de ne pas retenir ce modèle dans la suite de notre étude.

8.4.4 Comparaison inter-modèles sur l'échantillon de test

Dans la phase précédente, pour la station de test 1, deux modèles linéaires, un modèle de forêt aléatoire et un modèle de réseau de neurones ont été sélectionnés. Il s'agit du modèle GLM, GLM_MIXTE.STEP, RFC (qu'on notera RF_100 dans la suite), et RNA.

Pour la station de test 2, deux modèles linéaires (GLM, GLM_MIXTE.STEP) et un modèle de forêt aléatoire (RF_100) ont été sélectionnés, les réseaux de neurones n'ayant pas été utilisés pour la station de test 2.

Par la suite, une comparaison a été établie entre ces modèles afin de choisir le modèle final qui sera utilisé pour l'extension de la série d'observation. Pour cela, les scores de validation croisée sur l'échantillon de test, la courbe de fiabilité (QQ-Plot) et la restitution de cycle (diurne, annuel) pour chacun des modèles ont été examinés.

Les illustrations 8.31 et 8.32 présentent les scores de validation croisée sur l'échantillon de test.




Illustration 8.31: Station de test 1 – FF – Comparaison inter-modèles - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon de test




Illustration 8.32: Station de test 1 – FF – Comparaison inter-modèles - Box-plot PSS (première ligne pss > 3 m/s, pss > 9 m/s et pss > 12 m/s) et FA (deuxième ligne fa > 3 m/s, fa > 9 m/s et fa > 12 m/s) pour l'échantillon de test

Les scores RMSE, ECT, BIAIS et MAE des 4 modèles GLM, GLM_MIXTE.STEP, RF_100 et RNA sont très proches et dans tous les cas l'utilisation des modèles statistiques améliorent les sorties de AROME.BRUT. Cependant, le modèle RNA a des scores de détection de vents moyen (PSS > 9 m/s) et fort (PSS > 12 m/s) moins bons que tous les autres modèles. Par conséquent, il ne pourra pas être retenu comme modèle final d'extension.

Par ailleurs, le modèle RF_100 semble avoir des indicateurs légèrement meilleurs que ceux des deux modèles linéaires GLM et GLM_MIXTE.STEP (ces 2 derniers ayant été confrontés dans la phase précédente). Le tableau 8.15 récapitule les scores de validations sur l'échantillon de test.

Tableau 8.15: Station de test 1 – FF – Scores de comparaison inter-modèles sur l'échantillon de test (en vert le modèle sélectionné)

Modèle	RMSE	ECT	BIAIS	MAE	PSS1	FA1	PSS2	FA2	PSS3	FA3	Corrélation linéaire avec l'observation
AROME.BRUT	1.396	1.366	-0.288	1.047	0.703	0.21	0.699	0.024	0.482	0.005	0.882
GLM	1.208	1.207	-0.01	0.9	0.754	0.142	0.7	0.023	0.644	0.008	0.906
GLM_MIXTE.STEP	1.192	1.192	-0.004	0.884	0.76	0.138	0.7	0.024	0.585	0.008	0.908
RF_100	1.173	1.172	-0.003	0.86	0.761	0.14	0.701	0.023	0.676	0.007	0.911
RNA	1.182	1.181	-0.023	0.871	0.746	0.172	0.624	0.015	0.452	0.002	0.910

Au vu des scores ci-dessus, **le modèle RF_100 se positionne comme le meilleur modèle pour la station de test 1**. Selon la même démarche c'est également **RF_100 qui a été choisi comme meilleur modèle pour la station de test 2**. Pour affiner cette analyse, les courbes de fiabilités (QQ-Plot) ainsi que le cycle diurne et annuel ont été visualisés (illustrations 8.33, 8.34 et 8.35).




Illustration 8.33: Station de test 1 – FF – QQ-Plot de FF pour les modèles GLM, GLM_MIXTE.STEP, RF_100, RNA et AROME

Sur la courbe QQ-Plot de AROME, on remarque que celui-ci est très proche des observations jusqu'à environ 14 m/s mais surestime les fortes vitesses de vent.

Les courbes de fiabilités penchent également en faveur du modèle RF_100. En effet, le QQ-Plot du RF_100 est meilleur que ceux du GLM, GLM_MIXTE.STEP et RNA. Il se démarque notamment en début et fin de distribution où il est plus proche de la diagonale. Il faudra retenir que la correction par rapport à AROME est un peu trop forte avec notamment une légère sous-estimation des vents entre 12 et 15 m/s environ.

Les QQ-Plots sont également favorables au modèle RF_100 pour la station de test 2.

Pour aller encore plus loin dans l'analyse, les cycles diurne et annuel des modèles superposés aux observations ont été examinés (illustrations 8.34 et 8.35).




Illustration 8.34: Station de test 1 – FF – Cycle diurne des modèles statistiques (bleu) superposé aux observations (rouge)




Illustration 8.35: Station de test 1 – FF – Cycle annuel des modèles statistiques (bleu) superposé aux observations (rouge)

Les modèles statistiques améliorent tous la distribution de la force du vent AROME (notamment le biais annuel). Cependant, ils restituent tous le cycle diurne et annuel quasiment de la même façon. En effet, ces graphiques ne permettent pas de faire une distinction flagrante visuellement entre les distributions des 4 modèles statistiques (GLM, GLM_MIXTE.STEP, RF_100 et RNA). Par conséquent, l'avantage reste toujours pour le modèle RF_100 dans le choix du modèle final pour l'extension.

Au vu des analyses précédentes, **nous avons décidé de choisir le modèle RF_100 (qui présente les meilleurs indicateurs par rapport aux autres modèles) pour l'extension de la série d'observation horaire de la force du vent de la station de test 1.**

Concernant la station de test 2, le constat était le même. C'est le modèle RF_100 qui présente les meilleurs indicateurs de qualité.

8.4.4.1 Test des prédicteurs de régimes de temps

Après avoir choisi d'étendre la série d'observation avec le modèle de forêt aléatoire avec des prédicteurs issus du modèle AROME, nous avons testé les données de régimes de temps comme prédicteurs pour les 2 stations de test. Ces données caractérisent (plus ou moins) la variabilité basse fréquence de l'atmosphère. Elles sont issues de la classification en anomalie de pression ramenée au niveau de la mer (PMER) des réanalyses ERA5.

Nous utilisons 8 variables constituées par les corrélations de chaque jour aux centroïdes des régimes PMER pour constituer 4 prédicteurs. Les 8 variables utilisées sont les suivantes :

- H_Z0 : corrélation au régime d'hiver NAO+ (Zonal)
- H_AR : corrélation au régime d'hiver Dorsale (Atlantic Ridge)
- H_EA : corrélation au régime d'hiver Blocage (European Blocking)
- H_AL : corrélation au régime d'hiver NAO- (Atlantic Low)
- E_GA : corrélation au régime d'été Anticyclone Groenland
- E_AL : corrélation au régime d'été minimum atlantique (Atlantic Low)
- E_EA : corrélation au régime d'été Blocage (European Blocking)
- E_Z0 : corrélation au régime d'été Zonal

Ces 8 variables constituées par les régimes été/hiver sont liées 2 à 2 en utilisant le tableau 8.16 de pondération.

Tableau 8.16: Table de pondération utilisée pour lier les régimes de temps 2 à 2

Pondération	Janvier	Février	Mars	Avril	Mai	Juin	Juillet	Août	Septembre	Octobre	Novembre	Décembre
H_Z0	1	1	1	0.5	0.25	0	0	0	0.25	0.5	1	1
E_Z0	0	0	0	0.5	0.75	1	1	1	0.75	0.5	0	0
H_AR	1	1	1	0.5	0.25	0	0	0	0.25	0.5	1	1
E_GA	0	0	0	0.5	0.75	1	1	1	0.75	0.5	0	0
H_EA	1	1	1	0.5	0.25	0	0	0	0.25	0.5	1	1
E_EA	0	0	0	0.5	0.75	1	1	1	0.75	0.5	0	0
H_AL	1	1	1	0.5	0.25	0	0	0	0.25	0.5	1	1
E_AL	0	0	0	0.5	0.75	1	1	1	0.75	0.5	0	0

Une fois les pondérations appliquées aux données, nous obtenons les 4 prédicteurs (RG_Zonal, RG_Dorsal, RG_Blocage et RG_AtlantiqueLow) en utilisant les associations suivantes :

- $RG_Zonal = H_Z0 + E_Z0$
- $RG_Dorsal = H_AR + E_GA$
- $RG_Blocage = H_EA + E_EA$
- $RG_AtlantiqueLow = H_AL + E_AL$.

Afin d'apprécier l'apport de ces prédicteurs, ils ont été ajoutés aux 17 variables explicatives pour les 2 stations, c'est-à-dire :

- RegMM, RegHH_FF, SECTEURARO_100, FFARO_10, FFARO_100, FFARO_250, TARO_2, TARO_500, SQRTTKEARO_100, HUARO_2, TKEARO_10, TPWARO_850, PC1_FF, PC2_FF, PC3_FF, PC4_FF et PC5_FF pour la modélisation de FF de la station de test 1,
- RegMM, RegHH_FF, SECTEURARO_100, FFARO_100, FFARO_250, TARO_2, TARO_50, TKEARO_100, SQRTTKEARO_10, HUARO_2, PMERARO, TPWARO_850, PC1_FF, PC2_FF, PC3_FF, PC4_FF et PC5_FF pour la modélisation de FF de la station de test 2.

Les illustrations 8.36 à 8.39 ainsi que les tableaux 8.17 et 8.18 présentent les scores de validation croisée pour le modèle de forêt aléatoire pour FF sans les prédicteurs de régimes de temps (RF_100) et avec les prédicteurs de régimes de temps (noté RF_100.AVEC.REGI) pour la station de test 2.




Illustration 8.36: Station de test 2 – FF – Modèles de forêt aléatoire à 100 arbres avec et sans prédicteurs de régimes de temps - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon d'apprentissage




Illustration 8.37: Station de test 2 – FF – Modèles de forêt aléatoire à 100 arbres avec et sans prédicteurs de régimes de temps - Box-plot PSS (première ligne pss > 3 m/s, pss > 9 m/s et pss > 12 m/s) et FA (deuxième ligne fa > 3 m/s, fa > 9 m/s et fa > 12 m/s) pour l'échantillon d'apprentissage




Illustration 8.38: Station de test 2 – FF – Modèles de forêt aléatoire à 100 arbres avec et sans prédicteurs de régimes de temps - Box-plot RMSE (haut gauche), ECT (bas gauche), BIAIS (haut droite) et MAE (bas droite) pour l'échantillon de test




Illustration 8.39: Station de test 2 – FF – Modèles de forêt aléatoire à 100 arbres avec et sans prédicteurs de régimes de temps - Box-plot PSS (première ligne pss > 3 m/s, pss > 9 m/s et pss > 12 m/s) et FA (deuxième ligne fa > 3 m/s, fa > 9 m/s et fa > 12 m/s) pour l'échantillon de test

Tableau 8.17: Station de test 2 – FF – Modèles de forêt aléatoire avec et sans prédicteurs de régimes de temps - Scores de validation croisée sur l'échantillon d'apprentissage (en vert, le modèle choisi)

Modèle	RMSE	ECT	BIAIS	MAE	PSS1	FA1	PSS2	FA2	PSS3	FA3
RF_100	0.6	0.6	0	0.424	0.931	0.049	0.942	0.02	0.829	0.003

RF_100.AVEC.REGI	0.586	0.586	0.001	0.417	0.933	0.047	0.943	0.019	0.831	0.003
------------------	-------	-------	-------	-------	-------	-------	-------	-------	-------	-------

Tableau 8.18: Station de test 2 – FF – Modèles de forêt aléatoire avec et sans prédicteurs de régimes de temps - Scores de validation croisée sur l'échantillon de test (en vert, le modèle choisi)

Modèle	RMSE	ECT	BIAIS	MAE	PSS1	FA1	PSS2	FA2	PSS3	FA3
RF_100	1.373	1.372	-0.003	1.004	0.821	0.132	0.861	0.053	0.509	0.005
RF_100.AVEC.REGI	1.357	1.357	-0.003	0.994	0.822	0.131	0.863	0.052	0.491	0.005

L'ajout des prédicteurs de régimes de temps aux modèles de FF, U et V ne montre pas un apport notable. De ce fait et afin de ne pas augmenter encore le nombre de prédicteurs (déjà 17 pour les deux stations de test, risque de non parcimonie), **nous avons décidé de conserver les modèles de forêts aléatoires à 100 arbres pour FF.**

8.5 Modélisation de la direction du vent à 100 m

Dans l'élaboration des modèles statistiques pour la direction du vent DD, la démarche reste la même que celle présentée pour la force du vent FF. La différence majeure se situe au niveau de la variable à prédire (DD), qui est une variable circulaire. Par conséquent, DD est décomposée en 2 composantes U et V qui sont définies par :

$$U = \sin(DD * \pi / 180) * FF$$

$$V = \cos(DD * \pi / 180) * FF$$

Ainsi, on a une variable à prédire pour chacun des composantes U et V de DD, puis on estime la direction du vent à partir des estimations de U et V à travers la formule suivante :

$$DD = (90 - (180 * \arctan 2(V, U) / \pi))$$

Comme pour la force du vent, les modèles statistiques de chacune des composantes U et V sont ajustés non pas sur U et V de l'observation, mais sur l'écart de U et V observé avec U et V du vent AROME.

Par conséquent, **les variables à prédire sont :**

$$Y_1 = U_m U_{ARO} = U_{OBS} - U_{ARO}, \text{ et } Y_2 = V_m V_{ARO} = V_{OBS} - V_{ARO}.$$

La méthodologie étant la même que pour les études de la force du vent, nous allons présenter uniquement les résultats principaux pour la direction du vent.

Notamment, nous ne détaillons pas la sélection des modèles « champion » pour chaque catégorie de modèle statistique et nous présentons directement les résultats de l'inter-comparaison de ces modèles « champion ».

8.5.1 Sélection des variables explicatives

Les figures suivantes (illustrations 8.40 à 8.42) montrent les différentes phases de la sélection des variables explicatives pour les composantes U et V de DD pour la station de test 1.

À la suite du processus de sélection des variables explicatives pour les composantes U et V de DD, il y a 18 variables qui ont été utilisées pour établir les modèles statistiques (linéaires, arbre binaire, forêt aléatoire et réseau de neurones) pour chacune des deux stations de test.

Les variables explicatives de la station de test 1 sont : RegMM, RegHH_DD, UARO_10, UARO_100, UARO_250, VARO_100, VARO_500, SQRTTKEARO_10, SQRTTKEARO_100, TARO_2, TARO_500, HUARO_2, TPWARO_850, PC1_DD, PC2_DD, PC3_DD, PC4_DD, PC5_DD ;

et celles de la station de test 2 sont RegMM, RegHH_DD, UARO_100, UARO_500, VARO_10, VARO_500, SQRTTKEARO_100, SQRTTKEARO_160, TARO_100, TARO_500, HUARO_2, PMERARO, TPWARO_850, PC1_DD, PC2_DD, PC3_DD, PC4_DD, PC5_DD.




Illustration 8.40: Station de test 1 – Premier groupe (variables explicatives conservées pour la sélection finale) pour la prédiction de DD




Illustration 8.41: Station de test 1 – Deuxième groupe (variables de l'ACP) pour la prédiction de DD




Illustration 8.42: Station de test 1 – Variables explicatives finales (avec les composantes principales de l'ACP) pour la prédiction de DD

8.5.2 Études des modèles statistiques

L'établissement des modèles statistiques pour l'estimation de la direction du vent (composantes U et V) suit la même démarche que celle de la force du vent.

Comme pour la force du vent, les réseaux de neurones n'ont pas été utilisés pour la modélisation des composantes U et V de la direction du vent de la station de test 2.

8.5.2.1 Scores de test pour la prédiction de U et V

8.5.2.1.1 Scores pour la composante U

Les illustrations 8.43 à 8.46 présentent les distributions des scores de test (par validation croisée) de la prédiction de U de la station de test 1 pour les réseaux de neurones puis AROME, les modèles linéaires et les forêts aléatoires « champion ».




Illustration 8.43: Station de test 1 – U – Réseau de neurones - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test




Illustration 8.44: Station de test 1 – U – Réseau de neurones - Box-plot PSS et FA pour l'échantillon de test




Illustration 8.45: Station de test 1 – U – Modèles linéaires, forêt et AROME - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test




Illustration 8.46: Station de test 1 – U – Modèles linéaires, forêt et AROME - Box-plot PSS et FA pour l'échantillon de test

Comme pour la force du vent, les modèles RNB et RNC ont sur-appriés. Par conséquent, on analyse uniquement les résultats du modèle RNA.

Les scores RMSE, ECT, BIAIS et MAE du modèle RNA sont du même ordre de grandeur que ceux des meilleurs modèles (GLM, GLM_MIXTE.STEP et RF_200) pour la prédiction de U. Mais visuellement ces scores sont relativement meilleurs pour les modèles GLM, GLM_MIXTE.STEP et RF_200 que pour RNA.

Pour les scores PSS et FA, ils sont beaucoup moins bons pour le modèle RNA que pour les modèles GLM, GLM_MIXTE.STEP et RF_200. En effet pour le calcul de ces scores, nous avons cherché à connaître le taux de bonne prédiction et de fausse alarme de la prédiction pour les valeurs et U inférieur à son 1^{er} quantile, et les valeurs U supérieur à son 3^e quantile.

Le tableau 8.19 permet de résumer les scores de test détaillés pour les différents modèles.

Tableau 8.19 : Station de test 1 – U – Modèles linéaires, forêt, Réseau de neurones – Scores de validation croisée sur l'échantillon de test

Modèle	RMSE	ECT	BIAIS	MAE	PSS1	FA1	PSS3	FA3
LM0	1.195	1.194	-0.004	0.861	0.648	0.112	0.666	0.111
GLM	1.147	1.147	-0.004	0.813	0.669	0.109	0.691	0.104
GLM_PCA	1.204	1.204	-0.007	0.865	0.629	0.111	0.658	0.106
GLM_MIXTE.STEP	1.147	1.147	-0.005	0.814	0.668	0.11	0.696	0.105
RF_200	1.139	1.138	-0.001	0.802	0.668	0.105	0.707	0.104
AROME.BRUT	1.272	1.254	0.21	0.916	0.644	0.108	0.598	0.088
RNA	1.149	1.149	0.003	0.821	0.592	0.066	0.610	0.057

Le tableau confirme la hiérarchie constatée des modèles statistiques lors de l'analyse des box-plots. Les meilleurs modèles restent le GLM, GLM_MIXTE.STEP et le RF_200, avec un avantage pour le RF_200.

Le même constat est fait pour la station de test 2 : selon les indicateurs de qualité, les meilleurs modèles restent le GLM, GLM_MIXTE.STEP et le RF_200, avec un avantage pour le RF_200.

8.5.2.1.2 Scores pour la composante V

Les box-plots suivants (illustrations 8.47, 8.48, 8.49 et 8.50) présentent les scores de test (par validation croisée) de la prédiction de la composante V de la station de test 1.




Illustration 8.47: Station de test 1 – V – Réseau de neurones - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test




Illustration 8.48: Station de test 1 – V – Réseau de neurones - Box-plot PSS et FA pour l'échantillon de test




Illustration 8.49: Station de test 1 – V – Modèles linéaires, forêt et AROME - Box-plot RMSE, ECT, BIAIS et MAE pour l'échantillon de test




Illustration 8.50: Station de test 1 – V – Modèles linéaires, forêt et AROME - Box-plot PSS et FA pour l'échantillon de test

Le tableau 8.20 récapitule les scores de validation croisée sur le jeu de test pour tous les modèles de V.

Tableau 8.20 : Station de test 1 – V – Modèles linéaires, forêt, Réseau de neurones – Scores de validation croisée sur l'échantillon de test

Modèle	RMSE	ECT	BIAIS	MAE	PSS1	FA1	PSS3	FA3
LM0	1.443	1.443	0.002	1.061	0.863	0.051	0.828	0.057
GLM	1.29	1.29	0	0.944	0.876	0.033	0.829	0.048
GLM_PCA	1.378	1.378	0.004	1.009	0.86	0.035	0.824	0.051
GLM_MIXTE.STEP	1.273	1.273	0	0.93	0.879	0.032	0.838	0.049
RF_200	1.269	1.269	0.003	0.915	0.88	0.032	0.836	0.046
AROME.BRUT	1.446	1.445	-0.036	1.072	0.862	0.051	0.83	0.063
RNA	1.281	1.280	0	0.937	0.874	0.031	0.813	0.037

La même analyse réalisée sur les scores de test de U a été faite sur les scores de V, et les tendances n'ont pas changé pour les deux stations. Les meilleurs modèles pour la prédiction de V restent le GLM, GLM_MIXTE.STEP et RF_200, avec toujours un avantage pour le RF_200.

8.5.2.1.3 Roses des vents après reconstitution de DD à partir de U et V

Pour les deux stations de test, les scores RMSE, ECT, MAE, BIAIS, PSS et FA ont permis de sélectionner les trois modèles GLM, GLM_MIXTE.STEP et RF_200 comme meilleurs modèles statiques pour la prédiction de U et V.

Cependant, il est très difficile de départager les modèles sur les critères d'évaluations identifiés pour l'estimation statistique de direction du vent. **Nous avons donc décidé de sélectionner le modèle statistique d'estimation de DD sur sa capacité de restitution de la rose des vents** : c'est-à-dire que parmi les roses des vents établies à partir des modèles statistiques, celle qui se rapprochera le plus de la rose des vents de l'observation verra sa méthode choisie pour l'estimation de DD. Le FF des roses des vents est celui du modèle RF_100 pour une comparaison optimale sur DD.

Les graphiques de l'illustration 8.51 montrent les roses des vents issues de la combinaison des différents modèles d'estimation des composantes U et V de DD.




Illustration 8.51: Station de test 1 – Roses des vents issues des combinaisons de U et V des modèles statistiques: sur la 1ère colonne l'observation ; sur la 2ème colonne (de haut en bas) on retrouve DD AROME brut (U.BRUT et V.BRUT), DD GLM (U.GLM et V.GLM), U.GLM et V.RF_200, U.BRUT et V.GLM; et sur la 3ème colonne on retrouve DD RF_200 (U.RF_200, V.RF_200), DD GLM MIXTE.STEP (U.GLM MIXTE.STEP, V.GLM MIXTE.STEP), U.RF_200 et V.GLM, U.BRUT et V.RF_200

Pour la station de test 1, les secteurs prépondérants pour le choix du modèle statistique sont les secteurs situés dans le nord (notamment de 340° à 360°), et dans le sud (notamment de 140° à 200°) où AROME brut restitue moins bien la rose de vent. Cependant, à part les roses où on utilise la composante U de AROME (roses issues de U.BRUT V.GLM, et U.BRUT V.RF_200), les roses issues des modèles statistiques sont très proches les unes des autres. En effet, elles sont meilleures que les roses impliquant AROME pour les vents du sud, et moins biens que ce dernier pour les vents du nord. Ainsi, ce sont les scores B95+ (notamment le critère C2 qui concerne la direction, et le critère C4 qui concerne la corrélation circulaire) qui seront décisifs pour choisir le modèle statistique d'estimation de DD.

Le tableau 8.21 présente le récapitulatif des scores B95+ pour les différents modèles.

Tableau 8.21: Station de test – Scores B95+ des roses de vents issues de la combinaison de U et V des modèles statistiques (en vert le modèle choisi)

Modèle	C1	C2	C3	C4 (corrélation circulaire)
OBS - BRUT	85.65	89.31	92.72	19.93
OBS - RF_200	85.34	89.59	92.72	64.19
OBS - GLM	84.94	89.08	92.72	61
OBS - GLM_MIXTE.STEP	84.94	89.28	92.72	61.27
OBS - U.GLM-V.RF_200	84.82	89.03	92.72	61.57
OBS - U.RF_200-V.GLM	85.08	89.32	92.72	63.77
OBS - U.BRUT-V.GLM	86.74	90.59	92.72	22.2
OBS - U.BRUT-V.RF_200	87.17	91.1	92.72	21.25

Les scores sont favorables au modèle RF_200 qui se démarque avec un très bon C2 et la meilleure corrélation circulaire C4. Par conséquent, **nous avons décidé de choisir le modèle RF_200 pour l'estimation de DD pour la station de test 1.**

La reconstitution de DD à partir de U et V pour la station de test 2 a donné des résultats similaires. C'est en effet le modèle RF_200 qui a été choisi pour l'estimation de DD.

Des tests sur le réseau de forêt à 200 arbres pour U et V avec et sans les prédicteurs de régimes de temps ont également été réalisés pour les deux stations de test. Comme pour la force du vent, l'apport des régimes de vent n'est pas suffisamment notable pour rajouter ces variables explicatives supplémentaires.

8.6 Synthèse du choix des modèles

Suite aux études des différents modèles statistiques, **le modèle de forêt aléatoire à 100 arbres (RF_100) a été retenu pour étendre la série horaire de FF et le modèle de forêt à 200 arbres (RF_200) pour étendre la série de DD pour chacune des deux stations de test.** On note cependant que pour de nombreuses stations étudiées après ces tests, le modèle retenu est la forêt aléatoire à 200 arbres pour la force et la direction du vent.

Les modèles statistiques d'estimation de FF et DD ont été appris sur les données AROME de l'année 2017 pour la station de test 1, et celles de l'année 2018 pour la station de test 2.

Le graphique ci-dessous (illustration 8.52) montre les roses finales d'extension entre 2018 et 2020 de la station de test 1.




Illustration 8.52: Station de test 1 – Roses des vents finales de l'extension entre l'année 2018 et 2020

Sur cette période d'extension (2018 à 2020), la rose des vents de l'extension restitue mieux les vents du sud que AROME. En revanche, il surestime légèrement la force du vent dans le secteur nord, et sous estime la proportion de vent très faible (FF < 1.5 m/s). **Globalement c'est la rose issue du modèle statistique qui est plus proche de l'observation.**

Comme pour la station de test 1, c'est la rose issue du modèle statistique qui est plus proche de l'observation dans l'ensemble pour la station de test 2. L'illustration 8.53 présente les roses finales d'extension entre 2017 et 2020 (sans les données de l'année d'apprentissage 2018) de la station de test 2.




Illustration 8.53: Station de test 2 – Roses des vents finales de l'extension entre l'année 2017 et 2020 (sans les données d'apprentissage de l'année 2018)

8.7 Limites de l'extension

Pour la station de test 1, l'extension avec le modèle statistique améliore la rose des vents AROME, autant sur la force (secteur 340° à 0°) que sur la direction (secteur 140° à 180°). Cependant, la fréquence des vents très faibles reste toujours moindre pour l'extension comme on peut l'apercevoir sur les graphiques de l'illustration 8.54 qui présentent les histogrammes de FF par classe de vent par pas de 5 m/s.




Illustration 8.54: Station de test 1 – Histogrammes de FF par classe de vent par pas de 5 m/s pour les années 2018 à 2020. En haut, observations (bleu) comparées à AROME (rouge). En bas, observations comparées à l'extension (vert).

Les vents très faibles sont moins fréquents pour l'extension que pour AROME et l'observation. Ils correspondent globalement à des forces de vents inférieurs à 1.5 m/s. Par ailleurs, les vents forts ($FF > 15 \text{ m/s}$) sont également moins fréquents (voire inexistant pour la période de 2018-2020) pour l'extension comparativement à AROME et l'observation où l'on trouve peu de vent fort.

L'illustration 8.55 présente les histogrammes de FF par classe de vent par pas de 5 m/s pour la station de test 2.




Illustration 8.55: Station de test 2 – Histogrammes de FF par classe de vent par pas de 5 m/s pour les années 2017 à 2020 (sans les données d'apprentissage de l'année 2018). En haut, observations (bleu) comparées à AROME (rouge). En bas, observations (bleu) comparées à l'extension (vert).

Pour la station de test 2, les vents très faibles sont également sous-estimés par l'extension avec le modèle statistique. Aussi les vents forts sont légèrement moins fréquents que pour AROME, mais leur estimation est meilleure que celle des vents forts de la station de test 1. On note cependant qu'il y a plus de vents forts dans les observations de la station de test 2 que dans celles de la station 1.

8.8 Conclusion de l'étude d'optimisation

L'objectif de cette étude complète sur les stations de test était de valider l'utilisation d'une méthode statistique unique et optimale pour étendre la série horaire d'observation.

En complément des méthodes statistiques utilisées sur les deux campagnes de mesures précédentes (Dunkerque et Oléron), nous avons exploré d'autres variables explicatives (régime de temps), une autre méthode de sélection des variables explicatives (l'ACP) et deux autres méthodes statistiques (modèle linéaire avec anamorphose et réseau de neurones). Excepté le modèle linéaire avec anamorphose, toutes les méthodes testées ont donné des résultats satisfaisants mais ce sont les forêts aléatoires qui se sont démarquées autant sur la force que sur la direction du vent.

Dans la suite de nos études, nous utiliserons la forêt aléatoire pour étendre nos séries de mesure de vent à 100 m. Pour chaque extension, une comparaison au modèle AROME sera effectuée pour qualifier l'apport de la forêt aléatoire.

FIN DE DOCUMENT