

**Titre:** Amélioration des prévisions immédiates du vent et de la production éolienne  
Title: éolienne

**Auteur:** Olivia Beauregard-Harvey  
Author:

**Date:** 2018

**Type:** Mémoire ou thèse / Dissertation or Thesis

**Référence:** Beauregard-Harvey, O. (2018). Amélioration des prévisions immédiates du vent et de la production éolienne [Mémoire de maîtrise, École Polytechnique de Montréal]. PolyPublie. <https://publications.polymtl.ca/3127/>  
Citation:

## Document en libre accès dans PolyPublie Open Access document in PolyPublie

**URL de PolyPublie:** <https://publications.polymtl.ca/3127/>  
PolyPublie URL:

**Directeurs de recherche:** Christophe Sibuet Watters, & Roland P. Malhamé  
Advisors:

**Programme:** Génie énergétique  
Program:

UNIVERSITÉ DE MONTRÉAL

AMÉLIORATION DES PRÉVISIONS IMMÉDIATES DU VENT ET DE LA  
PRODUCTION ÉOLIENNE

OLIVIA BEAUREGARD-HARVEY  
DÉPARTEMENT DE GÉNIE ÉLECTRIQUE  
ÉCOLE POLYTECHNIQUE DE MONTRÉAL

MÉMOIRE PRÉSENTÉ EN VUE DE L'OBTENTION  
DU DIPLÔME DE MAÎTRISE ÈS SCIENCES APPLIQUÉES  
(GÉNIE ÉNERGÉTIQUE)  
MAI 2018

UNIVERSITÉ DE MONTRÉAL

ÉCOLE POLYTECHNIQUE DE MONTRÉAL

Ce mémoire intitulé :

AMÉLIORATION DES PRÉVISIONS IMMÉDIATES DU VENT ET DE LA  
PRODUCTION ÉOLIENNE

présenté par : BEAUREGARD-HARVEY Olivia

en vue de l'obtention du diplôme de : Maîtrise ès sciences appliquées

a été dûment accepté par le jury d'examen constitué de :

M. SIROIS Frédéric, Ph. D., président

M. MALHAMÉ Roland, Ph. D., membre et directeur de recherche

M. SIBUET WATTERS Christophe, Ph. D., membre et codirecteur de recherche

M. KARIMI Houshang, Ph. D., membre externe

## REMERCIEMENTS

Tout d'abord, je tiens à remercier les membres du jury, Frédéric Sirois et Houshang Karimi, d'avoir accepté de lire et d'évaluer ce mémoire.

Je souhaite particulièrement remercier mes directeurs de recherche, Roland Malhamé et Christophe Sibuet Watters, pour l'encadrement et le soutien qu'ils m'ont apporté tout au long de ma maîtrise. Leur aide a été indispensable à la réussite du projet.

J'aimerais aussi remercier le CRSNG, Mitacs et Hydro-Québec pour le soutien financier qui m'a été accordé et qui a rendu possible la réalisation de ce projet.

Merci à mon collègue Mehdi Abedinpour Fallah, qui a toujours été disponible pour répondre à mes questions. Je désire aussi remercier mes collègues et amis François Bergeron et John Ibrahim pour leur précieuse aide à la relecture et à la correction de ce mémoire.

Je tiens également à remercier Daniel, Judith, David, et tous mes amis qui m'ont encouragée tout au long de la réalisation de ce mémoire. Finalement, j'adresse mes plus sincères remerciements à mes parents, qui ont cru en moi et qui m'ont permis de me rendre où je suis.

## RÉSUMÉ

Le vent est une variable météorologique extrêmement difficile à prédire. Augmenter la précision des prévisions de vent à court terme (jusqu'à 12 heures à l'avance) est nécessaire pour optimiser les opérations des parcs éoliens, maximiser leur rendement, et favoriser leur développement. L'objectif de ce projet est donc d'améliorer les techniques existantes de prévision des vitesses de vent et de la puissance produite par les éoliennes.

Suite à une revue de littérature approfondie des techniques de prévision du vent, le filtre de Kalman est identifié comme l'approche la plus prometteuse. Il s'agit d'une méthode adaptative de correction de l'erreur associée aux modèles de prévision physiques, qui peut être appliquée presque instantanément puisqu'elle ne nécessite pas de longue période d'entraînement sur un ensemble de données historiques.

La plupart des approches récentes reposent sur les prévisions de vitesse de vent uniquement comme paramètre d'entrée, alors qu'il a été mentionné à plusieurs reprises dans la littérature que l'ajout d'autres variables, notamment la direction du vent, devrait être considéré pour améliorer la précision des modèles. Il a déjà été démontré pour certaines approches (par exemple, les réseaux de neurones artificiels), que la direction permettait de réduire l'erreur moyenne. En revanche, l'ajout de la direction dans les modèles de filtre de Kalman appliqués à la vitesse du vent ou à la puissance n'a pas été étudié à ce jour.

Dans le cadre de ce projet, une nouvelle méthode est proposée, selon laquelle des filtres de Kalman sont modélisés de façon à tenir compte de la direction du vent comme paramètre d'entrée. Le biais entre les prévisions brutes d'un modèle de prévision numérique du temps et les observations est modélisé de façon non linéaire, en fonction de la vitesse et la direction du vent. Pour la prévision de la puissance, deux approches sont développées pour les cas où des observations de vitesse de vent ne sont pas disponibles. D'une part, un filtre de Kalman est appliqué à la puissance directement afin d'estimer son biais. D'autre part, une technique selon laquelle les puissances observées sont converties en vitesses de vent fictives par la courbe de puissance inverse est introduite, dans le but d'appliquer les filtres sur la vitesse du vent.

Les données historiques de prévision et d'observation de 20 sites situés en Europe et en Amérique du Nord sont utilisées pour analyser la performance des modèles. Afin de quantifier la précision des différents modèles, plusieurs indicateurs sont calculés, notamment le biais, le *Mean Absolute Error* (MAE) et le *Root-Mean-Square Error* (RMSE).

Pour les filtres de Kalman corrigeant la vitesse, le polynôme d'ordre 1 est établi comme le plus approprié, alors que pour celui appliqué à la puissance, les ordres plus élevés réduisent davantage les erreurs moyennes. En définitive, l'ajout de la direction dans les modèles permet d'améliorer la précision des prévisions pour toutes les approches étudiées.

Les filtres de Kalman adaptés pour corriger directement les prévisions de puissance présentent des erreurs nettement plus élevées. Étant donné que la forte variabilité du vent est largement amplifiée pour les données de puissance, ces filtres démontrent moins de succès à prédire le biais. Ainsi, lorsque les observations de vitesse ne sont pas disponibles, la conversion des puissances en vitesses fictives (par la courbe de puissance inverse) permet d'atteindre les meilleurs résultats.

Parallèlement, bien que certains modèles montrent en moyenne une forte tendance à surpasser les autres en ce qui concerne la précision, il a été établi que la performance des différents modèles peut varier en fonction du temps, de l'horizon, et de l'emplacement géographique des sites étudiés. Une méthode de combinaison adaptative est donc également explorée, afin d'allouer plus ou moins de poids à chacun des modèles selon leurs performances passées et récentes. Au final, la combinaison permet de réduire les erreurs de façon significative, comparativement au meilleur modèle de filtre de Kalman.

## ABSTRACT

Short term wind speed and wind power production have been studied thoroughly in the last decades. Wind is a highly fluctuating meteorological parameter, and improving the accuracy of wind speed forecasts is essential to favor the expansion of the wind energy sector, and thus lower our dependence on fossil fuels. Essentially, enhancing the quality of short term wind speed forecasts (up to 12 hours ahead) is necessary in order to optimize wind farm operations and maximize their economic profitability. The purpose of this project is therefore to improve existing wind speed and wind power output prediction techniques. Following a comprehensive literature review, the Kalman Filter appears as the most promising approach. It is an adaptive method that corrects the bias associated to the Numerical Weather Prediction (NWP) models, and which can be applied almost instantly without prior training on an extensive set of historical data.

Most of the recent techniques rely exclusively on wind speed data input, while it is mentioned numerous times in literature that more input parameters, particularly wind direction, should be considered in order to improve forecast accuracy. It has already been shown that for some approaches, such as Artificial Neural Networks, the addition of wind direction leads to reduced forecast errors. However, introducing wind direction into the Kalman Filter models has not been studied to this date.

In this project, a novel approach is introduced, where Kalman Filter algorithms are used to estimate the bias of NWP forecasts as non-linear functions of wind speed and wind direction. As for wind power forecast, two techniques are introduced for wind farms where power measurement is the sole available data. Firstly, wind power bias is estimated by a Kalman Filter applied to power forecasts. Secondly, an Inverse Power Curve Transformation is used to convert observed power production into estimated wind speed values to then apply the filter directly on wind speeds. The forecast values of wind speed are then converted back into power forecasts with the usual power curve.

Historical measurement and forecast data from 20 wind farms located throughout Europe and North America have been made available for this study. In order to quantify the accuracy of the models developed in this research, various performance indicators were used, such as bias, Mean Absolute Error (MAE) and Root-Mean-Square Error (RMSE). For Kalman Filters applied on wind speed, the first order polynomial has shown the best results, whereas for power output, higher order polynomials have shown better performances in correcting the bias. Furthermore, the addition of wind direction into the bias modeling allows achieving higher accuracy for all of the studied approaches.

On the other hand, Kalman Filters applied directly to power predictions clearly show lower performances. Given that the high variability of the wind is greatly amplified at the level of power data, these filters demonstrate less success in predicting the bias. Consequently, when wind speed online measurements are not available, the inverse power curve transformation based approach produces better results.

Alternatively, although specific bias models tend to show higher accuracies in average over all studied wind farms, it was observed that performance can differ from one model to the other, as a function of time of day, prediction horizon and geographic location. An adaptive forecast combination procedure is therefore implemented, consisting of a time varying weighting of all Kalman Filter versions based on their past and recent performances. It is observed that the combination approach leads to significantly reduced forecast errors, compared to the best Kalman Filter model.

## TABLE DES MATIÈRES

REMERCIEMENTS . . . . .	iii
RÉSUMÉ . . . . .	iv
ABSTRACT . . . . .	vi
TABLE DES MATIÈRES . . . . .	viii
LISTE DES TABLEAUX . . . . .	xi
LISTE DES FIGURES . . . . .	xii
LISTE DES SIGLES ET ABRÉVIATIONS . . . . .	xiv
LISTE DES SYMBOLES . . . . .	xvi
LISTE DES ANNEXES . . . . .	xix
 CHAPITRE 1 INTRODUCTION . . . . .	 1
1.1 Préambule . . . . .	1
1.2 Éléments de la problématique . . . . .	1
1.3 Définitions et concepts de base . . . . .	3
1.3.1 Méthodes de prévision . . . . .	3
1.3.2 Conversion en puissance . . . . .	5
1.4 Plan du mémoire . . . . .	6
 CHAPITRE 2 REVUE DE LITTÉRATURE . . . . .	 8
2.1 Modèles physiques . . . . .	8
2.2 Modèles statistiques . . . . .	9
2.2.1 Séries temporelles . . . . .	10
2.2.2 Approches par apprentissage . . . . .	12
2.2.3 Autres modèles . . . . .	14
2.2.4 Sommaire des méthodes de prévision statistiques . . . . .	16
2.3 Modélisation de la puissance . . . . .	18
2.3.1 Norme IEC . . . . .	19
2.4 Méthodes de correction de la puissance . . . . .	19

2.4.1	Inversion de la courbe de puissance . . . . .	20
2.4.2	Filtre de Kalman sur la puissance . . . . .	20
2.5	Évaluation de la performance des modèles . . . . .	21
CHAPITRE 3 DÉTAIL ET DÉVELOPPEMENT DE LA SOLUTION CHOISIE . .		23
3.1	Description mathématique du filtre de Kalman . . . . .	23
3.1.1	Équations de base . . . . .	23
3.1.2	Équations spécifiques . . . . .	24
3.2	Hypothèses avancées par Louka et Galanis . . . . .	27
3.3	Modifications au filtre de Louka et Galanis . . . . .	30
3.3.1	Développement mathématique . . . . .	30
3.3.2	Application du modèle à la puissance . . . . .	32
3.3.3	Résumé de l'approche . . . . .	32
3.4	Combinaison de plusieurs modèles . . . . .	33
3.4.1	Combinaison d'amélioration . . . . .	35
3.4.2	Combinaison d'adaptation . . . . .	39
3.4.3	Estimation en deux étapes . . . . .	40
CHAPITRE 4 PRÉVISION DE LA VITESSE DE VENT . . . . .		41
4.1	Description des données disponibles . . . . .	41
4.1.1	Données de prévision . . . . .	41
4.1.2	Données d'observation . . . . .	42
4.2	Étude préliminaire . . . . .	43
4.3	Validation des modèles . . . . .	44
4.3.1	Initialisation des paramètres du filtre . . . . .	45
4.3.2	Convergence des coefficients du vecteur d'état . . . . .	45
4.4	Analyse des résultats . . . . .	46
4.4.1	Performance des modèles . . . . .	46
4.4.2	Performance en fonction de l'horizon . . . . .	51
4.4.3	Choix du meilleur modèle . . . . .	55
4.4.4	Combinaison des modèles . . . . .	56
CHAPITRE 5 PRÉVISION DE LA PUISSANCE . . . . .		62
5.1	Approche <b>A1</b> - Filtre de Kalman sur la vitesse . . . . .	63
5.1.1	Conversion de la vitesse du vent en puissance . . . . .	63
5.1.2	Analyse des résultats . . . . .	64
5.1.3	Performance en fonction de l'horizon et combinaison des modèles . . . . .	66

5.2	Approche <b>A2</b> - Inversion de la courbe de puissance . . . . .	70
5.2.1	Conversion de puissances en vitesses de vent . . . . .	70
5.2.2	Analyse des résultats . . . . .	71
5.2.3	Performance en fonction de l'horizon et combinaison des modèles . .	74
5.3	Approche <b>A3</b> - Filtre de Kalman sur la puissance . . . . .	77
5.3.1	Méthodologie . . . . .	77
5.3.2	Analyse des résultats . . . . .	78
5.3.3	Performance en fonction de l'horizon et combinaison des modèles . .	80
5.4	Comparaison des approches de prévision de la puissance . . . . .	84
5.4.1	Meilleurs modèles . . . . .	84
5.4.2	Combinaison des modèles . . . . .	86
CHAPITRE 6 CONCLUSION . . . . .		89
6.1	Synthèse des travaux . . . . .	89
6.2	Limitations de la solution proposée . . . . .	90
6.3	Principales contributions du mémoire . . . . .	90
6.4	Améliorations futures . . . . .	92
RÉFÉRENCES . . . . .		93
ANNEXES . . . . .		101

## LISTE DES TABLEAUX

Tableau 1.1	Horizons de prévision . . . . .	3
Tableau 2.1	Résumé des méthodes statistiques . . . . .	16
Tableau 4.1	Description des sites éoliens . . . . .	43
Tableau 4.2	ME (m/s) sur la vitesse, moyenne de $h = 1$ à $h = 6^*$ . . . . .	47
Tableau 4.3	MAE (m/s) sur la vitesse, moyenne de $h = 1$ à $h = 6^*$ . . . . .	47
Tableau 4.4	RMSE (m/s) sur la vitesse, moyenne de $h = 1$ à $h = 6^*$ . . . . .	48
Tableau 4.5	Nombre de coefficients à évaluer pour chaque modèle . . . . .	51
Tableau 4.6	Amélioration du RMSE (m/s) sur la vitesse (avec combinaison) . .	57
Tableau 5.1	Résumé des approches appliquées à la puissance . . . . .	62
Tableau 5.2	<b>A1</b> - ME sur la puissance, moyenne de $h=1$ à $h=6^*$ . . . . .	64
Tableau 5.3	<b>A1</b> - MAE sur la puissance, moyenne de $h=1$ à $h=6^*$ . . . . .	64
Tableau 5.4	<b>A1</b> - RMSE sur la puissance, moyenne de $h=1$ à $h=6^*$ . . . . .	65
Tableau 5.5	<b>A1</b> - Amélioration du RMSE sur la puissance (avec combinaison) .	69
Tableau 5.6	<b>A2</b> - ME sur la puissance, moyenne de $h=1$ à $h=6^*$ . . . . .	72
Tableau 5.7	<b>A2</b> - MAE sur la puissance, moyenne de $h=1$ à $h=6^*$ . . . . .	72
Tableau 5.8	<b>A2</b> - RMSE sur la puissance, moyenne de $h=1$ à $h=6^*$ . . . . .	73
Tableau 5.9	<b>A2</b> - Amélioration du RMSE sur la puissance (avec combinaison) .	76
Tableau 5.10	<b>A3</b> - ME sur la puissance, moyenne de $h=1$ à $h=6^*$ . . . . .	78
Tableau 5.11	<b>A3</b> - MAE sur la puissance, moyenne de $h=1$ à $h=6^*$ . . . . .	79
Tableau 5.12	<b>A3</b> - RMSE sur la puissance, moyenne de $h=1$ à $h=6^*$ . . . . .	79
Tableau 5.13	<b>A3</b> - Amélioration du RMSE sur la puissance (avec combinaison) .	82
Tableau 5.14	Amélioration du RMSE avec et sans combinaison pour <b>A1</b> , <b>A2</b> , et <b>A3</b>	87
Tableau 5.15	Amélioration du RMSE de la combinaison pour <b>A1</b> , <b>A2</b> , et <b>A3</b> .	87

## LISTE DES FIGURES

Figure 1.1	Courbe de puissance typique d'une éolienne de 2.5 MW . . . . .	5
Figure 2.1	Exemple de grille. Image libre de droits [23] . . . . .	9
Figure 2.2	Utilisation des méthodes statistiques . . . . .	10
Figure 2.3	Structure d'un réseau de neurones artificiels . . . . .	12
Figure 2.4	CP [67]. Reproduction avec autorisation © Siemens Gamesa. . . . .	18
Figure 3.1	Cycle du filtre de Kalman . . . . .	23
Figure 3.2	Fonctionnement du filtre de Kalman . . . . .	28
Figure 3.3	Schéma des modèles étudiés . . . . .	33
Figure 3.4	Étapes de la combinaison . . . . .	34
Figure 4.1	Analyse des données historiques du site #4 . . . . .	44
Figure 4.2	MAE en fonction de la direction pour le site #3 . . . . .	44
Figure 4.3	Validation des modèles . . . . .	45
Figure 4.4	Distributions des erreurs sur la vitesse pour le site #20 . . . . .	49
Figure 4.5	Exemple d'instabilité pour le site #4 . . . . .	50
Figure 4.6	Exemple de détection pour le site #7 . . . . .	50
Figure 4.7	Biais moyen en fonction de l'horizon . . . . .	51
Figure 4.8	MAE et RMSE moyens en fonction de l'horizon . . . . .	52
Figure 4.9	Amélioration moyenne par rapport aux PNTs en fonction de l'horizon	53
Figure 4.10	Distributions des erreurs sur la vitesse . . . . .	53
Figure 4.11	Distributions des erreurs sur la vitesse . . . . .	54
Figure 4.12	RMSE moyen en fonction de l'horizon pour le site #9 . . . . .	55
Figure 4.13	Combinaison des modèles pour le site #17 . . . . .	56
Figure 4.14	Biais moyen en fonction de l'horizon pour la combinaison . . . . .	59
Figure 4.15	MAE et RMSE en fonction de l'horizon . . . . .	59
Figure 4.16	Amélioration de la combinaison par rapport aux PNTs . . . . .	60
Figure 4.17	Distributions des erreurs sur la vitesse . . . . .	60
Figure 4.18	Réduction des instabilités . . . . .	61
Figure 4.19	Réduction des instabilités . . . . .	61
Figure 5.1	Courbes de puissance (CP) . . . . .	63
Figure 5.2	<b>A1</b> - Distribution des erreurs sur la puissance pour le site #20 . . . . .	66
Figure 5.3	<b>A1</b> - Biais (ME) moyen en fonction de l'horizon . . . . .	66
Figure 5.4	<b>A1</b> - MAE et RMSE moyens en fonction de l'horizon . . . . .	67
Figure 5.5	<b>A1</b> - Amélioration des MAE et RMSE moyens en fonction de l'horizon	67

Figure 5.6	<b>A1</b> - Distributions des erreurs sur la puissance . . . . .	68
Figure 5.7	<b>A1</b> - Puissance en fonction du temps pour le site #15 ( $h = 1$ ) . . . . .	70
Figure 5.8	<b>A2</b> - Distributions des erreurs sur la puissance pour le site #20 . . . . .	73
Figure 5.9	<b>A2</b> - Biais (ME) moyen en fonction de l'horizon . . . . .	74
Figure 5.10	<b>A2</b> - MAE et RMSE moyens en fonction de l'horizon . . . . .	74
Figure 5.11	<b>A2</b> - Amélioration des MAE et RMSE moyens en fonction de l'horizon	75
Figure 5.12	<b>A2</b> - Distributions des erreurs sur la puissance . . . . .	75
Figure 5.13	<b>A2</b> - Puissance en fonction du temps pour le site #15 ( $h = 1$ ) . . . . .	76
Figure 5.14	<b>A3</b> - Distributions des erreurs sur la vitesse pour le site #20 . . . . .	80
Figure 5.15	<b>A3</b> - Biais (ME) moyen en fonction de l'horizon . . . . .	80
Figure 5.16	<b>A3</b> - MAE et RMSE moyens en fonction de l'horizon . . . . .	81
Figure 5.17	<b>A3</b> - Amélioration des MAE et RMSE moyens en fonction de l'horizon	81
Figure 5.18	<b>A3</b> - Distributions des erreurs sur la puissance . . . . .	82
Figure 5.19	<b>A3</b> - Puissance en fonction du temps pour le site #15 ( $h = 1$ ) . . . . .	83
Figure 5.20	<b>A3</b> - Puissance en fonction du temps pour le site #15 ( $h = 1$ ) . . . . .	83
Figure 5.21	Biais (ME) moyen des meilleurs modèles pour A1, A2 et A3 . . . . .	84
Figure 5.22	MAE et RMSE moyens des meilleurs modèles pour A1, A2 et A3 . . . . .	85
Figure 5.23	Distributions des erreurs des meilleurs modèles pour A1, A2 et A3 . . . . .	85
Figure 5.24	Biais (ME) moyen des combinaisons pour A1, A2 et A3 . . . . .	86
Figure 5.25	MAE et RMSE moyens des combinaisons pour A1, A2 et A3 . . . . .	86
Figure 5.26	Distributions des erreurs des combinaisons pour A1, A2 et A3 . . . . .	87
Figure A.1	MAE en fonction de la direction pour le site #10 . . . . .	101
Figure A.2	MAE en fonction de la direction pour le site #11 . . . . .	101
Figure A.3	MAE en fonction de la direction pour le site #13 . . . . .	102
Figure A.4	MAE en fonction de la direction pour le site #14 . . . . .	102
Figure C.1	Exemple d'instabilité . . . . .	104
Figure C.2	Exemple de détection . . . . .	104
Figure D.1	Combinaison, exemple 1 . . . . .	105
Figure D.2	Combinaison, exemple 2 . . . . .	105

## LISTE DES SIGLES ET ABRÉVIATIONS

ADALINE	Adaptive Linear Element Network
AEC	Adaptive Exponential Combination
ANFIS	Adaptive-Network-Based Fuzzy Inference System
AR	Autoregressive
ARCH	Autoregressive Conditionally Heteroscedastic
ARIMA	Autoregressive Integrated Moving Average
ARMA	Autoregressive Moving Average
ARX	Autoregressive with Exogenous Input
AWNN	Adaptive Wavelet Neural Network
BNEF	Bloomberg New Energy Finance
CMC	Service météorologique du Canada
CP	Courbe de puissance
CSSO	Chaotic Shark Smell Optimization
CVNN	Complex-Valued Neural Network
EC	Environnement Canada
EMD	Empirical Mode Decomposition
EPSO	Enhanced Particle Swarm Optimization
EWMA	Exponentially Weighted Moving Average
ffBPN	Feed-Forward Back Propagation Network
ffNN	Feed-Forward Neural Network
FK	Filtre de Kalman
GES	Gaz à effet de serre
GP	Grey Predictors
GWEC	Global Wind Energy Council
IEC	International Electrotechnical Commission
IRENA	International Renewable Energy Agency
ITSM	Improved Time Series Method
LF	Logique floue
MA	Moving Average
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
ME	Mean Error
MLP	Multi-Layer Perceptron

MOS	Model Output Statistics
NEO	New Energy Outlook
NRMSE	Normalized Root-Mean-Square Error
PNT	Prévision numérique du temps
REP	Reduced Error Pruning
RMSE	Root-Mean-Square Error
RBfN	Radial Basis Function Network
RNA	Réseaux de neurones artificiels
RNN	Recurrent Neural Network
SGPD	Système global de prévision déterministe
SRN	Simultaneous Recurrent Neural Network
ST	Série Temporelle
SVM	Support Vector Machine
SVMreg	Support Vector Machine regression
WT	Wavelet Transform

## LISTE DES SYMBOLES

### Notations pour le Filtre de Kalman

$t$	Indice dénotant le temps ( $h$ )
$h$	Indice dénotant l'horizon de prévision ( $h$ )
$t h$	Indice dénotant une variable prédictive au temps $t$ à partir du moment $t-h$
$PNT$	Indice dénotant une prévision faite par le modèle de PNT
$v$	Vitesse du vent ( $m/s$ )
$\hat{v}$	Vitesse du vent prédictive ( $m/s$ )
$p$	Puissance ( $kW$ )
$\hat{p}$	Puissance prédictive ( $kW$ )
$\hat{\theta}$	Direction du vent prédictive ( <i>radians</i> )
$x, \alpha, \beta, \gamma, \eta$	Coefficients des vecteurs d'état
$n$	Longueur du vecteur d'état
$l$	Longueur du vecteur d'observation (dans notre cas $l = 1$ )
$\mathbf{x}$	Vecteur d'état $[n \times 1]$
$\hat{\mathbf{x}}$	Vecteur d'état estimé $[n \times 1]$
$\mathbf{y}$	Vecteur d'observation (mesure) $[l \times 1]$
$\mathbf{m}$	Bruit de la mesure $[l \times 1]$
$\mathbf{w}$	Bruit du processus $[n \times 1]$
$\mathbf{u}$	Paramètre de contrôle $[n \times 1]$
$\mathbf{H}$	Matrice ou vecteur d'observation $[l \times n]$
$\mathbf{B}$	Matrice de contrôle $[n \times n]$
$\mathbf{F}$	Matrice de prédition $[n \times n]$
$\mathbf{K}$	Gain de Kalman $[n \times l]$
$\mathbf{Q}$	Covariance du bruit de processus $[n \times n]$
$\mathbf{R}$	Covariance du bruit de mesure $[l \times l]$
$\mathbf{P}$	Matrice de covariance du processus $[n \times n]$
$\mathbf{S}$	Matrice de covariance de la mesure $[l \times l]$

### Notations additionnelles pour la combinaison

$k$	Indice dénotant le $k^e$ modèle combiné
$K$	Nombre total de modèles combinés

$\hat{v}^C$	Vitesse du vent estimée par la combinaison des $K$ modèles ( $m/s$ )
$y$	Mesure (observation) de $v$ ( $m/s$ )
$z$	Mesure (équivalent de $y$ , pour l'approche de combinaison C2) ( $m/s$ )
$I$	Nouvelle information pour la combinaison C3
$B$	Poids non normalisés pour la combinaison C3
$D$	Distance de Cook
$H$	Poids déterminé par une distribution khi carré
$N$	Taille équivalente de l'échantillon
$\lambda^{Cook}$	Facteur d'oubli de Cook
$\omega$	Éléments de la diagonale de la matrice $\mathbf{W}$
$\chi_n^2$	Distribution khi carré avec $n$ degrés de liberté
$\hat{\mathbf{v}}$	Vecteur contenant les vitesses prédictes par les $K$ modèles [ $K \times 1$ ]
$\phi$	Vecteur contenant les poids attribués à tous les $K$ modèles contenus dans $\hat{\mathbf{v}}$ [ $K \times 1$ ]
$\hat{\mathbf{z}}$	Prévisions (équivalent de $\hat{\mathbf{v}}$ , pour l'approche de combinaison C2) [ $(K - 1) \times 1$ ]
$\beta$	Vecteur contenant les poids associés aux prévisions $\hat{\mathbf{z}}$ [ $(K - 1) \times 1$ ]
$\Omega$	Matrice de variance-covariance [ $K \times K$ ]
$\mathbf{W}$	Matrice diagonale de $\Omega$ [ $K \times K$ ]
$\hat{\Gamma}$	Dispersion de $\hat{\phi}$ ou $\hat{\beta}$ [ $K \times K$ ]

## Notations pour le calcul d'erreur

$e$	Erreur de prévision sur la vitesse ( $m/s$ )
$\epsilon$	Erreur de prévision sur la puissance (%) de $p_{nom}$ )
$Impr_I^{ref}$	Amélioration d'une méthode par rapport à une méthode de référence ( $ref$ ), pour l'indicateur $I$

## Autres notations

$A$	Surface balayée par les pales d'une éolienne ( $m^2$ )
$p_{nom}$	Puissance nominale d'une éolienne ou d'un parc éolien ( $kW$ )
$R_0$	Constante universelle des gaz parfaits ( $\frac{J}{mol \cdot K}$ )
$T$	Température ( $K$ )
$\rho$	Masse volumique de l'air ( $kg/m^3$ )
$\rho_0$	Masse volumique de l'air pour des pression et température standards de l'atmosphère ( $1,225 kg/m^3$ )

$v_{cut-in}$	Vitesse de démarrage de l'éolienne ( $m/s$ )
$v_{cut-out}$	Vitesse d'arrêt de l'éolienne ( $m/s$ )
$\mu$	Représente la moyenne d'une distribution gaussienne
$\Sigma$	Représente une matrice de covariance

**LISTE DES ANNEXES**

Annexe A	Analyse directionnelle des données historiques . . . . .	101
Annexe B	Temps de convergence des coefficients . . . . .	103
Annexe C	Comportement des modèles : vitesse en fonction du temps . . . . .	104
Annexe D	Comportement des modèles : vitesse en fonction du temps, avec combinaison . . . . .	105

## CHAPITRE 1 INTRODUCTION

### 1.1 Préambule

L'énergie éolienne est en constante croissance dans le monde. À la fin de l'année 2017, la puissance éolienne mondiale installée atteignait 540 gigawatts (GW), avec une croissance de 52 GW en 2017 seulement [29]. Selon le *New Energy Outlook 2017* (NEO), un rapport publié par le *Bloomberg New Energy Finance* (BNEF), la demande mondiale en énergie devrait augmenter de 58% entre 2017 et 2040, ce qui correspond à une augmentation annuelle d'environ 2% [7]. Les énergies renouvelables seront nécessaires afin d'atteindre les objectifs de réduction de gaz à effet de serre (GES) tout en comblant cette croissance de la demande énergétique. L'éolien étant l'une des énergies les moins dispendieuses (en \$/MWh), le marché favorisera par lui-même les investissements dans cette branche énergétique. Le NEO estime donc que 3300 milliards de dollars seront investis pour l'installation de nouvelles capacités éoliennes dans le monde d'ici 2040 [7]. D'ici 2021, on estime une puissance installée de 817 GW, ce qui correspond à une augmentation de plus de 50% comparativement à aujourd'hui [29].

En termes de coût, chaque année les éoliennes deviennent de plus en plus abordables : par exemple, les prix des développements éoliens en mer (ou *offshore*) ont drastiquement diminué récemment. En 2016, l'industrie du *offshore* prévoyait atteindre une cible de 100 €/MWh ( $\approx$ 160 \$/MWh en avril 2018) d'ici 2020 [29], alors qu'en novembre 2016, un projet au Danemark a été proposé à un prix aussi faible que 50 €/MWh ( $\approx$ 80 \$/MWh en avril 2018), bien en dessous des prix estimés. De plus, selon un rapport produit par l'*International Renewable Energy Agency* (IRENA) en 2016, les prix des parcs éoliens terrestres (*onshore*) pourraient diminuer de 26% d'ici 2025 [33]. Très récemment, en décembre 2017, un projet de parc terrestre en Alberta a été accepté à 31 \$/MWh. Il est à noter que le marché n'est pas seulement favorisé par la chute des prix des turbines elles-mêmes, mais aussi par les avancées récentes dans les réseaux électriques permettant une gestion plus facile des ressources intermittentes, comme l'énergie éolienne [29].

### 1.2 Éléments de la problématique

Le développement du marché éolien permet aussi de construire des réseaux électriques diversifiés, alimentés en moins grande proportion à partir de combustibles fossiles, ce qui les rend plus sécuritaires en termes d'indépendance énergétique. Le caractère intermittent des nouvelles sources renouvelables force aussi les réseaux à évoluer de sorte à devenir plus robustes face à ces grandes variations.

Les défis associés à l'énergie éolienne sont encore considérables : d'une part, il est bien connu qu'il existe encore une grande résistance face aux questions d'acceptabilité sociale (pollution sonore, pollution visuelle, etc.) ; d'autre part, la nature relativement imprévisible des ressources éoliennes complexifie leur pénétration en grande proportion dans les réseaux électriques. Plus précisément, la forte variabilité et l'imprévisibilité du vent rendent difficile la gestion de l'offre de puissance en fonction de la demande, ainsi que la gestion de la stabilité du réseau [32].

Au niveau économique, bien qu'il s'agisse d'un des choix les moins coûteux parmi les sources de production d'électricité [10], l'éolien doit néanmoins rester concurrentiel par rapport à d'autres méthodes de production d'énergie. En effet, comme les ressources de vent varient d'une région à l'autre dans le monde, il est possible qu'à certains endroits l'énergie éolienne disponible ne soit pas suffisante pour que les coûts demeurent avantageux [21]. Ainsi, bien que les coûts de construction des parcs diminuent continuellement, il est nécessaire de continuer à améliorer le rendement des éoliennes ainsi que des procédés d'exploitation afin de maximiser leur rentabilité.

Dans certains cas, le prix de vente de l'énergie éolienne est fixé par des tarifs de rachat (*feed-in-tariffs*) qui sont implantés pour encourager le développement des énergies renouvelables. Ces tarifs de rachat permettent d'assurer aux développeurs un prix de vente fixe, garanti pour une durée déterminée (généralement pour la durée de vie du projet). En revanche, d'autres producteurs ne bénéficient pas de ce genre de programmes et doivent être assujettis aux prix fixés par le marché de l'énergie. Si tel est le cas, les producteurs doivent proposer des offres de génération à l'avance, donc prévoir la quantité d'énergie qui sera produite à court terme. En général, ils peuvent corriger leurs prévisions quelques heures avant la vente, et selon les législations en vigueur, des pénalités peuvent leur être facturées pour tout écart entre la production réelle et celle qui avait été offerte lors de la vente [58].

Pour augmenter la profitabilité des parcs, il est donc fondamental de s'attaquer à la nature variable des ressources éoliennes. Améliorer la précision des prévisions de production éolienne à court terme (entre 1 et 12 heures à l'avance) est essentiel afin d'atteindre cet objectif. Ce progrès permettrait d'abord de réduire certains frais associés aux processus d'exploitation, par exemple en planifiant les opérations d'entretien qui nécessitent des arrêts de turbines aux moments les moins venteux, et ce, en vue de minimiser les pertes de production. Ensuite, pour les producteurs assujettis aux prix du marché, des prévisions à court terme améliorées permettraient de réduire les pénalités liées aux écarts entre anticipation et réalisation de puissance. Aussi, de meilleures prévisions faciliteront la gestion de l'offre et de la demande énergétique pour les opérateurs de réseaux. Cette amélioration favorisera l'intégration des

éoliennes sur les réseaux électriques et par le fait même, les gouvernements seront plus encouragés à soutenir le développement de l'énergie éolienne.

En somme, l'objectif central de cette recherche est d'améliorer les techniques existantes de prévision du vent et de la production éolienne à court terme, ce qui permettrait ultimement de maximiser la rentabilité des parcs éoliens et en favoriser le développement. WPred, une entreprise québécoise offrant des services de prévision pour les parcs éoliens, s'est intéressée au sujet. Elle souhaite participer à l'avancement de la recherche dans ce domaine afin d'améliorer ses services, c'est donc elle qui a été l'instigatrice du projet. Ainsi, c'est à partir d'une collaboration entre WPred et l'École Polytechnique de Montréal que ce projet de recherche a été lancé.

### 1.3 Définitions et concepts de base

De nombreuses études ont déjà été menées au sujet des prévisions de la vitesse du vent, et ce, sur divers horizons. Le terme *horizon*, très souvent utilisé dans le domaine, décrit le pas de temps sur lequel est réalisée la prévision. En d'autres termes, une prévision faite pour un horizon de 2 h correspond à la prévision d'une variable 2 heures dans le futur. Les différentes méthodes répertoriées dans la littérature fonctionnent plus ou moins bien selon l'horizon étudié. De façon générale, les horizons de prévision peuvent être regroupés en trois grandes catégories [68, 74] :

Tableau 1.1 Horizons de prévision

<b>Très court terme</b>	Quelques minutes à quelques heures
<b>Court terme</b>	Jusqu'à 24 h
<b>Long terme</b>	Plusieurs jours à quelques semaines

Tel que mentionné plus haut, l'objectif de ce projet est d'améliorer les prévisions pour des horizons de 12 heures et moins, ce qui correspond au court terme.

#### 1.3.1 Méthodes de prévision

Les méthodes de prévision de vent peuvent être divisées en deux principales catégories : les méthodes à base physique et les méthodes statistiques.

**Méthode physique.** La méthode physique, généralement appelée prévision numérique du temps (PNT), est basée sur des équations et des paramètres physiques de l'atmosphère comme le relief, la rugosité du terrain, la pression et la température, ainsi que l'interaction de plusieurs phénomènes physiques entre eux. Lorsqu'on connaît l'état de l'atmosphère au

moment présent, on peut, à l'aide de simulations informatiques, simuler l'évolution du système actuel en se basant sur une multitude de lois physiques [22]. Le développement d'un tel modèle est très complexe, et les ressources informatiques nécessaires à son fonctionnement sont substantielles. La prévision météorologique étant stratégique pour un pays, les modèles de PNT sont par conséquent généralement réalisés par des agences gouvernementales. Par exemple, elle est produite aux États-Unis par la NOAA, en France par Météo-France et au Canada par Environnement Canada. Bien que très répandus et largement utilisés partout dans le monde, les modèles physiques présentent certaines faiblesses. D'abord, comme ces modèles se basent sur les conditions initiales des paramètres de l'atmosphère, la moindre erreur dans les variables de départ peut se propager et s'amplifier avec l'évolution dans le temps. De plus, comme ces modèles nécessitent une quantité excessive de ressources informatiques, la résolution spatiale des prévisions est limitée [22]. Par exemple, un modèle de prévision qui couvre le monde entier ne pourra pas aller au-delà d'une résolution spatiale de quelques kilomètres ou plus, et des méthodes de réduction d'échelle (*downscaling*) doivent être utilisées pour étudier des phénomènes à plus petite échelle. En général, des méthodes statistiques de sortie de modèle, *Model Output Statistics* (MOS), sont utilisées pour réduire les erreurs reliées à la PNT [28]. Par ailleurs, comme le temps de calcul est très élevé, les prévisions numériques sont exécutées généralement entre 2 et 4 fois par jour seulement, ce qui constraint leur utilisation au moyen terme et au long terme [68].

**Méthode statistique.** L'approche statistique, quant à elle, ne tient pas compte de l'environnement physique pour prédire la vitesse du vent. Elle permet d'atteindre des précisions accrues pour le court terme comparativement aux modèles physiques [56], et comme son nom l'indique, est basée sur des méthodes statistiques. Une multitude de techniques de ce genre ont été étudiées pour la prévision du vent ; de façon générale, les modèles sont entraînés sur un ensemble de données historiques permettant d'ajuster les paramètres des modèles à partir des vitesses de vent prédites et observées. Habituellement, ils impliquent des techniques d'intelligence artificielle comme les réseaux de neurones artificiels (RNA), ou des approches par série temporelle (ST). Des approches mixtes combinant différentes méthodes (statistiques et physiques) sont aussi couramment utilisées. Pour le court terme, la précision des prévisions peut également être considérablement améliorée lorsqu'on dispose de données mesurées aux turbines en temps presque réel. On nomme techniques de prévision immédiate (*nowcast*) les méthodes permettant d'ajuster les prévisions météorologiques issues des modèles de PNT en tenant compte des observations en temps presque réel. Cela étant dit, puisque l'objectif du projet consiste à améliorer les prévisions à court terme, ce seront les méthodes statistiques et le *nowcast* qui seront considérés.

### 1.3.2 Conversion en puissance

Les éoliennes servent à convertir l'énergie cinétique du vent en électricité. Cette conversion est décrite par une courbe de puissance (CP) propre à chaque modèle d'éolienne, reliant la vitesse du vent à la hauteur du moyeu à la puissance produite. Les modèles décrits précédemment permettent de prévoir la *vitesse du vent*, alors que dans le cadre du projet, il est aussi question de prévoir la *puissance* produite par les parcs éoliens. Par conséquent, les vitesses doivent être converties en puissances générées, ce qui est réalisé à l'aide d'une CP. De façon générale, ces courbes ont toutes une forme similaire, tel que présenté à la Figure 1.1.

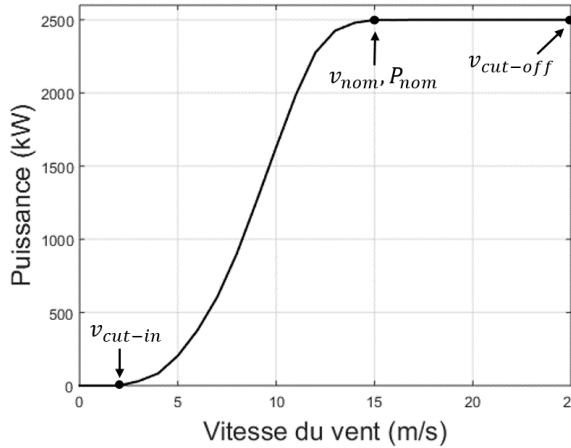


Figure 1.1 Courbe de puissance typique d'une éolienne de 2.5 MW

Sous la vitesse de vent de démarrage (ou  $v_{cut-in}$  en anglais), la puissance produite est nulle. Cette valeur est propre à chaque turbine et dépend de sa conception : elle est généralement entre 2 et 4 m/s [30]. Ensuite, la puissance produite augmente rapidement jusqu'à la puissance nominale  $P_{nom}$  (généralement entre 12 et 16 m/s), qui correspond à la puissance maximale pour laquelle la turbine a été conçue. Puis, la puissance reste constante jusqu'à ce que la vitesse du vent atteigne la vitesse de coupure ( $v_{cut-off}$ ), entre 20 et 30 m/s [30]. À ce moment, la turbine est arrêtée complètement afin d'éviter les bris pouvant être associés à des vitesses de vent trop élevées.

Dans la section de la courbe située entre  $v_{cut-in}$  et  $v_{nom}$ , la puissance croît rapidement. Cette augmentation abrupte est expliquée par la relation entre la puissance contenue dans un courant de vent et sa vitesse, qui suit en théorie une fonction cubique :

$$p = \frac{1}{2} \rho_{air} A v^3 \quad (1.1)$$

En pratique, la partie de droite de l'équation précédente est multipliée par le facteur  $C_p$ , qui correspond au rendement de l'éolienne. En effet, la loi de Betz stipule qu'indépendamment du design des éoliennes, les conditions géométriques font en sorte qu'il n'est pas possible de capturer plus de 59% de l'énergie du vent. En général, les turbines atteignent au maximum 75% à 80% de cette limite [9].

L'approche la plus simple pour convertir la vitesse du vent en puissance consiste à utiliser la courbe de puissance fournie par le manufacturier. Toutefois, plusieurs études démontrent qu'une CP faite sur mesure à partir des données de vent et de puissance mesurées sur place mène à des résultats plus précis [28]. De fait, cette dernière option peut améliorer l'erreur quadratique moyenne, ou RMSE, de 20% sur la puissance comparativement à l'utilisation de la courbe de puissance du manufacturier [78].

En bref, le but central de ce projet est d'améliorer les prévisions de vitesse de vent et de puissance pour le court terme, plus précisément pour des horizons de 1 à 12 heures. Afin d'y parvenir, il est d'abord nécessaire d'effectuer une revue de littérature des méthodes statistiques existantes pour bien cerner ce qui a été étudié jusqu'à ce jour et ce qui s'applique le mieux à notre problématique. Une fois cette revue terminée, il sera possible de déterminer le modèle mathématique le plus prometteur qui sera, dans le cadre du projet, exploré, bonifié et amélioré.

#### 1.4 Plan du mémoire

Ce mémoire présente les informations pertinentes à la compréhension du projet, ainsi que les résultats obtenus. Tout d'abord, un premier chapitre sera consacré à la revue des méthodes de prévision de vent à court terme. Les atouts et les inconvénients de chaque modèle seront discutés, dans l'objectif de déterminer la méthodologie à explorer pour la prévision des vitesses de vent. Une section de ce chapitre sera également consacrée à une revue des principales méthodes de conversion de la vitesse en puissance. Par la suite, les méthodes envisagées pour la correction de la puissance seront discutées et finalement, les méthodes d'évaluation de la performance des prévisions seront décrites.

Ensuite, un chapitre présentera les détails et le développement de la solution choisie. En premier lieu, la théorie derrière la technique sélectionnée sera introduite. En second lieu, la nouvelle approche développée pour la prévision des vitesses de vent sera décrite en détail.

Une section sera ensuite dédiée aux résultats du nouveau modèle au niveau des prévisions de vitesses de vent. D'abord, les données disponibles pour l'étude seront détaillées, puis une étude préliminaire sera présentée afin de justifier l'intérêt de l'approche envisagée. Enfin, les

résultats du modèle développé seront analysés de façon exhaustive.

Finalement, un dernier chapitre traitera des résultats de l'application des modèles aux données de prévision de la puissance. Trois différentes approches seront évaluées et comparées entre elles.

## CHAPITRE 2 REVUE DE LITTÉRATURE

Les premiers travaux importants concernant les prévisions de la vitesse du vent à court terme ont été publiés dans les années 1980 [17]. Le propos étant encore d'actualité aujourd'hui, plusieurs méthodes continuent d'être développées jusqu'à ce jour. Ces méthodes possèdent toutes leurs contraintes et leurs limites, chacune performant plus ou moins bien selon l'horizon de prévision. Récemment, le développement du court terme a été prédominant en raison de son importance pour les systèmes électriques [70]. Les différentes méthodes existantes sont analysées dans les sections suivantes afin de déterminer la méthode la plus prometteuse, qui sera utilisée et poussée plus loin dans le cadre du projet.

Il est important de mentionner que comparer plusieurs modèles entre eux n'est pas évident, et ce, pour plusieurs raisons. D'abord, il n'existe pas de mesure de performance standard permettant de comparer arbitrairement les résultats obtenus dans les études publiées à ce jour. La complexité du terrain et la qualité des données, par exemple, peuvent influencer grandement la performance de certains modèles. Ainsi, puisque les études existantes ont été réalisées sur des sites différents, une comparaison quantitative est plus ardue. Pour plusieurs cas, les méthodes étudiées sont comparées soit au modèle physique, soit au modèle dit de persistance, qui est généralement considéré comme une approche appropriée pour comparer les résultats entre différentes études. Le modèle de persistance correspond simplement à estimer que les valeurs des prévisions au temps  $t + h$  (où l'horizon de prévision vaut  $h = 1, 2, 3, \dots$ ) sont égales à la valeur observée de la variable au temps  $t$  :

$$x_{t+h} = x_t, \quad h = 1, 2, 3, \dots \quad (2.1)$$

Il est à noter que dans les sections suivantes, la revue sera centrée sur les études fournissant des indicateurs d'erreurs quantitatifs et permettant la comparaison avec les autres études.

### 2.1 Modèles physiques

Les modèles physiques ne sont pas précis pour les prévisions à court terme, étant donné leur temps de calcul très élevé. Néanmoins, plusieurs approches statistiques hybrides ont recours aux prévisions des PNTs comme paramètres d'entrée.

Les prévisionnistes effectuant des prévisions à partir de modèles physiques reçoivent les résultats des modèles de prévision numérique du temps par courrier électronique ou par service FTP [42]. Ils sont couramment émis sous forme de grille grossière ayant une résolution de

plusieurs kilomètres. Au Canada, le modèle disponible est le Système global de prévision déterministe (SGPD) du modèle GEM (Global Environmental Multiscale) d'Environnement Canada. Celui-ci possède une résolution effective d'environ 25 km, soit de  $0,24^\circ \times 0,24^\circ$  [23] (la Figure 2.1 illustre le concept, mais ne correspond pas à la résolution réelle du modèle).

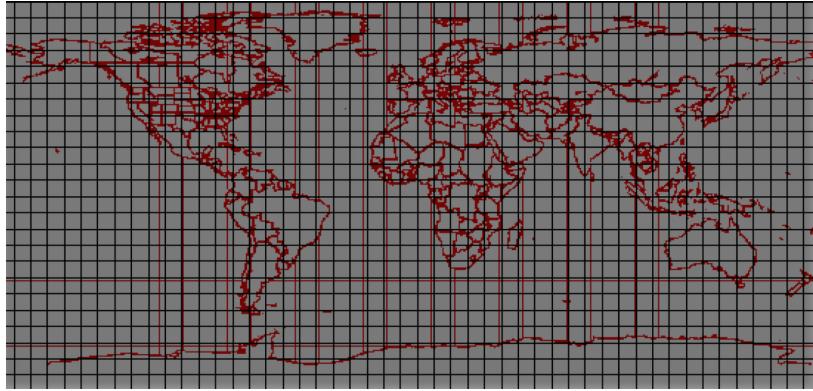


Figure 2.1 Exemple de grille. Image libre de droits [23].

La résolution spatiale de ces modèles a une influence majeure sur la précision des prévisions, ce qui est encore plus significatif dans le cas de terrains complexes. La combinaison de plusieurs méthodes (physiques et statistiques) est donc cruciale pour réduire l'erreur [37]. Pour le Système global de prévision déterministe (SGPD), les prévisions sont générées toutes les 12 heures pour un horizon de 10 jours, avec un pas de temps de 3 h. Comme mentionné précédemment, les modèles physiques sont conçus et performant mieux pour les prévisions à long terme.

## 2.2 Modèles statistiques

Les modèles statistiques, quant à eux, sont orientés vers les prévisions à très court et court terme [56] : ce seront donc ceux-ci qui sont étudiés dans le cadre du projet. Ils s'entraînent généralement sur des données d'observations historiques, en se basant sur les vitesses de vent prédites et réelles pour ajuster les paramètres du modèle (voir la Figure 2.2). Certains utilisent les données brutes des modèles de PNT, d'autres non. Comparativement aux approches physiques, l'approche statistique est beaucoup moins exigeante en termes de temps de calcul et de ressources. En effet, comme les processus météorologiques ne sont pas explicitement représentés par des modèles mathématiques complexes, la prévision est plutôt basée sur la reconnaissance de motifs dans le temps [70]. Les deux approches les plus répandues actuellement sont les méthodes conventionnelles basées sur des séries temporelles, ainsi que les méthodes d'apprentissage (*machine learning*).

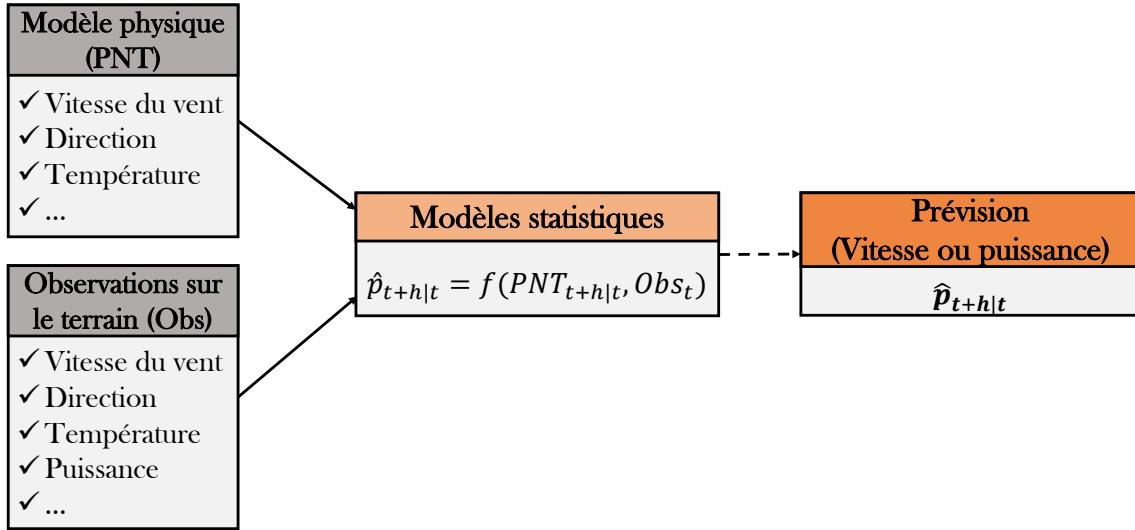


Figure 2.2 Utilisation des méthodes statistiques

### 2.2.1 Séries temporelles

Ce type de technique nécessite un ensemble de données historiques en ordre chronologique représentant l'évolution des vitesses de vent dans le temps. Ces informations servent à entraîner les modèles avant de les appliquer. Parmi les plus populaires, on retrouve le modèle *Autoregressive Moving Average* (ARMA) et ses dérivées. La méthode de la persistance, décrite au début de ce chapitre, est considérée comme l'approche la plus simple par série temporelle.

Cette approche est purement statistique, c'est-à-dire que l'entraînement est effectué seulement sur des données observées historiques, et aucune information provenant de modèles physiques n'est considérée. La méthode Box-Jenkins propose d'appliquer les modèles *Autoregressive* (AR), *Moving Average* (MA), *Autoregressive Moving Average* ou *Autoregressive Integrated Moving Average* (ARIMA) afin de déterminer les paramètres correspondant le mieux aux données historiques d'une série temporelle. Le modèle typique  $ARMA(p, q)$  d'ordre  $p$  (partie autorégressive) et  $q$  (partie moyenne mobile) est de la forme suivante :

$$x_t = \sum_{i=1}^p \varphi_i x_{t-i} + \sum_{j=1}^q \theta_j \alpha_{t-j} + \alpha_t \quad (2.2)$$

où  $x_t$  la vitesse du vent prédite au temps  $t$ ,  $\varphi_i$  est le paramètre autorégressif (AR),  $\theta_j$  le paramètre de moyenne mobile (MA), et  $\alpha_t$  le bruit blanc normal [43]. Il est possible de retrouver facilement les modèles AR et MA en posant respectivement les paramètres de moyenne mobile ( $q$ ) et autorégressif ( $p$ ) égaux à zéro. Si la série temporelle n'est pas stationnaire, la

forme  $ARIMA(p, d, q)$ , quant à elle, peut être obtenue en différenciant la forme ARMA,  $d$  fois, jusqu'à ce que la stationnarité soit atteinte [65].

Milligan et Schwartz ont testé différents modèles ARMA pour un horizon de 6 h sur deux parcs éoliens aux États-Unis. Ils ont testé environ 175 configurations du modèle (différents  $p$  et  $q$ ) et en ont conclu que les résultats sont très dépendants des paramètres du modèle ainsi que de la période d'entraînement. Par exemple pour une période d'entraînement d'un mois en mars, ils n'ont pas obtenu d'amélioration significative par rapport à la persistance pour le mois suivant, alors que pour un entraînement en avril, ils ont pu réduire le RMSE par rapport à la persistance de 11% au mois de mai, pour 6 heures d'horizon. Ils en déduisent qu'une période d'entraînement trop courte pourrait omettre certaines informations importantes pour la précision du modèle : idéalement, elle devrait couvrir au moins une année entière afin de capturer les motifs et variations à différents moments de l'année [53]. Torres et coll. ont aussi étudié le modèle ARMA pour 5 sites en Espagne, en déterminant des paramètres spécifiques à chaque site et pour chaque mois de l'année. Ils sont parvenus à réduire le RMSE par rapport à la persistance de 12% à 20% pour un horizon de 10 heures [71].

Les modèles ARMA ont aussi été couplés à d'autres modèles statistiques pour tenter d'améliorer leur précision. Dans [44], une technique utilisant le *Improved Time Series Method* (ITSM) basé sur un modèle ARIMA a été étudiée. En bref, les modèles sont entraînés sur des séries temporelles qui ont été divisées en sous-séries par décomposition en ondelettes (*wavelet decomposition*) afin de considérer la non-stationnarité des séries. Une fois les prévisions effectuées pour chaque sous-série, elles sont agrégées afin de calculer la prévision finale. L'étude montre que les prévisions jusqu'à 10 h d'horizon peuvent être améliorées comparativement aux modèles statistiques classiques sans décomposition. D'autres modèles combinant ARIMA et *Autoregressive Conditionally Heteroscedastic* (ARCH) ont été étudiés, pour prévoir les vitesses de vent, avec et sans décomposition par ondelettes. Dans les deux cas, l'erreur a pu être réduite comparativement au modèle ARIMA traditionnel [49, 73].

En somme, les méthodes de prévisions statistiques classiques sont basées sur le modèle ARMA et ses dérivées. La méthode Box-Jenkins est utilisée pour identifier les meilleurs modèles ( $p$  et  $q$ ) et estimer les paramètres de l'équation 2.2. Ce sont des outils assez faciles à utiliser, mais qui nécessitent une grande quantité de données pour atteindre une précision raisonnable. Une période d'au moins un an de données est nécessaire pour entraîner les modèles. Aujourd'hui, avec l'amélioration continue de la précision de la prévision, ces types de modèles sont fréquemment utilisés comme modèle de référence [35].

### 2.2.2 Approches par apprentissage

Les méthodes d'apprentissage explorées jusqu'à ce jour, aussi communément appelées méthodes d'intelligence artificielle (IA), incluent les réseaux de neurones artificiels (RNA), la logique floue (*fuzzy logic*), ainsi que plusieurs approches mixtes combinant les RNAs avec une ou plusieurs autres techniques.

#### Réseaux de neurones artificiels

À la base, les réseaux de neurones artificiels ont été inspirés du raisonnement des cerveaux humains. Ils tentent donc de reproduire le comportement des réseaux de neurones biologiques qui composent les cerveaux. Ils sont utilisés dans une multitude d'applications, notamment pour le traitement d'image, la reconnaissance automatique du langage, les jeux vidéo, la finance, etc.

Les RNAs sont parmi les modèles les plus fréquemment utilisés pour la prévision des vitesses de vent et de la puissance [35]. Ils sont entraînés en utilisant une grande quantité de données historiques ainsi que les prévisions brutes issues des PNTs. L'objectif est d'apprendre la relation entre les données brutes du modèle de PNT en entrée (vitesse, direction du vent, température, etc.) et les vitesses de vent ou les puissances mesurées en sortie.

Les réseaux de neurones artificiels sont constitués de plusieurs couches de neurones : une couche en entrée, une couche de sortie, et une ou plusieurs couches cachées (voir la Figure 2.3).

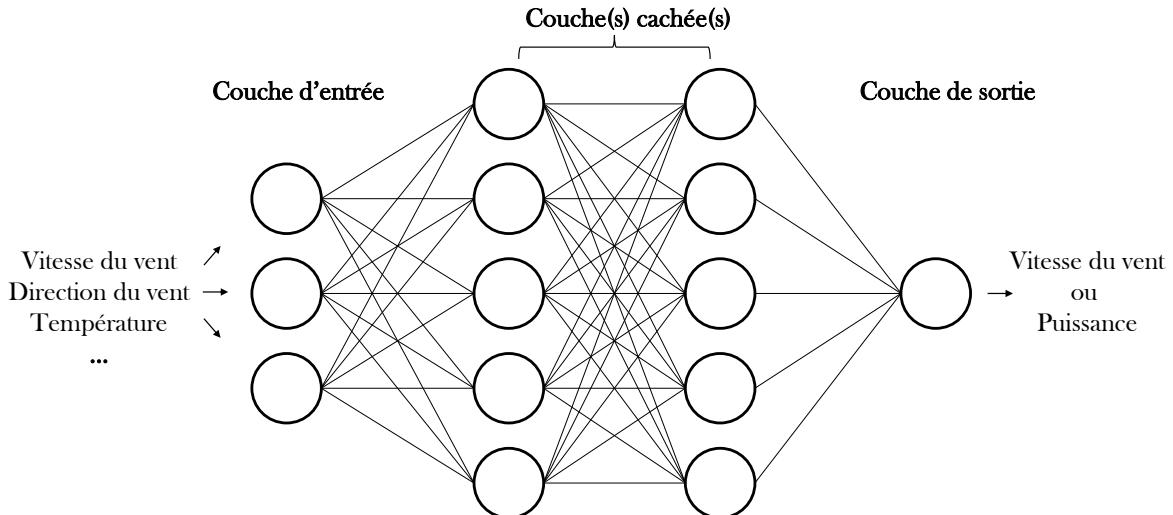


Figure 2.3 Structure d'un réseau de neurones artificiels

Chaque couche peut contenir plusieurs neurones qui sont connectés avec les neurones de couches précédentes, alors que celles qui se trouvent dans la même couche sont indépendantes entre elles. Chacun des neurones possède son propre poids et une fonction de transfert [43]. En général, les réseaux neuronaux performent mieux que les méthodes par séries temporelles [68, 43]. Il existe plusieurs types de RNAs : les *Multi-Layer Perceptron* (MLP) et les *Recurrent Neural Network* (RNN) sont parmi les plus couramment étudiés [24].

Au début des années 2000, les études sur les réseaux de neurones artificiels étaient plutôt centrées sur des modèles simples et la comparaison des RNAs aux modèles existants à ce moment. Panteri et coll. ont évalué la performance d'un *Radial Basis Function Network* (RBfN) à 9 neurones comparativement à la persistance et à un modèle *Autoregressive with Exogenous Input* (ARX). Ils sont parvenus à des NRMSE (RMSE normalisé sur la puissance nominale du parc) de 5% et 14% pour le RBfN pour des horizons entre de 1 h et 6 h respectivement. Leurs résultats démontrent que les RNAs performent mieux que le modèle ARX, et sont aussi plus précis que la persistance pour des horizons 4 heures et plus [57]. Également, Catalão et coll. ont proposé une approche utilisant un RNA entraîné par la méthode de Levenberg-Marquardt pour la prévision de la puissance au Portugal. Pour un horizon de 24 h, le *Mean Absolute Percentage Error* (MAPE) moyen sur la puissance est de 19,05% pour la persistance, de 10,34% pour ARIMA, alors que les RNAs surpassent les deux autres modèles avec une moyenne de 7,26%. [12]. Dans [47], un MLP testé sur un site éolien en Espagne a permis de déterminer que l'ajout de la direction comme paramètre d'entrée diminuait le RMSE sur la vitesse de 30% comparativement au modèle non directionnel. Welch et coll. ont comparé plusieurs structures différentes de RNA, soient les MLP, les RNN et les *Simultaneous Recurrent Neural Network* (SRN). Les modèles récurrents ont montré les meilleures performances, bien que leur plus grande précision implique un temps d'exécution plus élevé que les autres méthodes (soit 55 heures), ce qui peut limiter leur application [76].

Vers la fin des années 2000, des RNAs plus complexes ou combinés à d'autres méthodes ont été davantage étudiés. Dans [14] par exemple, un RNA est combiné à une transformée par ondelettes, ou *Wavelet Transform* (WT) en anglais. Pour un horizon d'une heure, ils sont parvenus à réduire le MAPE de 32% par rapport à la méthode ARIMA et de 3,6% par rapport au RNA sans WT. De façon similaire, un modèle de RNA combiné à une technique de décomposition des séries temporelles en sous-séries, le *Empirical Mode Decomposition* (EMD), a permis une amélioration de 35% par rapport à ARIMA, et de 12% comparativement au RNA traditionnel [45].

Dans [3], une combinaison de réseaux RBfN et MLP bonifiés par un *Enhanced Particle Swarm Optimization* (EPSO) pour l'entraînement a été testée. Un NRMSE de 7,5% a pu être atteint

pour un horizon d'une heure, soit une amélioration de 37% par rapport à la persistance. Une autre technique d'optimisation originale, le *Chaotic Shark Smell Optimization* (CSSO) a permis d'obtenir un RMSE sur la vitesse réduit de 13% par rapport à la méthode ARIMA pour un horizon d'une heure [1].

### RNA et logique floue

La logique floue (*Fuzzy Logic* en anglais) peut être décrite comme une évolution de la logique booléenne (vrai ou faux, 1 ou 0). Le concept est similaire, cependant la logique floue (LF) se base sur un intervalle continu de valeurs entre 0 et 1. Les modèles de logique floue ne possèdent pas la propriété de s'adapter, ce pour quoi dans le domaine des prévisions de vent, ils sont généralement combinés à un réseau de neurones artificiels, et on y réfère souvent par l'acronyme ANN-Fuzzy.

Le modèle *Adaptive-Network-Based Fuzzy Inference System* (ANFIS) proposé en 1993 dans [34] est un modèle ANN-Fuzzy utilisant un *Feed-Forward Neural Network* à six couches. Il a été étudié à quelques reprises pour des applications de prévision du vent [60, 13]. Dans [13], le NMAE sur la puissance a pu être réduit (en moyenne sur une année) de 68% et de 57% par rapport à la persistance et au modèle ARIMA respectivement, pour un horizon de 3 h. Un modèle ANN-Fuzzy a aussi été développé dans [66], permettant de réduire le NRMSE de 40% par rapport à la persistance pour un horizon de 10 h.

#### 2.2.3 Autres modèles

Certains modèles ont été développés de façon plus indépendante. Par exemple, un *Grey Predictor* (GP) étudié dans [31] utilise les 4 dernières heures de données historiques pour générer des prévisions. Les résultats se montrent encourageants, cependant ils n'ont pas été comparés avec aucune autre méthode existante et peu d'information numérique sur la performance est disponible, ce qui rend difficile leur évaluation. Des approches basées sur des processus gaussiens ont permis de réduire le MAE sur la vitesse du vent entre 12% et 27% par rapport à des modèles de RNA pour des horizons d'une heure [55, 40]. Un *Support Sector Machine* (SVM) a été étudié dans [54], et a atteint des performances supérieures comparativement au MLP. Plus de 5 ans de données étaient nécessaires pour entraîner le modèle. Finalement, dans [41], 5 approches de *data mining* ont été comparées : le *Support Vector Machine regression* (SVMreg), le MLP, le M5P tree, le *Reduced Error Pruning* (REP) et le *bagging tree algorithm*. Au final, il a été conclu que l'approche par RNA (MLP) surpassait toutes les autres. Une nouvelle approche combinant des RNAs ou des SVMs à un système de Lorenz afin de tenir compte des perturbations atmosphériques [80, 81, 82]. Cette approche

est prometteuse et permet de réduire significativement l'erreur de prévision comparativement aux RNAs et aux SVMs seuls, cependant les résultats obtenus à ce jour proviennent tous d'un seul et même parc éolien : plus de résultats seraient nécessaires pour démontrer son efficacité.

Il existe aussi certains modèles de corrélation spatiale permettant de combiner des méthodes statistiques à des mesures prises en temps réel sur des sites avoisinants [20, 5, 2]. Ces techniques ne seront cependant pas explorées dans le cadre de ce projet, puisque dans la réalité d'un prévisionniste, les données mesurées sur des sites adjacents sont très rarement disponibles.

## Filtre de Kalman

Le filtre de Kalman a été développé en 1960 par Rudolf E. Kalman, un ingénieur d'origine hongroise naturalisé américain. Il possède plusieurs applications aujourd'hui dans le domaine de l'aérospatiale pour le contrôle et la navigation de véhicules, ainsi qu'en traitement de signal par exemple [79]. En 2006, un premier article fut publié par Galanis et coll. à propos de l'application d'un filtre de Kalman aux prévisions de vent [25]. Ce dernier est conçu pour filtrer les erreurs systématiques des modèles de prévision numérique du temps. Ce sont des algorithmes récursifs qui permettent d'estimer les états d'un système dans le futur en tenant compte d'observations récentes. Ce type de prévisions à court terme se basant sur des données d'observation obtenues en temps quasi réel sont souvent appelées techniques de prévision immédiate, ou *nowcasting* en anglais. L'avantage du filtre de Kalman est qu'il est adaptatif et nécessite très peu de données historiques pour la calibration initiale.

Dans [48], le filtre de Kalman a été implémenté pour modéliser le biais des PNT comme un polynôme d'ordre 3. Pour un horizon de 24 h, le biais moyen pour la vitesse de vent a pu être réduit de plus de 90% par rapport aux prévisions du modèle physique utilisé. Au niveau de la puissance, les données filtrées présentaient un biais moyen de moins de 20% de la puissance nominale, alors qu'il dépassait 50% pour les prévisions brutes du modèle de PNT. Le filtrage de Kalman a aussi conduit à des améliorations au niveau du RMSE. Les auteurs ont également comparé les résultats obtenus par filtre de Kalman (FK) à des modèles numériques à plus petite échelle. Ils ont pu constater que les données filtrées à partir des modèles numériques à plus grande échelle (12 km) étaient de précision égale ou meilleure aux modèles numériques à haute résolution, qui eux sont très coûteux en termes de ressources informatiques. Dans un autre article, le FK a été testé pour le long terme, avec une actualisation du filtre à toutes les 12 heures. L'erreur absolue a pu être considérablement réduite, alors que l'impact sur le RMSE est plus faible [69].

Un FK a été appliqué sur deux sites en Italie pour un horizon plus court, soit 6 h. L'erreur systématique a pu être éliminée des données de PNT, et le MAE a pu être réduit de 37% par rapport aux prévisions brutes de vitesse du vent du modèle physique. Les résultats montrent à nouveau que la performance des modèles est très dépendante des sites et de la complexité des terrains. Les auteurs suggèrent d'ajuster la procédure de filtrage de façon individualisée pour chacun des sites étudiés [11]. Finalement, dans [83], un FK a été implémenté pour un parc éolien en Chine. Le RMSE sur la vitesse a pu être réduit de 23% comparativement au modèle numérique une fois le filtrage effectué pour un horizon de 24 h.

#### 2.2.4 Sommaire des méthodes de prévision statistiques

Le tableau 2.1 regroupe les principales caractéristiques des méthodes de prévisions du vent à court terme qui ont été passées en revue dans cette section.

Tableau 2.1 Résumé des méthodes statistiques

Catégorie	Méthode	PNT	Particularités
Séries temporelles	Persistance	Non	<ul style="list-style-type: none"> <li>- Méthode la plus simple, généralement surpassée par les autres méthodes</li> <li>- Souvent utilisée comme référence</li> </ul>
	Type ARMA	Non	<ul style="list-style-type: none"> <li>- 1 an ou plus de données historiques</li> <li>- Moins performante que les méthodes récentes</li> <li>- Facile à implémenter</li> </ul>
	Grey Predictor	Non	<ul style="list-style-type: none"> <li>- Nécessite seulement les dernières 4 heures de données historiques</li> <li>- Moins performante que les méthodes récentes</li> </ul>
	Filtre Kalman	Oui	<ul style="list-style-type: none"> <li>- Nécessite des observations en temps réel</li> <li>- Est adaptatif</li> <li>- Temps de calcul très court</li> <li>- Pas de données historiques nécessaires</li> <li>- Performances similaires aux RNAs</li> <li>- Seule la vitesse du vent est utilisée comme paramètre d'entrée</li> </ul>
Apprentissage	RNA, RNA-Fuzzy	Oui	<ul style="list-style-type: none"> <li>- 1 à 5 ans de données historiques</li> <li>- Méthode la plus répandue</li> <li>- Bonnes performances</li> <li>- Considère plusieurs variables météorologiques</li> <li>- Temps de calcul très élevé pour l'entraînement</li> </ul>
	SVM	Non	<ul style="list-style-type: none"> <li>- Performance inférieure aux RNAs</li> </ul>
Autres	Corrélation spatiale	Non	<ul style="list-style-type: none"> <li>- Ne s'applique pas si des données de sites avoisinants ne sont pas disponibles en temps réel</li> </ul>

À la lumière de cette revue de littérature, les deux approches ressortant du lot sont les RNA ainsi que les filtres de Kalman : les deux techniques performent très bien pour le court terme. En pratique, le filtre de Kalman possède l'avantage de ne pas nécessiter de données historiques pour être implémenté, contrairement aux RNAs. Pour un prévisionniste, cette approche est intéressante puisque de longues périodes de données historiques ne sont pas toujours disponibles lorsque les prévisions doivent être réalisées pour un nouveau parc éolien.

De plus, puisque le filtre utilise des données en temps réel, il est très réactif aux changements soudains dans la vitesse du vent et peut s'adapter rapidement, contrairement aux RNA qui sont entraînés sur un ensemble de données une seule fois, et conservent la même configuration pour toutes les prévisions futures. Le filtre de Kalman, quant à lui, se met à jour continuellement dès qu'une nouvelle donnée d'observation est disponible.

D'un point de vue physique, il est aussi intéressant d'utiliser ce modèle d'abord parce qu'il considère les PNTs, et aussi parce qu'il ne s'agit pas d'un «*black box*» comme les réseaux de neurones artificiels : la relation entre les vitesses de vent prédites et observées est décrite par des équations dont les paramètres varient en fonction du temps. Finalement, le coût informatique est considérablement plus élevé pour les RNAs que les FK, soit des dizaines, voir des centaines d'heures pour l'entraînement d'un RNA, alors que l'on parle de quelques secondes ou moins pour chaque nouvelle itération du filtre de Kalman.

Somme toute, bien que les RNAs semblent démontrer une performance légèrement supérieure aux filtres de Kalman, il serait intéressant de développer et bonifier les FK existants à ce jour. Actuellement, les filtres étudiés tiennent uniquement compte la vitesse du vent en entrée, alors que les approches par RNA incorporent souvent la direction du vent comme paramètre d'entrée [62, 60, 38].

Plus concrètement, il a aussi été démontré que parmi les paramètres météorologiques généralement disponibles, l'ajout de la direction en entrée d'un modèle permet particulièrement de réduire les erreurs de prévision [72, 27]. Dans le cadre de ce projet, il sera donc question de tenter d'améliorer les techniques de filtrage Kalman avec l'ajout d'une nouvelle variable météorologique, soit la direction du vent. Une analyse approfondie des modèles et de leurs erreurs sera effectuée afin de qualifier la performance de l'approche avancée.

### 2.3 Modélisation de la puissance

Une fois la vitesse du vent prédictée, elle doit être convertie en prévision de puissance produite par les turbines, puisque cette donnée est aussi importante pour les exploitants. La méthode la plus simple consiste à utiliser la courbe de puissance (CP) fournie par le manufacturier de l'éolienne pour une densité d'air fixée (voir la Figure 2.4).

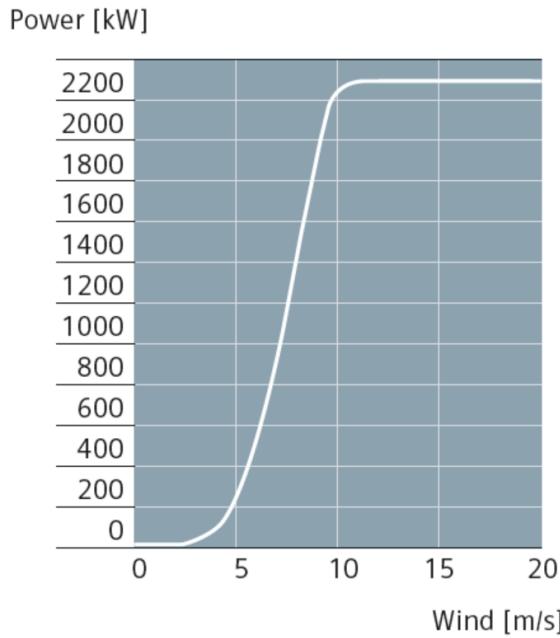


Figure 2.4 CP [67]. Reproduction avec autorisation © Siemens Gamesa.

Non seulement la courbe fournie par le manufacturier n'est pas précise, mais elle ne tient pas compte des spécificités du site sur lequel la turbine est installée et de la variation de la densité de l'air et de la proximité d'autres éoliennes avoisinantes (qui peuvent créer un effet de sillage). Si un ensemble de données historiques est disponible, il existe une panoplie de méthodes statistiques permettant de créer une courbe expérimentale, plus précise que la courbe du manufacturier. Il est aussi possible de tenir compte de la densité de l'air pour améliorer la conversion en puissance. Les approches fréquemment utilisées pour générer des courbes expérimentales sont la norme IEC et les techniques de modélisation paramétrique [50]. Les données des courbes de puissance fournies par WPred pour le projet ont été déterminées à l'aide de la méthode IEC.

### 2.3.1 Norme IEC

L'*International Electrotechnical Commission* (IEC) a développé une méthode standard pour l'évaluation des courbes de puissances, sous la norme 61400-12-1 [77]. La CP expérimentale est composée de plusieurs couples de données vitesse-puissance. La méthodologie IEC consiste à regrouper ces données en classes (*bins* en anglais) de 0.5 m/s selon les équations suivantes :

$$v_i = \frac{1}{N_i} \sum_{j=1}^{N_i} v_{n,i,j} \quad (2.3)$$

$$p_i = \frac{1}{N_i} \sum_{j=1}^{N_i} p_{n,i,j} \quad (2.4)$$

où  $v_i$  est la vitesse du vent normalisée moyenne dans la classe  $i$ ,  $v_{n,i,j}$  est la vitesse normalisée du couple de données  $j$  dans la classe  $i$ , et de même pour  $p_i$  et  $p_{n,i,j}$ .  $N_i$  correspond au nombre de couples de données dans la classe  $i$ . Les variables normalisées correspondent aux variables corrigées avec la densité de l'air. Pour calculer la vitesse normalisée, on a :

$$\rho_j = \frac{p_j}{R_0 \cdot T_j} \quad (2.5)$$

et

$$v_{n,j} = v_j \left( \frac{\rho_j}{\rho_0} \right)^{\frac{1}{3}} \quad (2.6)$$

où  $\rho_j$  est la densité de l'air associée au couple de données  $j$ ,  $p_j$  la pression atmosphérique,  $T_j$  la température et  $R_0$  la constante universelle des gaz parfaits.  $v_j$  est la vitesse non normalisée. Les valeurs moyennes obtenues pour chaque classe de vitesse constituent les points de la courbe de puissance IEC.

## 2.4 Méthodes de correction de la puissance

Dans certains cas, les observations de vitesse du vent ne sont pas disponibles. À ce moment, seules les données de puissance peuvent être utilisées pour corriger les prévisions : le *now-casting* sur la vitesse tel que décrit précédemment ne peut pas s'appliquer. Il s'agit d'une situation qui survient couramment en pratique. Très peu de recherche a été effectuée à ce jour pour le *nowcasting* sur la puissance directement. Cette section décrira les approches pouvant être appliquées à la problématique.

### 2.4.1 Inversion de la courbe de puissance

Dans [52], les auteurs proposent une approche visant à contourner les problèmes de non-linéarité pour la modélisation des courbes de puissance. Ils proposent de convertir les puissances observées en vitesses de vent à l'aide de la courbe de puissance inverse. Cela leur permet d'obtenir une courbe de *vitesse fictive* en fonction de la *vitesse mesurée*, pour laquelle des régressions linéaires beaucoup plus simples peuvent être appliquées. Dans le cadre du projet, il serait possible d'appliquer cette méthode pour transformer les puissances mesurées en « mesures de vitesses virtuelles ». Le filtre de Kalman pourrait être appliqué par la suite sur ces vitesses comme s'il s'agissait de mesures réelles afin de produire des prévisions de vitesses corrigées, qui seront ensuite reconvertis en puissance.

Il est à noter que cette conversion est appliquée seulement sur la plage de puissance située entre 0 et la puissance nominale, ainsi qu'entre la vitesse de *cut-in* et la vitesse de *cut-out*. Les vitesses transformées ( $v_i$ ) seront donc contraintes à des valeurs situées entre le *cut-in* et la vitesse nominale (voir la Figure 1.1). L'équation 2.7 exprime cette contrainte.

$$v_i = f^{-1}(p_i) = \begin{cases} v_{cut-in}, & v_i^* \leq v_{cut-in} \\ v_i^*, & v_{cut-in} < v_i^* < v_{nom} \\ v_{nom}, & v_i^* \geq v_{nom} \end{cases} \quad (2.7)$$

Il est à noter que la fonction de puissance inversée dans notre cas est la courbe IEC de la turbine en question.

### 2.4.2 Filtre de Kalman sur la puissance

Une deuxième approche pour corriger les valeurs de puissance pourrait être d'appliquer un filtre de Kalman sur la puissance directement, c'est-à-dire de corriger le biais entre la puissance observée et la puissance prédite à partir des vitesses de vent brutes du modèle de PNT. Jusqu'à très récemment, l'application d'un filtre de Kalman sur la puissance n'avait pas été explorée. En 2016, dans [15], un filtre de Kalman a été testé selon plusieurs configurations différentes dans le but de prédire la production de puissance : seulement sur la vitesse, seulement sur la puissance, et finalement sur la vitesse et la puissance. Le FK sur la puissance a permis d'améliorer de 23% de RMSE par rapport aux prévisions numériques. Il est à noter que les auteurs ont aussi montré que le filtre utilisé sur la vitesse seulement avait une meilleure performance que celui appliqué sur la puissance seulement. Le filtre appliqué aux deux variables donnait les meilleurs résultats, soit une amélioration de 8% comparativement à celui appliqué sur la vitesse seulement. Somme toute, cet article suggère non seulement que

l'ajout d'un deuxième filtre sur la puissance pourrait permettre de réduire les incertitudes introduites par les modèles de courbes de puissance, mais aussi que la correction par FK directement sur la puissance (pour les sites où la donnée de vent n'est pas disponible) donne de bons résultats. Le filtre appliqué dans cette étude corrige le biais comme une constante, et non comme un polynôme, comme il est fait dans [48] pour corriger la vitesse. Il serait donc intéressant d'étudier, pour la prévision de la puissance, les performances de biais modélisés par des polynômes d'ordres plus élevés, en plus d'introduire la direction du vent comme paramètre d'entrée.

## 2.5 Évaluation de la performance des modèles

Cette section présentera les principaux outils qui seront utilisés pour mesurer et caractériser la performance des prévisions. D'abord, il est nécessaire de calculer les erreurs pour chaque horizon individuellement, ce qui permet d'évaluer la performance du modèle selon l'horizon de prévision. Pour la vitesse du vent, l'erreur de prévision est définie comme la différence entre la valeur mesurée  $v_{t+h}$  et la valeur prédictive  $\hat{v}_{t+h|t}$  :

$$e_{t+h|t} := v_{t+h} - \hat{v}_{t+h|t} \quad (2.8)$$

Cette équation est appropriée pour déterminer les erreurs associées à la vitesse du vent. En revanche, pour la puissance  $p_t$ , il est pertinent de normaliser l'erreur par rapport à la puissance nominale du parc, ce qui permet de pouvoir comparer les performances des modèles entre des parcs différents (voir l'équation 2.9). L'erreur représente donc un pourcentage de la puissance maximale.

$$\epsilon_{t+h|t} := \frac{1}{P_{nom}}(p_{t+h} - \hat{p}_{t+h|t}) \quad (2.9)$$

Tout d'abord, l'erreur moyenne (aussi nommée l'erreur systématique, ou le biais), indique si le modèle a tendance à sur-prédire ou sous-prédire la variable météorologique (voir l'équation 2.10). Utilisé seul, cet indicateur ne permet pas de déterminer la qualité des résultats : un biais presque nul signifie uniquement que les biais positifs et négatifs s'annulent sur la période d'évaluation.

$$ME(h) = \frac{1}{N} \sum_{t=1}^N e_{t+h|t} \quad (2.10)$$

Une meilleure façon d'estimer la performance de la méthode est de calculer l'erreur absolue moyenne (*mean absolute error*, MAE) :

$$MAE(h) = \frac{1}{N} \sum_{t=1}^N |e_{t+h|t}| \quad (2.11)$$

L'erreur moyenne quadratique, ou *Root-Mean-Square Error* RMSE, est similaire au MAE, cependant elle donne une plus grande importance aux grands écarts. Ces deux indicateurs sont pertinents : combinés, ils permettent d'avoir une meilleure idée de la distribution des erreurs.

$$RMSE(h) = \sqrt{MSE(h)} = \sqrt{\frac{1}{N} \sum_{t=1}^N (e_{t+h|t})^2} \quad (2.12)$$

Finalement, un dernier indicateur très pertinent est le calcul d'amélioration par rapport à une méthode de référence (*Improvement*). Généralement, on compare les performances soit aux sorties du modèle physique brut pour étudier l'amélioration globale des prévisions, soit à la méthode de persistance qui correspond au modèle statistique le plus simple. Dans l'équation 2.13,  $I^{ref}(h)$  représente l'indicateur (ME, MAE, ou RMSE) de la méthode référence pour l'horizon  $h$ , et  $I(h)$  l'indicateur de la méthode que l'on veut comparer, par exemple un filtre de Kalman.

$$Impr_I^{ref}(h) = \frac{I^{ref}(h) - I(h)}{I^{ref}(h)} \quad (2.13)$$

## CHAPITRE 3 DÉTAIL ET DÉVELOPPEMENT DE LA SOLUTION CHOISIE

### 3.1 Description mathématique du filtre de Kalman

En 1960, R. E. Kalman publie son article notoire décrivant un algorithme récursif pour les problèmes de filtrage de données discrètes, algorithme maintenant connu sous le nom de *filtre de Kalman* [36]. À partir de ce moment, le filtre en question a été étudié de long en large, et souvent utilisé dans le domaine de l'automatisation de l'aviation. Dans cette section, le filtre de Kalman sera décrit de façon concise. Pour plus d'information ou pour une description mathématique plus exhaustive, plusieurs autres documents de référence sont disponibles, notamment [16], [8], [51] et [4].

Dans cette section, les matrices seront dénotées par des lettres majuscules en gras (ex : **A**, **B**, **C**) et les vecteurs par des lettres minuscules également en gras (ex : **x**, **y**, **z**).

#### 3.1.1 Équations de base

Le filtre de Kalman (FK) est basé sur des algorithmes récursifs permettant d'obtenir des estimations des états d'un système dynamique dans le futur. Il est conçu pour minimiser l'erreur quadratique. Le modèle est divisé en deux grandes étapes : d'abord, la *prévision*, puis la *correction* de cette valeur prédictive. Le filtre simule premièrement un processus inconnu afin de projeter vers l'avant (au prochain pas de temps) l'estimation actuelle, et de prévoir l'état futur du système. Puis, il raffine son estimation à l'aide d'une mesure (bruitée) de ce même système (voir la Figure 3.1) [6].

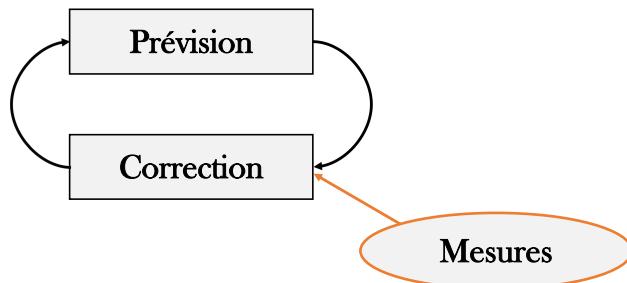


Figure 3.1 Cycle du filtre de Kalman

Le but du procédé est d'estimer un vecteur d'état au temps  $t$ , identifié  $\mathbf{x}_t$ , en se basant sur les observations ( $\mathbf{y}$ ) jusqu'au temps  $t$ . On considère que l'état  $\mathbf{x}_t$  et sa mesure  $\mathbf{y}_t$  sont des vecteurs de variables aléatoires, et donc qu'il s'agit d'un processus stochastique. Le processus est décrit par la suite récurrente linéaire présentée à l'équation (3.1), qu'on désigne comme l'*équation d'état*.

$$\mathbf{x}_t = \mathbf{F}_t \mathbf{x}_{t-1} + \mathbf{B}_t \mathbf{u}_{t-1} + \mathbf{w}_t \quad (3.1)$$

Dans cette équation,  $\mathbf{F}_t$  est appelée la matrice de *prédition*. Elle relie l'état  $\mathbf{x}_t$  à celui du pas de temps précédent,  $\mathbf{x}_{t-1}$ , dans un système sans influence externe. En présence d'un facteur exogène, on définit le paramètre de contrôle  $\mathbf{u}_t$ , avec  $\mathbf{B}_t$  qui le relie à l'état  $\mathbf{x}_t$ . Le facteur exogène correspond à un changement externe contrôlé, par exemple appuyer sur l'accélérateur d'une automobile. Finalement,  $\mathbf{w}_t$  est une variable aléatoire qui représente le *bruit du processus*.

La relation entre l'état et la mesure est quant à elle exprimée par l'*équation d'observation* :

$$\mathbf{y}_t = \mathbf{H}_t \mathbf{x}_t + \mathbf{m}_t \quad (3.2)$$

Dans cette équation, la matrice d'observation  $\mathbf{H}_t$  relie l'état  $\mathbf{x}_t$  à la mesure  $\mathbf{y}_t$ , dans le cas où les deux vecteurs n'ont pas les mêmes unités ou les mêmes dimensions. Dans le cas contraire, elle peut être remplacée par une matrice identité. Finalement,  $\mathbf{m}_t$  est aussi une variable aléatoire représentant cette fois le *bruit de la mesure*. Il est à noter qu'on considère que les bruits  $\mathbf{w}_t$  et  $\mathbf{m}_t$  sont des bruits blancs suivant une distribution normale de variance  $\mathbf{Q}_t$  et  $\mathbf{R}_t$  respectivement (voir l'équation (3.3)), et sont indépendants entre eux.

$$\mathbf{w}_t \sim N(0, \mathbf{Q}_t) \quad (3.3)$$

$$\mathbf{m}_t \sim N(0, \mathbf{R}_t) \quad (3.4)$$

### 3.1.2 Équations spécifiques

Pour appliquer le filtre de Kalman, les équations (3.1) et (3.2) sont divisées en deux parties : une partie représentant la transformation *connue* du processus, et une partie représentant la covariance.

**Étape 1 : prédition** Posons une estimation de l'état  $\hat{\mathbf{x}}_{t-1}$  initial qui possède une certaine covariance représentée par la matrice  $\mathbf{P}_{t-1}$ . D'abord, supposons un processus dynamique sans

influence externe pour l'*équation d'état*. Selon l'équation (3.1), notre meilleure prédiction de l'état au temps  $t$  est donnée par la relation (3.5) :

$$\hat{\mathbf{x}}_{t|t-1} = \mathbf{F}_t \hat{\mathbf{x}}_{t-1} \quad (3.5)$$

Dans l'équation ci-dessus, la notation «  $\hat{\cdot}$  » désigne une variable correspondant à une estimation d'un paramètre réel. La qualité de cette prédiction est évaluée grâce à une matrice de covariance d'erreur de prédiction. Grâce à l'identité

$$\text{cov}(\mathbf{C} \cdot \mathbf{x}) = \mathbf{C} \cdot \text{cov}(\mathbf{x}) \cdot \mathbf{C}^T, \quad (3.6)$$

il est possible d'appliquer la même transformation à la matrice de covariance :

$$\mathbf{P}_{t|t-1} = \mathbf{F}_t \mathbf{P}_{t-1} \mathbf{F}_t^T \quad (3.7)$$

La matrice de covariance  $\mathbf{P}_{t-1}$  représente la qualité de l'estimateur d'état à l'étape précédente, c'est à dire au temps  $t-1$ , alors que  $\mathbf{P}_{t|t-1}$  représente la qualité de la prédiction au temps  $t$  sur la base des observations passées. En ajoutant la variable exogène  $\mathbf{u}_{t-1}$  au système ainsi que la covariance du bruit du processus  $\mathbf{Q}_t$ , on obtient le système d'équations final ci-dessous.

$$\begin{cases} \hat{\mathbf{x}}_{t|t-1} = \mathbf{F}_t \hat{\mathbf{x}}_{t-1} + \mathbf{B}_t \mathbf{u}_{t-1} \\ \mathbf{P}_{t|t-1} = \mathbf{F}_t \mathbf{P}_{t-1} \mathbf{F}_t^T + \mathbf{Q}_t \end{cases} \quad (3.8)$$

**Étape 2 : correction** Comme à l'étape 1, l'équation d'observation peut être divisée en deux équations représentant la moyenne et sa covariance. Ici,  $\mathbf{y}_t$  doit être interprété comme la mesure et  $\mathbf{S}_{t|t-1}$ , sa covariance.

$$\mathbf{y}_t = \mathbf{H}_t \hat{\mathbf{x}}_{t|t-1} \quad (3.9)$$

$$\mathbf{S}_{t|t-1} = \mathbf{H}_t \mathbf{P}_{t|t-1} \mathbf{H}_t^T \quad (3.10)$$

On s'attend donc à ce que la valeur mesurée soit  $\mathbf{H}_t \hat{\mathbf{x}}_{t|t-1}$ , avec une covariance de  $\mathbf{H}_t \mathbf{P}_{t|t-1} \mathbf{H}_t^T$  à partir de l'équation d'état. La valeur mesurée réelle, quant à elle, est décrite par  $\mathbf{y}_t$  et sa covariance, ou le bruit sur la mesure, est dénotée  $\mathbf{R}_t$ . Les équations finales de mise à jour permettant de corriger la valeur prédite à partir d'une valeur mesurée sont les suivantes :

$$\begin{cases} \hat{\mathbf{x}}_t &= \hat{\mathbf{x}}_{t|t-1} + \mathbf{K}_t (\mathbf{y}_t - \mathbf{H}_t \hat{\mathbf{x}}_{t|t-1}) \\ \mathbf{P}_t &= (I - \mathbf{K}_t \mathbf{H}_t) \mathbf{P}_{t|t-1} \\ \mathbf{K}_t &= \mathbf{P}_{t|t-1} \mathbf{H}_t^T (\mathbf{H}_t \mathbf{P}_{t|t-1} \mathbf{H}_t^T + \mathbf{R}_t)^{-1} \end{cases} \quad (3.11)$$

où la quantité  $\mathbf{y}_t - \mathbf{H}_t \hat{\mathbf{x}}_{t|t-1}$  représente l'écart entre la mesure au temps  $t$  et sa valeur prévue sur la base de toutes les mesures jusqu'au temps  $t - 1$ . C'est ce qu'on appelle l'innovation, et cela représente l'information réellement nouvelle dans la lecture  $\mathbf{y}_t$ . On doit alors trouver la corrélation entre cette nouvelle information et  $\hat{\mathbf{x}}_t$  afin de mettre à jour la prédiction  $\hat{\mathbf{x}}_{t|t-1}$ , d'où le coefficient de gain  $\mathbf{K}_t$ . On remarque dans la dernière équation que plus le bruit de la mesure ( $\mathbf{R}_t$ ) est grand, plus l'influence de l'innovation dans la première équation est petite, et plus on fait confiance à la prédiction pure. Finalement, on peut aussi vérifier le résultat intuitif que si  $\mathbf{R}_t$  est nul (c'est-à-dire que les mesures ne sont pas bruitées), alors au moins dans le cas scalaire, le prédicteur disparaît de l'équation de mise à jour.

On peut retrouver les équations finales présentées ci-dessus à partir des équations (3.9) et (3.10), de la valeur mesurée  $\mathbf{y}_t$  et sa covariance  $\mathbf{R}_t$ . On a alors deux distributions normales : une pour la valeur mesurée prédite,  $N(\mathbf{H}_t \hat{\mathbf{x}}_{t|t-1}, \mathbf{H}_t \mathbf{P}_{t|t-1} \mathbf{H}_t^T)$ , et une pour la valeur réellement mesurée,  $N(\mathbf{y}_t, \mathbf{R}_t)$ . La valeur la plus probable de l'état au temps  $t$  correspond à la multiplication de ces deux gaussiennes.

Il est possible de démontrer qu'en multipliant deux distributions gaussiennes sous forme matricielle, on obtient une nouvelle distribution normale avec les moyennes et covariances suivantes :

$$\boldsymbol{\mu} = \boldsymbol{\mu}_0 + \mathbf{C} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_0) \quad (3.12)$$

$$\boldsymbol{\Sigma} = \boldsymbol{\Sigma}_0 - \mathbf{C} \boldsymbol{\Sigma}_0 \quad (3.13)$$

avec

$$\mathbf{C} = \boldsymbol{\Sigma}_0 (\boldsymbol{\Sigma}_0 + \boldsymbol{\Sigma}_1)^{-1} \quad (3.14)$$

En remplaçant la valeur prédite  $(\boldsymbol{\mu}_0, \boldsymbol{\Sigma}_0) = (\mathbf{H}_t \hat{\mathbf{x}}_{t|t-1}, \mathbf{H}_t \mathbf{P}_{t|t-1} \mathbf{H}_t^T)$  et la valeur mesurée  $(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1) = (\mathbf{y}_t, \mathbf{R}_t)$  dans les équations (3.12), (3.13) et (3.14), on trouve les équations ci-dessous qui décrivent le meilleur estimé de l'état  $\hat{\mathbf{x}}_t$ .

$$\begin{cases} \mathbf{H}_t \hat{\mathbf{x}}_t &= \mathbf{H}_t \hat{\mathbf{x}}_{t|t-1} + \mathbf{C}_t (\mathbf{y}_t - \mathbf{H}_t \hat{\mathbf{x}}_{t|t-1}) \\ \mathbf{H}_t \mathbf{P}_{t|t-1} \mathbf{H}_t^T &= \mathbf{H}_t \mathbf{P}_{t|t-1} \mathbf{H}_t^T - \mathbf{K} \mathbf{H}_t \mathbf{P}_{t|t-1} \mathbf{H}_t^T \\ \mathbf{C}_t &= \mathbf{H}_t \mathbf{P}_{t|t-1} \mathbf{H}_t^T (\mathbf{H}_t \mathbf{P}_{t|t-1} \mathbf{H}_t^T + \mathbf{R}_t)^{-1} \end{cases} \quad (3.15)$$

En simplifiant, et en définissant le gain  $\mathbf{K}_t = \mathbf{C}_t \mathbf{H}_t^{-1}$ , on retrouve le système d'équations finales donné en (3.11). En résumé, pour appliquer un filtre de Kalman à un processus, seuls les systèmes d'équations (3.8) et (3.11) sont nécessaires.

### 3.2 Hypothèses avancées par Louka et Galanis

Le filtre de Kalman a déjà été étudié pour la prévision des températures de surface [26, 19], mais les premières études portant sur l'application du FK pour la prévision des vitesses de vent se retrouvent dans un article publié par Galanis et Louka en 2006 [25]. Le modèle est quelque peu différent des équations générales présentées précédemment. D'abord, dans l'équation (3.1), la matrice de prévision  $\mathbf{F}_t$  est posée comme une matrice identité, ce qui signifie qu'on assume que le vent est de nature persistante ( $\mathbf{F}_t$  peut ainsi être retirée de l'équation). De plus, comme il n'y a pas d'influence externe au système, le paramètre de contrôle  $\mathbf{u}_t$  est aussi retiré de l'*équation d'état*. On obtient alors l'équation simplifiée :

$$\mathbf{x}_t = \mathbf{x}_{t-1} + \mathbf{w}_t \quad (3.16)$$

L'*équation d'observation*, quant à elle, reste inchangée :

$$\mathbf{y}_t = \mathbf{H}_t \cdot \mathbf{x}_t + \mathbf{m}_t \quad (3.17)$$

Les équations finales qui sont utilisées pour l'étape de **prévision** sont donc :

$$\hat{\mathbf{x}}_{t|t-1} = \hat{\mathbf{x}}_{t-1} \quad (3.18)$$

$$\mathbf{P}_{t|t-1} = \mathbf{P}_{t-1} + \mathbf{Q}_t \quad (3.19)$$

et pour l'étape de **correction** :

$$\hat{\mathbf{x}}_t = \hat{\mathbf{x}}_{t|t-1} + \mathbf{K}_t (\mathbf{y}_t - \mathbf{H}_t \hat{\mathbf{x}}_{t|t-1}) \quad (3.20)$$

$$\mathbf{P}_t = (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t) \mathbf{P}_{t|t-1} \quad (3.21)$$

où :

$$\mathbf{K}_t = \mathbf{P}_{t|t-1} + \mathbf{H}_t^T (\mathbf{H}_t \mathbf{P}_{t|t-1} \mathbf{H}_t^T + \mathbf{R}_t)^{-1} \quad (3.22)$$

Enfin, pour mieux saisir le fonctionnement du filtre, la Figure 3.2 résume les équations et les interactions entre elles. À titre de rappel,  $\hat{\mathbf{x}}_t$  dénote le vecteur d'état estimé, et  $\mathbf{P}_t$  est sa covariance.

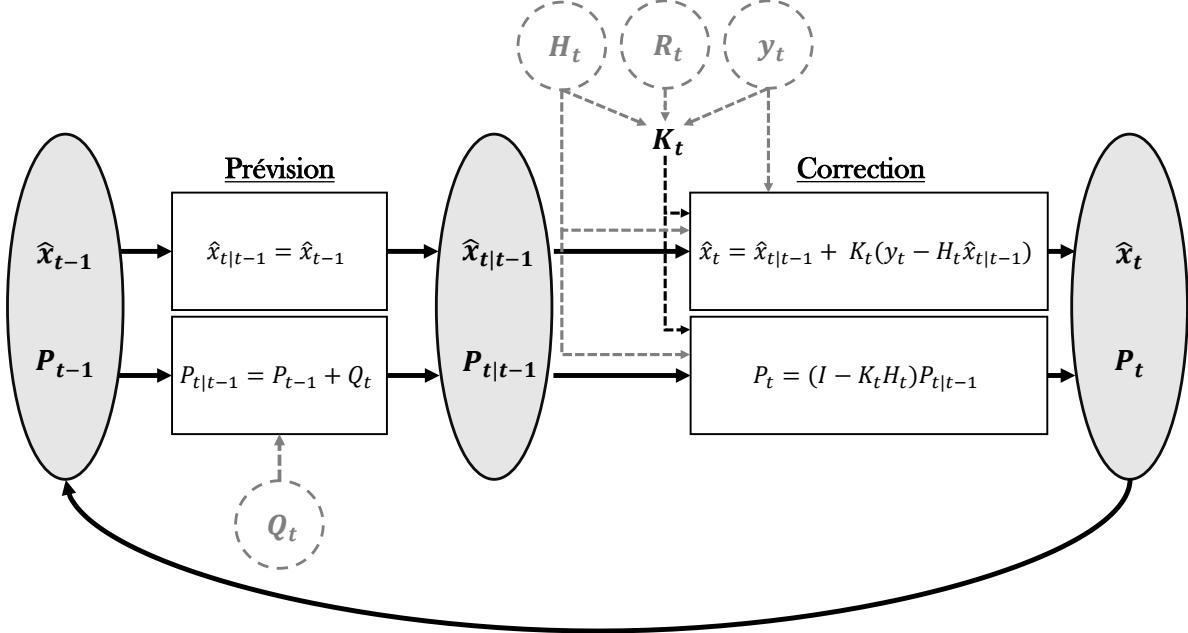


Figure 3.2 Fonctionnement du filtre de Kalman

L'approche de Louka et Galanis est basée sur la correction du biais de la vitesse de vent prédite par le modèle de PNT. Ainsi, l'objectif du filtre développé n'est pas d'estimer la vitesse du vent à chaque pas de temps, mais plutôt d'estimer la valeur du *biais* sur la vitesse. L'utilisation d'un filtre de Kalman de cette façon permet donc de minimiser le biais entre la prévision et les observations. On modélise le biais selon l'équation suivante :

$$y_t = x_{0,t} + x_{1,t} \cdot \hat{v}_{t,PNT} + x_{2,t} \cdot \hat{v}_{t,PNT}^2 + \dots + x_{n-1,t} \cdot \hat{v}_{t,PNT}^{n-1} + m_t \quad (3.23)$$

où les paramètres  $x_{i,t}$  (avec  $i = 0, 1, \dots, n-1$ ) doivent être estimés par le filtre. Le biais  $y_t$  est donc modélisé comme une fonction linéaire ou non linéaire (dépendamment de la valeur de  $n$ ) de la prévision du modèle de PNT ( $\hat{v}_{t,PNT}$ ). En comparant (3.23) avec l'équation (3.17), il est possible de définir le vecteur d'état à estimer  $\mathbf{x}_t$  et le vecteur d'observation  $\mathbf{H}_t$  tels que :

$$\mathbf{x}_t = [x_{0,t}, \quad x_{1,t}, \quad x_{2,t}, \quad \dots, \quad x_{n-1,t}]^T \quad (3.24)$$

$$\mathbf{H}_t = [1, \quad \hat{v}_{t,PNT}, \quad \hat{v}_{t,PNT}^2, \quad \dots, \quad \hat{v}_{t,PNT}^{n-1}] \quad (3.25)$$

L'horizon  $h = 1$  est utilisé pour mettre à jour le vecteur d'état. En d'autres termes, au temps actuel  $t - 1$ , le prédicteur de la vitesse aux éoliennes est donné par  $\hat{v}_{t|t-1,PNT}$ . Une heure plus tard, le biais  $y_t$  peut être calculé avec  $v_t$  (mesure bruitée de la vitesse à l'éolienne au temps  $t$ ) afin de corriger, ou mettre à jour, le vecteur d'état.

$$y_t = \hat{v}_{t|t-1,PNT} - v_t \quad (3.26)$$

Les matrices de covariance de l'équation de système ( $\mathbf{Q}_t$ ) et de l'équation d'observation ( $\mathbf{R}_t$ ) sont calculées à partir des 7 dernières valeurs des erreurs  $\mathbf{w}_t = \hat{\mathbf{x}}_t - \hat{\mathbf{x}}_{t-1}$  et  $m_t = y_t - \mathbf{H}_t \hat{\mathbf{x}}_t$ . Cette méthode de calcul de la covariance, basée sur les 7 derniers pas de temps, a été déterminée optimale selon Louka et Galanis [25]. Elle permet une grande adaptabilité tout en ne nécessitant pas la sauvegarde d'une trop grande quantité d'informations.

$$\mathbf{Q}_t = \frac{1}{6} \sum_{i=0}^6 \left( \left( (\hat{\mathbf{x}}_{t-i} - \hat{\mathbf{x}}_{t-i-1}) - \left( \frac{\sum_{i=0}^6 (\hat{\mathbf{x}}_{t-i} - \hat{\mathbf{x}}_{t-i-1})}{7} \right) \right) \right)^2 \quad (3.27)$$

$$\mathbf{R}_t = \frac{1}{6} \sum_{i=0}^6 \left( \left( (y_{t-i} - \mathbf{H}_{t-i} \cdot \hat{\mathbf{x}}_{t-i}) - \left( \frac{\sum_{i=0}^6 (y_{t-i} - \mathbf{H}_{t-i} \cdot \hat{\mathbf{x}}_{t-i})}{7} \right) \right) \right)^2 \quad (3.28)$$

Enfin, lorsqu'une nouvelle mesure est disponible, le vecteur d'état est actualisé. Les coefficients estimés de cette façon sont utilisés tels quels pour ensuite prédire tous les horizons. Ainsi, lorsqu'on a un vecteur d'état actualisé au temps  $t - h$  par exemple, il est possible de calculer le biais prédit au temps  $t$ , soit  $h$  heures dans le futur, à l'aide de l'équation :

$$\hat{y}_{t|t-h} = x_{0,t-h} + x_{1,t-h} \cdot \hat{v}_{t|t-h,PNT} + x_{2,t-h} \cdot \hat{v}_{t|t-h,PNT}^2 + \cdots + x_{n-1,t-h} \cdot \hat{v}_{t|t-h,PNT}^{n-1} \quad (3.29)$$

Une fois le biais prédit pour l'horizon en question, on estime la vitesse prédite par le filtre de Kalman à l'horizon  $h$  en soustrayant le biais estimé à la valeur prédite par le modèle de PNT :

$$\hat{v}_{t|t-h,kal} = \hat{v}_{t|t-h,PNT} - \hat{y}_{t|t-h} \quad (3.30)$$

### 3.3 Modifications au filtre de Louka et Galanis

Dans [27], plusieurs modèles statistiques de type *Autoregressive* (AR) ont été modifiés pour tenir compte de la direction du vent. Selon les auteurs, l'intégration du vent à ces modèles montre des résultats prometteurs. Dans [72], un RNA tenant compte de la direction comme paramètre d'entrée a été comparé à un RNA traditionnel. Il a été démontré que la performance était grandement améliorée lorsque la direction était considérée.

En 2012, un filtre de Kalman directionnel a été étudié dans [75]. L'approche envisagée était de séparer les données en classes de direction et de vitesse, puis générer des filtres individuels pour chacune de celles-ci. Au final, 300 classes, donc 300 filtres sont générés. Cette approche est intéressante afin d'intégrer la direction au filtre de Kalman. Toutefois, elle présente quelques inconvénients : d'abord, comme 300 filtres différents sont entraînés et que chacun de ces filtres nécessite au moins quelques dizaines d'heures de données pour y parvenir, le filtre ne peut pas être appliqué rapidement et nécessite une plus longue période d'entraînement. De plus, comme le vent est parfois très directionnel, il est possible que certaines classes reçoivent très peu de données et soient donc mal entraînées. Finalement, les auteurs ont aussi remarqué des discontinuités entre les filtres des différentes classes. En effet, des états de vitesse et de direction très rapprochés, mais tombant dans deux classes différentes, sont traités par des filtres distincts pouvant corriger les données de manière très différente.

Pour remédier à ces problèmes, l'approche envisagée dans ce projet est d'intégrer la direction dans un seul filtre de Kalman continu sur tout le domaine des vitesses et directions du vent. Pour ce faire, la variable  $\theta$  sera intégrée dans l'équation modélisant le biais  $\mathbf{y}_t$  décrite précédemment. Dans l'article de Louka et Galanis paru en 2006, les auteurs ont étudié plusieurs ordres pour l'équation du biais sur deux sites situés en Espagne et en Grèce. Ils en ont conclu que le polynôme d'ordre 3 donnait de meilleurs résultats. Néanmoins, l'étude de leurs résultats numériques permet de révéler que les filtres d'ordre 1 et 2 montrent aussi une performance similaire, alors que les filtres d'ordres plus élevés augmentent de façon notable l'instabilité du filtre [25]. Il a déjà été montré dans plusieurs articles que la précision des modèles diffère souvent selon le site géographique étudié. Ainsi, puisque les résultats présentés par Louka et Galanis résultent de l'étude de seulement deux parcs éoliens, il serait intéressant de considérer aussi les ordres 1 et 2 lors des essais sur les données disponibles pour ce projet.

#### 3.3.1 Développement mathématique

Le présent projet portera donc sur l'étude approfondie de la performance de plusieurs équations de biais  $\mathbf{y}_t$  certains intégrant la direction, et d'autres non, afin de vérifier si l'ajout de

cette variable est justifié. Comme mentionné précédemment, les polynômes d'ordre 1, 2 et 3 seront étudiés plus particulièrement. D'abord, les équations polynomiales développées par Louka et Galanis n'intégrant pas la direction du vent sont aussi évaluées sur nos données afin d'avoir une base comparative (la notation des coefficients ici est légèrement différente de celle utilisée à l'équation (3.23) et dans [48]).

$$y_t = \alpha_{0,t} + \beta_{0,t} \cdot \hat{v}_{t,PNT} + m_t \quad (3.31)$$

$$y_t = \alpha_{0,t} + \beta_{0,t} \cdot \hat{v}_{t,PNT} + \gamma_{0,t} \cdot \hat{v}_{t,PNT}^2 + m_t \quad (3.32)$$

$$y_t = \alpha_{0,t} + \beta_{0,t} \cdot \hat{v}_{t,PNT} + \gamma_{0,t} \cdot \hat{v}_{t,PNT}^2 + \eta_{0,t} \cdot \hat{v}_{t,PNT}^3 + m_t \quad (3.33)$$

La performance de ces modèles sera aussi étudiée sur plusieurs sites afin de vérifier les résultats obtenus par Louka et Galanis. Leur analyse est basée sur 2 sites éoliens seulement : une étude plus exhaustive de leur approche sur un plus grand nombre de parcs pourra donner une meilleure conclusion sur leur performance.

Pour intégrer la direction dans le calcul du biais, on introduit une dépendance de la direction pour chaque coefficient des équations ci-dessus ( $\alpha$ ,  $\beta$ ,  $\gamma$  et  $\eta$ ). Ainsi,  $\alpha_{0,t}$  devient  $\alpha_{0,t} + \alpha_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \alpha_{2,t} \cdot \cos \hat{\theta}_{t,PNT}$  par exemple. Les trois équations ci-dessous d'ordre 1, 2 et 3 seront étudiées afin d'étudier l'influence de l'ajout de la direction dans le calcul du biais.

$$\begin{aligned} y_t = & (\alpha_{0,t} + \alpha_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \alpha_{2,t} \cdot \cos \hat{\theta}_{t,PNT}) \\ & + (\beta_{0,t} + \beta_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \beta_{2,t} \cdot \cos \hat{\theta}_{t,PNT}) \cdot \hat{v}_{t,PNT} + m_t \end{aligned} \quad (3.34)$$

$$\begin{aligned} y_t = & (\alpha_{0,t} + \alpha_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \alpha_{2,t} \cdot \cos \hat{\theta}_{t,PNT}) \\ & + (\beta_{0,t} + \beta_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \beta_{2,t} \cdot \cos \hat{\theta}_{t,PNT}) \cdot \hat{v}_{t,PNT} \\ & + (\gamma_{0,t} + \gamma_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \gamma_{2,t} \cdot \cos \hat{\theta}_{t,PNT}) \cdot \hat{v}_{t,PNT}^2 + m_t \end{aligned} \quad (3.35)$$

$$\begin{aligned} y_t = & (\alpha_{0,t} + \alpha_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \alpha_{2,t} \cdot \cos \hat{\theta}_{t,PNT}) \\ & + (\beta_{0,t} + \beta_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \beta_{2,t} \cdot \cos \hat{\theta}_{t,PNT}) \cdot \hat{v}_{t,PNT} \\ & + (\gamma_{0,t} + \gamma_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \gamma_{2,t} \cdot \cos \hat{\theta}_{t,PNT}) \cdot \hat{v}_{t,PNT}^2 \\ & + (\eta_{0,t} + \eta_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \eta_{2,t} \cdot \cos \hat{\theta}_{t,PNT}) \cdot \hat{v}_{t,PNT}^3 + m_t \end{aligned} \quad (3.36)$$

Le vecteur d'état et la matrice d'observation auront donc la forme suivante pour l'équation (3.34) par exemple :

$$\mathbf{x}_t = [\alpha_{0,t}, \alpha_{1,t}, \alpha_{2,t}, \beta_{0,t}, \beta_{1,t}, \beta_{2,t}]^T \quad (3.37)$$

$$\mathbf{H}_t = [1, \sin \hat{\theta}_{t,PNT}, \cos \hat{\theta}_{t,PNT}, \hat{v}_{t,PNT}, \sin \hat{\theta}_{t,PNT} \cdot \hat{v}_{t,PNT}, \cos \theta_{t,PNT} \cdot \hat{v}_{t,PNT}] \quad (3.38)$$

### 3.3.2 Application du modèle à la puissance

Tel que mentionné à la section 2.4, deux méthodes sont envisagées pour corriger les données de puissance dans l'éventualité où la vitesse du vent n'est pas disponible. D'abord, l'approche par inversion de puissance (section 2.4.1) n'implique pas de modification dans le modèle développé dans les sections précédentes puisqu'on recalcule les données de vitesse à partir de la puissance.

La seconde méthode suggérée pour ce cas particulier est d'appliquer un FK directement sur la puissance. Ainsi, les modèles utilisés sont encore une fois ceux proposés par Louka et Galanis, sous forme directionnelle et non directionnelle. Ici, le paramètre d'entrée des modèles correspond à la puissance prédite, plutôt que la vitesse du vent. Plus particulièrement, les équations (3.31) à (3.36) sont utilisées, et le biais est calculé et corrigé sur la puissance directement. Ainsi, la quantité  $\hat{v}_{t,PNT}$  est remplacée par  $\hat{p}_{t,PNT}$ , et représente la prévision de la puissance générée calculée à partir des données de vitesses de vent brutes provenant du modèle de PNT.

### 3.3.3 Résumé de l'approche

Une première partie du travail qui sera réalisé dans le cadre de ce projet consistera à implémenter et tester les différents modèles sur la vitesse de vent et la puissance. Toutefois, la partie la plus importante sera d'analyser en profondeur la performance des modèles étudiés ainsi que de les comparer afin de pouvoir en tirer des conclusions pertinentes.

La Figure 3.3 résume les approches qui seront étudiées pour la prévision des vitesses de vent ainsi que de la puissance générée (les variables  $\mathbf{v}$ ,  $\mathbf{p}$  et  $\boldsymbol{\theta}$  dans cette figure désignent respectivement la vitesse du vent, la puissance et la direction du vent). Le prochain chapitre sera dédié à l'étude de la performance des modèles au niveau de la prévision des vitesses de vent, et le suivant traitera des prévisions de puissance. Une attention particulière sera portée à l'influence de l'ajout de la direction comme paramètre d'entrée sur la performance des modèles.

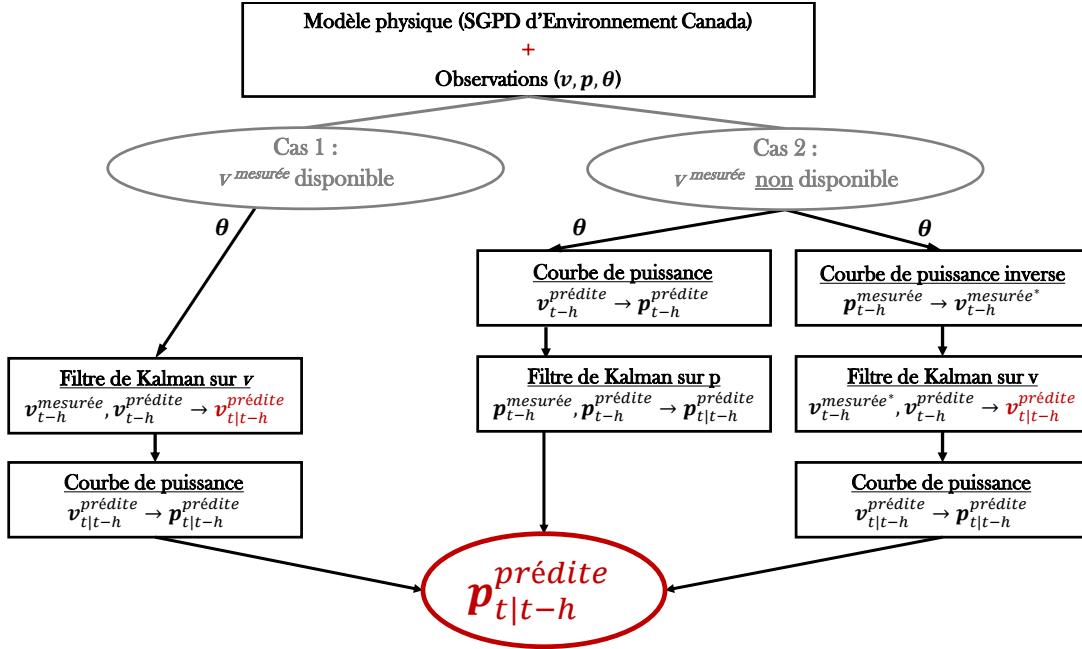


Figure 3.3 Schéma des modèles étudiés

### 3.4 Combinaison de plusieurs modèles

Des études préliminaires ont permis de remarquer que la performance des modèles varie beaucoup en fonction du site et de sa topographie. Cette affirmation est aussi confirmée par une panoplie d'études vérifiant des modèles sur plusieurs parcs. Par ailleurs, la performance des modèles peut aussi varier selon la période (saison, mois, etc.) sur laquelle ils sont appliqués et selon l'horizon de prévision [63, 53].

Pour un prévisionniste, l'objectif final est de réduire au maximum les erreurs des prévisions de vent et de production. Définir le modèle le plus performant pour un site est donc crucial. Il serait possible d'évaluer la performance de tous les modèles étudiés sur un site durant une longue période de temps, pour ensuite déterminer celui produisant les meilleures prévisions. Cependant, cette approche nécessiterait un ensemble de données historiques qui ne sont pas toujours disponibles, et le filtre ne présenterait plus l'avantage de pouvoir être appliqué rapidement. De plus, comme les performances des filtres peuvent varier au cours des mois ou des saisons, le filtre choisi au départ pourrait perdre de la précision avec le temps.

Pour remédier à ce problème, une méthode de combinaison adaptative basée sur l'approche de Sanchez [63] sera implémentée une fois les prévisions effectuées. Selon cette approche, une combinaison de tous les modèles générés résulte en une performance égale ou supérieure au

meilleur des modèles considérés. Cette technique peut être appliquée lorsqu'on dispose de données d'observation en temps quasi réel, puisqu'elle se base sur les performances récentes des modèles étudiés, afin de les pondérer sous forme de combinaison linéaire.

Il existe principalement deux techniques de combinaison : les combinaisons d'*amélioration* et les combinaisons d'*adaptation*. La première vise à produire une combinaison linéaire des différents modèles en assignant un certain poids à chacun d'entre eux. La deuxième approche, quant à elle, peut être interprétée plutôt comme une méthode de sélection du meilleur modèle de façon dynamique. Elle donnera tout, ou presque tout le poids, à un seul modèle.

En pratique, il n'est pas évident de savoir quelle approche est la plus appropriée pour une situation spécifique. Afin de profiter des deux types d'approches, la combinaison est effectuée en deux étapes [63]. D'abord, trois types de combinaisons différentes sont réalisées de façon indépendante. Les deux premières sont des approches adaptatives basées sur le calcul de la covariance pour l'estimation des coefficients. La troisième est fondée sur la méthode *Adaptive Exponential Combination* (AEC) développée par l'auteur de l'article, qui permet de sélectionner le modèle le plus adéquat. La performance des différentes approches varie selon la nature des données, ce pour quoi lors de la deuxième étape les trois combinaisons précédentes sont elles-mêmes utilisées en entrée dans un modèle AEC. Celui-ci déterminera quelle méthode de combinaison est la plus appropriée pour les données utilisées (voir la Figure 3.4).

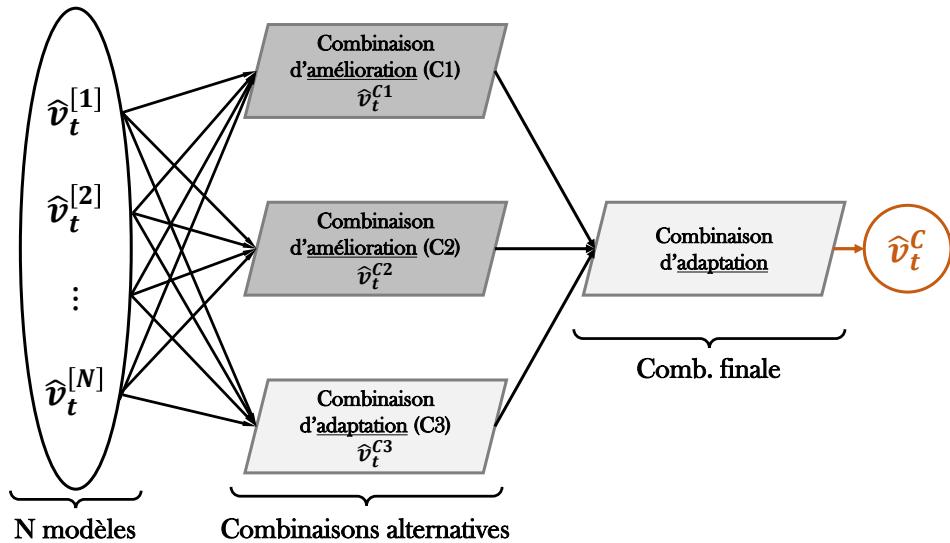


Figure 3.4 Étapes de la combinaison

Le processus général de combinaison linéaire des  $K$  modèles est décrit par l'équation suivante :

$$\hat{v}_{t|t-h}^C = \sum_{k=1}^K \phi_{k,t}(h) \hat{v}_{t|t-h}^{(k)} \quad (3.39)$$

où  $\hat{v}_{t|t-h}^{(k)}$  est la vitesse prédictive par le modèle  $k$  pour le temps  $t$ ,  $\phi_{k,t}(h)$  est le poids attribué à ce modèle pour l'horizon  $h$ , et  $\hat{v}_{t|t-h}^C$  correspond à la nouvelle prévision estimée par la combinaison. Sachant que la vitesse réelle (observée) est  $v_t$ , l'erreur de prévision pour un modèle  $k$  vaut  $e_{t|t-h}^{(k)} = v_t - \hat{v}_{t|t-h}^{(k)}$ , et l'erreur de la combinaison est donnée par  $e_{t|t-h}^C = v_t - \hat{v}_{t|t-h}^C$ .

Le modèle (3.39) peut être reformulé sous la forme vectorielle de la façon suivante :

$$v_t = \hat{v}_{t|t-h}^C + e_{t|t-h}^C = \phi_t(h)' \hat{v}_{t|t-h} + e_{t|t-h}^C \quad (3.40)$$

où  $\phi_t(h) = [\phi_{1,t}(h), \dots, \phi_{K,t}(h)]'$  contient les poids attribués aux différents modèles,  $\hat{v}_{t|t-h} = [\hat{v}_{t|t-h}^{(1)}, \dots, \hat{v}_{t|t-h}^{(K)}]'$  les prévisions de vitesse pour les  $K$  modèles et  $e_{t|t-h} = [e_{t|t-h}^{(1)}, \dots, e_{t|t-h}^{(K)}]'$  leurs erreurs respectives pour l'horizon  $h$ , sachant l'information disponible au temps  $t - h$ . Il est intéressant de noter que la combinaison est également dépendante de  $h$ , ce qui permet de gérer différents modèles performant plus ou moins bien selon l'horizon de prévision.

En général, les poids des différents modèles sont donnés par la solution du problème de combinaison donné en (3.40), soit  $\phi_t(h)$ , qui est estimée de façon à minimiser la fonction objectif suivante :

$$O(e_{t|t-h}^C) = E \left[ (e_{t|t-h}^C)^2 \right] \quad (3.41)$$

### 3.4.1 Combinaison d'amélioration

Les paramètres contenus dans  $\phi_t(h)$  sont estimés à partir des données de façon adaptative. Plusieurs approches d'estimation existent : deux d'entre elles sont abordées par Sanchez dans [63], soient le *Exponentially Weighted Moving Average* (EWMA) et les moindres carrés récursifs.

#### C1 - Estimation par EWMA

La solution de l'équation (3.40), lorsqu'on impose la contrainte  $\sum_{k=1}^K \phi_{k,t} = 1$ , est appelée méthode de variance-covariance (voir l'équation (3.42)) [61].

$$\phi_t^{vc} = \frac{\Omega_{t|t-h}^{-1} \mathbf{c}}{\mathbf{c}' \Omega_{t|t-h}^{-1} \mathbf{c}} \quad (3.42)$$

Plusieurs auteurs ont cependant montré que de meilleurs résultats sont obtenus lorsque les erreurs des différents modèles sont traitées de façon indépendante, soit en redéfinissant la covariance seulement par ses termes diagonaux,  $\mathbf{W}_{t|t-h} = \text{diag}(\Omega_{t|t-h})$  [63]. L'équation (3.42) est donc redéfinie par :

$$\phi_t^{vc-in} = \frac{\mathbf{W}_{t|t-h}^{-1} \mathbf{c}}{\mathbf{c}' \mathbf{W}_{t|t-h}^{-1} \mathbf{c}} \quad (3.43)$$

où  $\mathbf{c}$  est un vecteur unitaire de dimension  $K \times 1$ . Si  $w_{k,t|t-h}$  est le  $k^{\text{ième}}$  élément de la diagonale de  $\mathbf{W}_{t|t-h}$ , l'équation peut être reformulée par :

$$\phi_{k,t}^{vc-in} = \frac{\frac{1}{w_{k,t|t-h}}}{\sum_{i=1}^K \frac{1}{w_{i|t-h}}} \quad (3.44)$$

Cette première approche est donc basée sur le EWMA pour estimer la solution  $\hat{\phi}_t(h)$  minimisant la fonction objectif associée à l'équation (3.40). La variance  $w_{k,t|t-h}$  est obtenue à partir d'une pondération exponentielle des informations précédentes. Ainsi, les équations de récurrence de l'approche EWMA permettant de mettre à jour la variance sont données en (3.45), (3.46) et (3.47).

$$\hat{w}_{k,t|t-h} = N_{k,t}^{-1} S_{t|t-h}^{(k)} \quad (3.45)$$

$$S_{t|t-h}^{(k)} = e_{t|t-h}^{(k)} e_{t|t-h}^{(k)'} + \lambda_{k,t}^{\text{Cook}} S_{t-1|t-h-1}^{(k)} \quad (3.46)$$

$$N_{k,t} = 1 + \lambda_{k,t}^{\text{Cook}} N_{k,t-1} \quad (3.47)$$

avec  $N_{k,0} = 0$  et  $S_{0|t-h}^{(k)} = 0$ . Dans ces équations,  $N_{k,t}$  correspond à la taille équivalente de l'échantillon, et  $0 < \lambda_{k,t}^{\text{Cook}} < 1$  est un facteur d'oubli. Celui-ci est déterminé à partir de la distance de Cook de la nouvelle observation, qui a été développée dans un article précédent aussi publié par Sanchez [64].

La distance de Cook permet d'obtenir un indicateur de la variation des observations : une distance élevée indique que les paramètres de la solution pourraient fluctuer. En d'autres termes, lorsque  $D_{k,t}$  est grand, les coefficients de l'estimateur  $\hat{\beta}$  risquent de changer : la valeur de  $\lambda_{k,t}^{\text{Cook}}$  diminue donc afin de permettre à la combinaison de mieux s'adapter et de

donner moins d'importance aux données plus anciennes. Dans [63], le facteur d'oubli de Cook est déterminé selon les équations suivantes. D'abord, la distance est donnée par :

$$D_{k,t} = \frac{g_{k,t} (\hat{e}_{t|t-h}^C)^2}{\hat{\sigma}_{t-1}^2 \eta_{k,t}} \quad (3.48)$$

où la variance de l'erreur de la combinaison ( $e_{t|t-h}^C$ ) est définie par

$$\hat{\sigma}_{t-1}^2 = \frac{\sum_{i=1}^{t-1} (v_i - \hat{\phi}'_i \hat{v}_i)^2}{t-1}, \text{ et :}$$

$$\eta_{k,t} = u_k' \hat{\Gamma}_{t|I} u_k \quad (3.49)$$

$$\hat{\Gamma}_{t|I} = \left( \hat{\Gamma}_{t-1}^{-1} + \hat{v}_{t|t-h} \hat{v}_{t|t-h}' \right)^{-1} \quad (3.50)$$

$$g_{k,t} = u_k' \hat{\Gamma}_{t|I} \hat{v}_{t|t-h} \hat{v}_{t|t-h}' \hat{\Gamma}_{t|I} u_k \quad (3.51)$$

où  $u_k$  est un vecteur nul de dimension  $[K \times 1]$ , valant 1 à son  $k^{i\text{ème}}$  élément. L'estimation du facteur de Cook est basée sur la méthode de RLS (décrise plus en détail dans la prochaine section). La dispersion  $\hat{\Gamma}_t$  de l'estimation  $\hat{\phi}_t$  est donc donnée par l'équation récursive :

$$\hat{\Gamma}_t = \left( A_t \hat{\Gamma}_{t-1}^{-1} A_t + \hat{v}_{t|t-h} \hat{v}_{t|t-h}' \right)^{-1} \quad (3.52)$$

Ici,  $A_t$  est une matrice diagonale, composée des valeurs  $\sqrt{\lambda_{k,t}^{Cook}}$  sur les  $k = 1, \dots, K$  éléments de sa diagonale. Finalement, distance de Cook est convertie en facteur d'oubli selon l'équation suivante :

$$\lambda_{k,t}^{Cook} = \lambda_{min} + (\lambda_{max} - \lambda_{min}) H_{k,t} \quad (3.53)$$

où  $H_{k,t}$  est déterminé selon une distribution  $\chi^2$  avec 1 degré de liberté,  $H_{k,t} = P(\chi_1^2 > D_{k,t})$ . Cette formulation permet d'abord de s'assurer que le facteur d'oubli se situe entre 0 et 1, mais plus particulièrement entre des valeurs minimales et maximales, fixées à  $\lambda_{min} = 0,99$  et  $\lambda_{max} = 0,9999$  dans [63]. Une fois le facteur de Cook obtenu, la variance  $\hat{w}_{k,t|t-h}$  peut être déterminée, afin de finalement calculer la solution  $\hat{\phi}_{k,t}(h)$  à partir de l'équation (3.44). Comme la contrainte  $\sum_{k=1}^K \hat{\phi}_{k,t} = 1$  est imposée, il faut en dernier lieu normaliser la solution pour obtenir les poids finaux.

## C2 - Estimation par moindres carrés

La solution du modèle donné à l'équation (3.40) peut aussi être déterminée à partir de l'algorithme des moindres carrés récursifs (*recursive least squares* (RLS)). Dans ce cas-ci, Sanchez utilise une version légèrement différente de la combinaison linéaire donnée à l'équation (3.39), soit :

$$v_t - \hat{v}_{t|t-h}^{(1)} = \sum_{k=2}^K \hat{\phi}_{k,t}(h) \left( \hat{v}_{t|t-h}^{(k)} - \hat{v}_{t|t-h}^{(1)} \right) + e_{t|t-h}^C \quad (3.54)$$

En posant  $z_t = v_t - \hat{v}_{t|t-h}^{(1)}$ ,  $\hat{z}_{t|t-h}^{(k)} = \hat{v}_{t|t-h}^{(k)} - \hat{v}_{t|t-h}^{(1)}$  et  $\beta_t(h) = [\phi_{2,t}(h), \dots, \phi_{k,t}(h)]'$ , il est possible de reformuler l'équation ci-dessus sous forme vectorielle, de la façon suivante :

$$z_t = \hat{z}_{t|t-h}' \hat{\beta}_t + e_{t|t-h}^C \quad (3.55)$$

La nouvelle solution à estimer est donc  $\hat{\beta}_t$ . Selon l'approche RLS, l'opération permettant de mettre à jour cet estimateur est définie selon l'équation (3.56) [46].

$$\hat{\beta}_t = \hat{\beta}_{t-1} + \hat{\Gamma}_t' \hat{z}_{t|t-h} \hat{e}_{t|t-h}^C \quad (3.56)$$

où  $\hat{e}_{t|t-h}^C$  est l'erreur de prédiction de la valeur estimée au temps  $t$  :

$$\hat{e}_{t|t-h}^C = (v_t) - \hat{v}_{t|t-h}^C = (z_t + \hat{v}_{t|t-h}^{(1)}) - \hat{v}_{t|t-h}^C \quad (3.57)$$

La matrice de gain  $\hat{\Gamma}_t$  est une mesure de la dispersion de l'estimé  $\hat{\beta}_t$ , et est donnée par :

$$\hat{\Gamma}_t^{-1} = \lambda_t^{Cook} \hat{\Gamma}_{t-1}^{-1} + \hat{z}_{t|t-h} \hat{z}_{t|t-h}' \quad (3.58)$$

qui peut être reformulé :

$$\hat{\Gamma}_t = \frac{1}{\lambda_t^{Cook}} \left( \hat{\Gamma}_{t-1} - \frac{\hat{\Gamma}_{t-1} \hat{z}_{t|t-h} \hat{z}_{t|t-h}' \hat{\Gamma}_{t-1}}{\lambda_t^{Cook} + \hat{z}_{t|t-h}' \hat{\Gamma}_{t-1} \hat{z}_{t|t-h}} \right) \quad (3.59)$$

Encore une fois,  $\lambda_t^{Cook}$  est le facteur d'oubli basé sur la distance de Cook,  $D_t$ . La distance est donnée sous forme matricielle par l'équation (3.60), où toutes les variables sont connues.

$$D_t = \frac{\hat{\mathbf{z}}'_{t|t-h} \hat{\mathbf{\Gamma}}_{t-1} \hat{\mathbf{z}}_{t|t-h} (\hat{e}_{t|t-h}^C)^2}{K \hat{\sigma}_{t-1}^2 (1 + \hat{\mathbf{z}}'_{t|t-h} \hat{\mathbf{\Gamma}}_{t-1} \hat{\mathbf{z}}'_{t|t-h})} \quad (3.60)$$

$$\text{où} \quad \hat{\sigma}_{t-1}^2 = \frac{\sum_{i=1}^{t-1} (z_i - \hat{\mathbf{z}}'_i \hat{\beta}_i)^2}{t-1} \quad (3.61)$$

Puis,  $\lambda_t^{Cook}$  est déterminé de façon similaire à la méthode EWMA :

$$\lambda_t^{Cook} = \lambda_{min} + (\lambda_{max} - \lambda_{min}) H_t \quad (3.62)$$

Il est à noter qu'ici, le facteur n'est pas décomposé en éléments  $k$  pour chaque modèle.  $H_t$  est encore une fois déterminé selon une distribution  $\chi^2$  avec  $K$  degrés de liberté, soit  $H_t = P(\chi_K^2 > KD_t)$ .

### 3.4.2 Combinaison d'adaptation

La méthode de combinaison d'adaptation (ou de sélection) développée dans l'article de Sanchez [63] est nommée *Adaptive Exponential Combination* (AEC). Cette approche n'est toutefois pas complètement sélective, au sens où elle ne donne pas tout le poids à un seul modèle. L'objectif est d'assigner un poids près de 1 au meilleur modèle, tout en laissant un poids faible, mais non nul, aux autres. Cela permet des changements moins drastiques lorsque le choix du meilleur modèle varie entre deux pas de temps.

#### C3 - Combinaison exponentielle adaptative (AEC)

Les coefficients de l'estimateur sont donnés par les équations ci-dessous.

$$\hat{\phi}_{k,t} = \frac{B_{k,t}}{\sum_{i=1}^K B_{i,t}}, \quad (3.63)$$

$$B_{k,t} = I_{k,t-1} B_{k,t-1}^{\lambda_{k,t}^{Cook}} \quad (3.64)$$

Avec

$$I_{k,t-1} = \hat{w}_{k,t-1|t-h-1}^{-1/2} \cdot \exp \left( -\frac{(v_{t-1} - \hat{v}_{t-1|t-h-1}^{(k)})^2}{2\hat{w}_{k,t-1|t-h-1}} \right) \quad (3.65)$$

$I_{k,t-1}$  est interprété ici comme la nouvelle information au temps  $t$ . De plus,  $\hat{w}_{k,t-h}$  et  $\lambda_{k,t}^{Cook}$  sont déterminés de la même manière que pour l'approche EWMA.

Il est possible de noter que plus l'erreur de prévision  $(v_{t-1} - \hat{v}_{t-1|t-h-1}^{(k)})$  est grande pour un modèle  $k$ , plus le poids attribué au modèle  $k$  est réduit, et ce, de façon exponentielle. En d'autres termes, une erreur élevée est interprétée comme une détérioration de la performance du modèle en question, ce qui a pour conséquence de donner un poids très élevé à la meilleure approche et très faible pour les autres, d'où le caractère sélectif de l'approche.

Le facteur d'oubli est introduit à l'équation (3.64), de façon à ce que les anciennes données perdent exponentiellement de l'importance avec les itérations. Finalement, la relation (3.63) permet de normaliser les coefficients du vecteur de poids obtenus, afin que la somme de tous les coefficients soit égale à 1.

### 3.4.3 Estimation en deux étapes

Tel que mentionné au début de la section, la combinaison est effectuée en deux étapes. D'abord, les trois méthodes définies ci-dessus sont utilisées pour combiner les modèles. À la deuxième étape, les trois prévisions obtenues à l'étape 1 sont recombinées par AEC pour produire une prévision finale. Cette étape permet donc de constamment *choisir* la meilleure méthode de combinaison de façon adaptative. Selon Sanchez, cette approche permet d'obtenir des prévisions similaires ou supérieures au meilleur des  $K$  modèles.

## CHAPITRE 4 PRÉVISION DE LA VITESSE DE VENT

Dans ce chapitre, les filtres de Kalman appliqués à la vitesse sont étudiés. D'abord, les données d'observation ainsi que les données de prévision du modèle de PNT disponibles pour l'étude sont décrites. Puis, une analyse préliminaire de l'influence de la direction sur l'erreur de prévision est présentée. Finalement, le corps du chapitre est consacré à une analyse exhaustive de la performance de tous les modèles développés, où les filtres de Kalman adaptés pour tenir compte de la direction sont comparés aux filtres de Kalman conventionnels. Ces analyses, ainsi que l'implémentation des modèles, ont été réalisées à partir du logiciel MATLAB.

### 4.1 Description des données disponibles

Afin d'évaluer la performance des approches étudiées, il est essentiel d'avoir accès à des ensembles de données de prévision (soit le modèle de PNT dans notre cas), ainsi qu'à des ensembles de mesures prises sur des sites réels.

#### 4.1.1 Données de prévision

Les données de prévision fournies par WPred pour ce projet sont extraites du modèle SGPD d'Environnement Canada décrit à la section 2.1. Les prévisions sont produites deux fois par jour pour un horizon de 240 heures, soit 10 jours. Comme la résolution du modèle est de 0,24° (soit environ 25 km), WPred applique une méthode de *downscaling* linéaire afin d'interpoler les données entre les points de la grille (voir la Figure 2.1). Les valeurs, disponibles pour plusieurs altitudes, sont aussi interpolées à la hauteur exacte de la turbine. Les données de vent sont sous forme de moyenne horaire, de même les autres données disponibles telles la température, la direction du vent, la pression, etc.

Pour l'analyse des résultats, les modèles sont principalement comparés entre eux, à la persistance, ainsi qu'aux PNTs. WPred utilise cependant un modèle de statistique linéaire (*Model Output Statistics* (MOS)) afin d'ajuster les prévisions lorsqu'un ensemble de données historiques d'un an ou plus est disponible pour un site. La performance des filtres de Kalman est donc aussi comparée au modèle MOS afin de quantifier les améliorations, s'il y a lieu, pour WPred. Le MOS utilisé est défini par l'équation suivante :

$$\hat{\mathbf{v}}_t^{MOS} = \hat{\mathbf{v}}_t^{PNT} \cdot \left( \alpha_0 + \alpha_1 \cdot \cos(\hat{\theta}_t^{PNT}) + \alpha_2 \cdot \sin(\hat{\theta}_t^{PNT}) \right) \quad (4.1)$$

Le modèle est entraîné sur les données historiques afin de déterminer les coefficients  $\alpha_i$ . Une fois ces coefficients fixés, ils sont utilisés tels quels pour toutes les prévisions futures.

#### 4.1.2 Données d'observation

Des ensembles de données d'observation sur plusieurs sites éoliens réels sont rendus disponibles pour ce projet par WPred. Ces données proviennent de systèmes SCADA (*supervisory control and data aquisition*) qui permettent d'enregistrer les comportements de la turbine. Comme les données de prévision, les observations sont moyennées autour de l'heure. La donnée de vitesse de vent à 14h00, par exemple, correspond à la moyenne des vitesses enregistrées entre 13h30 et 14h30 (de même pour les autres variables météorologiques disponibles). Les données obtenues par SCADA ne sont pas toujours complètes : par exemple, un détecteur défectueux peut enregistrer la même donnée de température à plusieurs chiffres significatifs près pendant plusieurs heures de suite. Un contrôle de qualité a donc été fait sur ces données afin de retirer les valeurs erronées. En général, les données suivantes sont disponibles dans les fichiers d'observations :

1.  $\mathbf{v}$  : Vitesse du vent moyenne de toutes les éoliennes (m/s)
2.  $\theta$  : Direction du vent moyenne de toutes les éoliennes (par rapport au Nord, en radians)
3.  $\mathbf{T}$  : Température ( $^{\circ}\text{C}$ )
4.  $\mathbf{p}$  : Puissance (somme de toutes les éoliennes, kW)

La totalité des sites étudiés est située en Europe ou en Amérique du Nord. Par souci de confidentialité, leur identité et leur localisation ne peuvent être divulguées dans cette étude. Les vingt sites étudiés sont numérotés de 1 à 20 afin de pouvoir les distinguer. Généralement, les quatre données énumérées ci-dessus sont disponibles, toutefois certains sites ne possèdent pas de données de puissance. Pour les sites #4, #5 et #13, l'ensemble est trop incomplet pour être utilisé (plus de 25% des données sont manquantes). Le tableau 4.1 regroupe les sites étudiés et leurs caractéristiques : les données disponibles, la région et la complexité du terrain (la valeur **2** correspondant au terrain le plus complexe et **0** le moins complexe, selon une analyse qualitative des cartes topographiques). Les sites ont également été rassemblés en 9 groupes, à l'intérieur desquels les sites sont espacés de 100 km ou moins.

En application, les exploitants envoient les observations en temps réel afin que le modèle puisse se mettre à jour à chaque pas de temps. Pour l'analyse, les observations sont donc fournies au filtre de Kalman comme si elles étaient reçues à chaque heure, de façon à simuler une situation réelle.

Tableau 4.1 Description des sites éoliens

#	Complexité du terrain 0 (-) → 2 (+)	Nombre de données (jours)	Données disponibles	Région	Groupe
<b>1</b>	0	731	v,θ,T,p	Europe	A
<b>2</b>	0	731	v,θ,T,p		
<b>3</b>	0	731	v,θ,T,p		
<b>4</b>	2	1035	v,θ,T	Europe	B
<b>5</b>	2	1035	v,θ,T		
<b>6</b>	0	382	v,θ,T,p	Europe	C
<b>7</b>	0	619	v,θ,T,p		
<b>8</b>	0	619	v,θ,T,p		
<b>9</b>	1	382	v,θ,T,p	Europe	D
<b>10</b>	0	382	v,θ,T,p		
<b>11</b>	0	382	v,θ,T,p		
<b>12</b>	1	382	v,θ,T,p		
<b>13</b>	0	382	v,θ,T	Europe	E
<b>14</b>	0	1035	v,θ,T,p		
<b>15</b>	0	382	v,θ,T,p	Europe	F
<b>16</b>	0	382	v,θ,T,p		
<b>17</b>	0	730	v,θ,T,p	Amérique du Nord	G
<b>18</b>	0	756	v,θ,T,p		
<b>19</b>	0	2043	v,θ,T,p	Amérique du Nord	H
<b>20</b>	0	1949	v,θ,T,p	Amérique du Nord	I

## 4.2 Étude préliminaire

Plusieurs études mentionnées précédemment montrent que l'ajout de la direction dans les modèles statistiques peut améliorer la précision des prévisions de la vitesse du vent [27, 72]. Pour confirmer l'hypothèse avancée dans ce projet, les données historiques disponibles ont été analysées afin d'étudier l'influence de la direction du vent sur la précision des prévisions.

Pour certains sites, le vent est beaucoup plus directionnel. Le site #4, par exemple, présente cette forte directionnalité (la Figure 4.1(a) montre la distribution des directions de vent pour ce site). Lorsqu'on examine l'erreur moyenne absolue (MAE) du modèle de PNT selon la direction pour ce même endroit, on voit qu'elle est corrélée avec la direction (Figure 4.1(b)). Cette observation confirme qu'appliquer un modèle unique pour toutes les directions du vent n'est pas suffisant, et que notre modèle pourrait bénéficier de l'ajout de la direction comme paramètre d'entrée. Il est à noter que tous les sites ne présentent pas une variation aussi grande du MAE en fonction de la direction. Pour le site #20 par exemple (Figure 4.2), cette corrélation semble plus faible. Néanmoins, l'influence de la direction du vent sur la précision

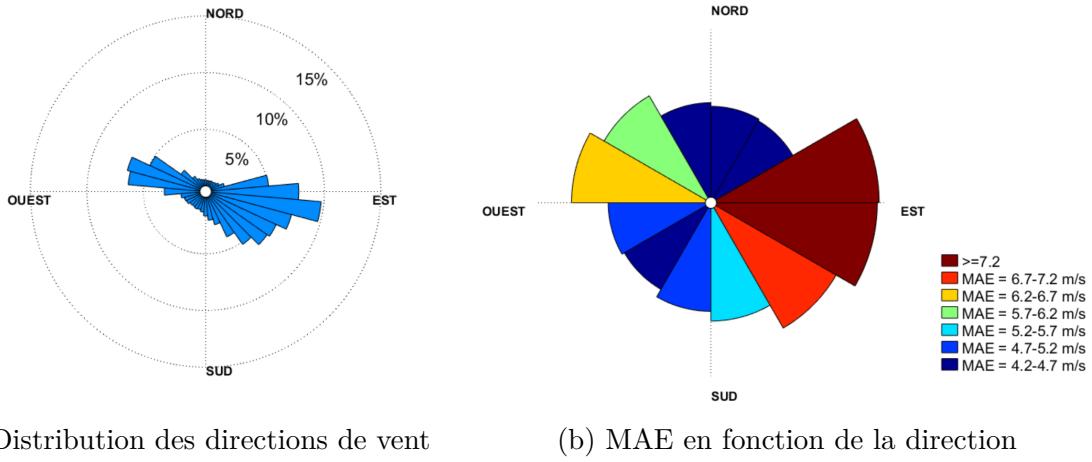


Figure 4.1 Analyse des données historiques du site #4

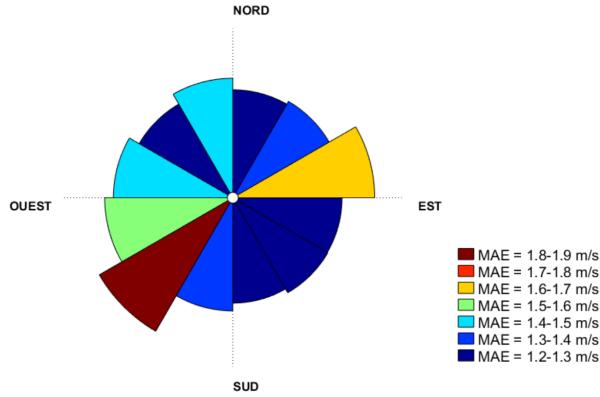


Figure 4.2 MAE en fonction de la direction pour le site #3

des prévisions demeure présente. Pour plus d'exemples, d'autres distributions et analyses directionnelles du MAE sont données à l'Annexe A.

### 4.3 Validation des modèles

Une fois les modèles implémentés, il est essentiel de s'assurer que le filtre fonctionne adéquatement, c'est-à-dire qu'il n'y ait pas d'erreurs d'implémentation dans le code. À cet effet, de *fausses prévisions* ont été créées à partir de coefficients fixes pour chacun des six modèles étudiés. Par exemple, pour le modèle d'ordre 1, le biais est défini par :

$$y_t = \alpha_{0,t} + \beta_{0,t} \cdot \hat{v}_{t,PNT} + m_t \quad (4.2)$$

En se basant sur un ensemble de données observées, on pose des coefficients fixes pour le biais (par exemple  $\alpha_{0,t} = 1$  et  $\beta_{0,t} = 0.1$ ), de manière à créer l'ensemble de données de prévision *fictives* ( $\hat{v}_{t,PNT}$ ) pour lesquelles le biais correspond à cette équation exactement. Ainsi, pour toute prévision fictive  $\hat{v}_{t,PNT}$ , l'observation  $v_t$  y étant associée correspond exactement à :

$$v_t = \hat{v}_{t,PNT} + y_t = \hat{v}_{t,PNT} + (\alpha_{0,t} + \beta_{0,t} \cdot \hat{v}_{t,PNT}) \quad (4.3)$$

Six ensembles de données fictives sont créés de cette façon, et chacun des modèles est testé sur son ensemble respectif afin de vérifier qu'il converge bien vers les coefficients imposés.

#### 4.3.1 Initialisation des paramètres du filtre

Avant la première itération, les coefficients du filtre sont d'abord initialisés. Posons  $L$  la longueur du vecteur d'état, soit le nombre de coefficients à estimer. Ainsi, on initialise le vecteur d'état  $\mathbf{x}_0$  comme un vecteur nul de longueur  $L$ . La matrice de covariance du vecteur d'état de départ  $\mathbf{P}_0$  est définie comme une matrice identité de dimensions  $L \times L$ , de même que pour la matrice de covariance de l'équation de système  $\mathbf{Q}_0$ . Finalement, la covariance initiale de l'équation d'observations  $\mathbf{R}_0 = 6$  est posée comme une valeur assez élevée afin de permettre une indépendance rapide des conditions initiales.

#### 4.3.2 Convergence des coefficients du vecteur d'état

Les figures suivantes montrent la variation des coefficients du vecteur d'état par rapport à leurs valeurs finales (en %), en fonction des itérations du filtre de Kalman pour les ensembles de données fictives décrits précédemment. Les données sont affichées jusqu'à ce que la variation de tous les coefficients soit inférieure à 0,1%.

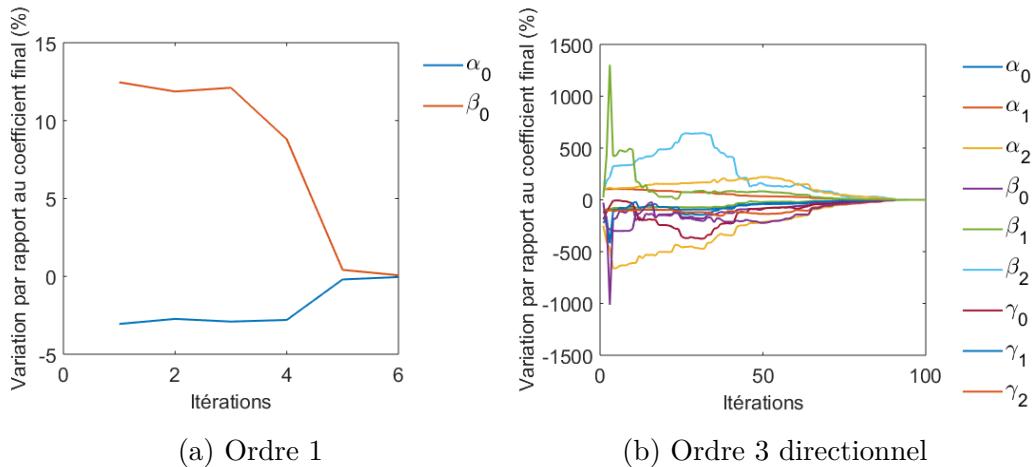


Figure 4.3 Validation des modèles

Comme il est possible de voir dans les figures ci-dessus, les modèles parviennent à converger vers les bons coefficients en un maximum de 100 itérations. La Figure 4.3(a) correspond au modèle possédant le moins de coefficients à évaluer (modèle d'ordre 1, non directionnel). Pour ce cas, le modèle converge très rapidement, après seulement 6 itérations. Pour le modèle le plus complexe (ordre 3 directionnel, 12 coefficients à évaluer), il faut plutôt 100 itérations, soit 100 heures, avant que le modèle ne converge. On remarque donc que plus le nombre de coefficients augmente, plus le nombre d'itérations nécessaires avant que les coefficients convergent vers des valeurs fixes est élevé. À des fins de comparaison, les graphiques de variation des coefficients pour les six modèles sont donnés en Annexe B.

Il est à noter que dans un cas réel, les coefficients ne convergeront pas nécessairement, puisque le biais ne suit pas exactement la relation polynomiale déterminée. Néanmoins, cette analyse permet d'avoir un indicatif de la durée de temps nécessaire pour entraîner le filtre après sa première application. Dans l'analyse des données présentée dans ce chapitre, les dix premiers jours (ou 240 premières itérations) d'application des filtres n'ont pas été considérés, ce qui dépasse largement le temps de convergence du filtre le plus complexe.

## 4.4 Analyse des résultats

L'objectif de l'analyse qui suit est d'étudier les différents modèles développés à la section 3.3.1 pour la vitesse du vent. D'abord, l'effet de l'ajout de la direction dans les modèles est analysé, puis les performances en fonction des différents ordres polynomiaux sont également examinées. Ultimement, nous tentons d'identifier le meilleur modèle.

Dans ce mémoire, les performances des filtres de Kalman développés sont principalement comparées à celles des données brutes du modèle de PNT, ainsi qu'à la persistance. Tel que mentionné précédemment, elles sont aussi comparées aux prévisions de WPred (modèle MOS) afin de déterminer si, et à quel point, les modèles développés ici améliorent leurs prévisions.

### 4.4.1 Performance des modèles

Le projet est centré sur l'amélioration des prévisions à court terme. Plus particulièrement, ce sont les six premières heures d'horizon qui nous intéressent. Les indicateurs donnés dans cette première section sont présentés sous forme de moyenne entre  $h = 1$  et  $h = 6$ , inclusivement. Ce choix a été fait afin de permettre une comparaison plus facile avec les études réalisées précédemment. Par ailleurs, puisque la persistance est désignée comme un bon modèle de référence pour les 6 premières heures [59], les horizons sélectionnés permettent une comparaison adéquate avec la persistance. Le tableau 4.2 présente d'abord le biais (ME), permettant de déterminer si le modèle a tendance à prédire des vitesses trop élevées ou trop

faibles. En d'autres termes, un biais nul signifie que la distribution des erreurs est centrée en 0, si on suppose une distribution normale. Le ME est donné pour tous les modèles, ainsi que pour les données de PNT brutes. Ensuite, l'erreur absolue moyenne (MAE) et l'erreur moyenne quadratique (RMSE) sont données aux tableaux 4.3 et 4.4 respectivement. Il est à noter que les modèles qualifiés de *classiques* dans les tableaux ci-dessous correspondent aux modèles non directionnels développés par Louka et Galanis.

Tableau 4.2 ME (m/s) sur la vitesse, moyenne de  $h = 1$  à  $h = 6$ \*

# Site	PNT	Ordre 1		Ordre 2		Ordre 3	
		Classique	Avec $\theta$	Classique	Avec $\theta$	Classique	Avec $\theta$
1	-0,16	<b>-0,05</b>	-0,07	-0,07	-0,06	-0,07	-0,08
2	0,40	0,08	0,06	<b>0,05</b>	<b>0,05</b>	0,06	0,07
3	2,22	0,07	0,06	0,06	0,07	<b>0,05</b>	0,06
4	-7,42	-0,22	-0,23	-0,23	<b>-0,21</b>	-0,25	-0,25
5	-6,82	<b>-0,10</b>	-0,12	-0,11	-0,18	-0,14	-0,20
6	1,67	<b>0,02</b>	0,04	<b>0,02</b>	0,04	<b>0,02</b>	0,04
7	1,03	<b>0,00</b>	0,04	0,03	0,04	-0,01	0,03
8	1,11	<b>0,00</b>	0,03	<b>0,00</b>	0,03	-0,01	0,02
9	1,39	<b>0,00</b>	<b>0,00</b>	0,01	0,03	0,03	0,02
10	2,26	0,02	0,02	0,03	<b>0,01</b>	0,02	<b>0,01</b>
11	1,30	0,01	<b>0,00</b>	0,02	<b>0,00</b>	0,03	<b>0,00</b>
12	1,11	<b>0,00</b>	0,01	<b>0,00</b>	0,03	0,02	0,03
13	0,98	-0,06	-0,05	-0,04	-0,03	-0,05	<b>0,01</b>
14	1,27	0,02	0,02	<b>0,01</b>	-0,02	<b>-0,01</b>	-0,02
15	1,35	<b>0,00</b>	0,02	0,03	0,01	0,01	0,01
16	1,70	<b>0,02</b>	0,04	0,04	0,04	0,05	0,06
17	2,70	0,18	0,19	0,22	0,17	<b>0,13</b>	0,15
18	0,91	-0,12	-0,20	<b>-0,12</b>	-0,19	<b>-0,12</b>	-0,16
19	0,96	0,02	<b>-0,01</b>	<b>0,01</b>	-0,06	<b>0,01</b>	-0,05
20	-2,09	<b>-0,05</b>	-0,07	-0,11	-0,06	-0,09	-0,13
<b>Biais moyen</b>		<b>0,05</b>	<b>0,06</b>	<b>0,06</b>	<b>0,07</b>	<b>0,06</b>	<b>0,07</b>

\*Plus le biais moyen est **faible**, meilleures sont les prévisions. Les erreurs minimales pour chacun des sites sont en gras.

Tableau 4.3 MAE (m/s) sur la vitesse, moyenne de  $h = 1$  à  $h = 6$ \*

# Site	PNT	Ordre 1		Ordre 2		Ordre 3	
		Classique	Avec $\theta$	Classique	Avec $\theta$	Classique	Avec $\theta$
1	1,27	1,13	<b>1,12</b>	<b>1,12</b>	<b>1,12</b>	1,13	1,14
2	1,43	<b>1,21</b>	1,22	1,22	1,23	1,24	1,24
3	2,73	1,28	1,24	1,26	<b>1,23</b>	1,26	<b>1,23</b>
4	7,42	1,74	<b>1,72</b>	1,76	<b>1,72</b>	1,77	1,74
5	6,82	1,64	<b>1,59</b>	1,68	1,60	1,68	1,63
6	1,97	<b>0,94</b>	0,95	<b>0,94</b>	0,95	<b>0,94</b>	0,95
7	1,98	1,18	1,15	1,17	1,15	1,17	<b>1,14</b>
8	2,11	1,14	<b>1,10</b>	1,13	<b>1,10</b>	1,13	1,11
9	1,81	<b>0,83</b>	<b>0,83</b>	0,84	0,84	0,85	0,85
10	2,49	0,96	0,95	0,95	<b>0,93</b>	0,95	0,95
11	1,78	0,85	0,85	0,85	<b>0,84</b>	0,86	0,86
12	1,77	<b>0,91</b>	<b>0,91</b>	<b>0,91</b>	0,91	0,92	0,92
13	1,37	1,04	1,00	1,02	<b>0,96</b>	1,02	0,98
14	1,74	0,96	0,96	0,96	<b>0,95</b>	0,97	0,96
15	1,90	0,84	0,84	0,84	<b>0,83</b>	0,85	0,85
16	2,01	0,87	0,86	0,86	<b>0,85</b>	0,86	0,87
17	3,64	2,40	<b>2,24</b>	2,46	2,33	2,49	2,28
18	2,32	2,14	2,06	2,16	2,07	2,22	<b>2,04</b>
19	1,69	1,23	<b>1,22</b>	1,24	1,24	1,25	1,23
20	2,35	1,25	<b>1,23</b>	1,32	1,25	1,29	1,26
<b>Amélioration moyenne</b>		<b>44,2%</b>	<b>45,1%</b>	<b>43,9%</b>	<b>45,1%</b>	<b>43,6%</b>	<b>44,7%</b>

\*Plus l'amélioration est **élevée**, meilleures sont les prévisions. Les erreurs minimales pour chacun des sites sont en gras.

Tableau 4.4 RMSE (m/s) sur la vitesse, moyenne de  $h = 1$  à  $h = 6^*$ 

# Site	PNT	Ordre 1		Ordre 2		Ordre 3	
		Classique	Avec $\theta$	Classique	Avec $\theta$	Classique	Avec $\theta$
1	1,63	<b>1,45</b>	1,46	<b>1,45</b>	<b>1,45</b>	1,48	1,49
2	1,86	<b>1,59</b>	1,61	1,61	1,63	1,63	1,64
3	3,53	1,68	1,64	1,68	<b>1,63</b>	1,67	<b>1,63</b>
4	7,94	2,24	<b>2,23</b>	2,25	2,24	2,28	2,28
5	7,27	2,11	<b>2,07</b>	2,16	2,08	2,17	2,11
6	2,37	<b>1,24</b>	1,25	<b>1,24</b>	1,25	<b>1,24</b>	1,26
7	2,52	1,55	<b>1,53</b>	1,56	<b>1,53</b>	1,55	1,54
8	2,66	1,49	<b>1,45</b>	1,49	<b>1,45</b>	1,50	1,47
9	2,24	<b>1,10</b>	<b>1,10</b>	1,11	1,11	1,14	1,14
10	3,06	1,25	1,26	1,24	<b>1,23</b>	1,24	1,28
11	2,17	1,12	1,12	<b>1,11</b>	1,12	1,13	1,15
12	2,21	<b>1,21</b>	1,22	1,22	<b>1,21</b>	1,24	1,26
13	1,69	1,39	1,33	1,36	<b>1,29</b>	1,39	1,34
14	2,17	1,26	1,26	1,26	<b>1,25</b>	1,27	1,27
15	2,37	<b>1,09</b>	1,10	<b>1,09</b>	<b>1,09</b>	1,10	1,15
16	2,43	1,14	1,15	<b>1,13</b>	1,14	1,15	1,18
17	4,60	3,29	<b>3,05</b>	3,37	3,20	3,41	3,11
18	2,92	2,84	2,78	2,86	2,78	2,95	<b>2,75</b>
19	2,16	<b>1,62</b>	<b>1,62</b>	1,64	1,66	1,64	<b>1,62</b>
20	2,80	<b>1,62</b>	<b>1,62</b>	1,76	1,67	1,73	1,69
<b>Amélioration moyenne</b>		40,9%	41,6%	40,5%	41,4%	39,9%	40,6%

\*Plus l'amélioration est élevée, meilleures sont les prévisions. Les erreurs minimales pour chacun des sites sont en gras.

Dans les tableaux de MAE et RMSE, l'amélioration moyenne (ou la réduction moyenne de l'indicateur) est donnée au bas de tableau pour chaque modèle. Une première conclusion pouvant être tirée des informations ci-dessus est que les modèles directionnels performent en moyenne mieux que les modèles non directionnels au niveau du MAE et du RMSE. En outre, le biais moyen est réduit à des valeurs très près de zéro pour tous les modèles. Ceci étant dit, le choix du modèle le plus performant parmi les six étudiés n'est pas trivial. Une analyse des tableaux de ME, MAE et RMSE sera effectuée dans les lignes suivantes, dans le but d'en interpréter le contenu. Il est à noter que dans les légendes des graphiques qui sont présentés ci-dessous, les notations suivantes sont utilisées :

- **PNT** : Données brutes de prévision numérique du temps d'EC
- **O1** : FK avec biais d'ordre 1
- **O2** : FK avec biais d'ordre 2
- **O3** : FK avec biais d'ordre 3
- **O1 Dir** : FK avec biais d'ordre 1 incluant la direction
- **O2 Dir** : FK avec biais d'ordre 2 incluant la direction
- **O3 Dir** : FK avec biais d'ordre 3 incluant la direction

**Biais** D'abord, on remarque que le biais de tous les modèles est considérablement réduit comparativement au modèle de PNT. En effet, il passe de 1,94 m/s en moyenne pour les prévisions brutes à entre 0,05 m/s et 0,07 m/s pour les modèles développés. Cette observation

indique que les filtres de Kalman fonctionnent correctement, puisque c'est ce biais qu'ils tentent de prédire et de corriger. Tel que mentionné à la section 2.5, le biais moyen permet de savoir si le modèle a tendance à sur-prédire ou sous-prédire. Cependant, cet indicateur, lorsque calculé sur l'ensemble de données au complet, ne donne qu'une information préliminaire sur la qualité des prévisions. Il ne permet pas de mesurer la performance réelle d'une approche : il est très improbable qu'un modèle ayant un biais nul sur un ensemble de données montre des prévisions parfaites. Un biais nul signifie uniquement que les erreurs positives et négatives s'annulent sur la période d'évaluation [59].

**MAE** Le MAE est une mesure plus commune permettant de tenir compte de la contribution à la fois des erreurs positives et des erreurs négatives. Pour cet indicateur, tous les filtres directionnels performent en moyenne mieux que leurs homonymes non directionnels. On remarque aussi que plus l'ordre du polynôme diminue, plus l'amélioration est élevée.

**RMSE** Les résultats sont très similaires au niveau du RMSE. L'amélioration moyenne par rapport au modèle de PNT donnée au tableau 4.4 a tendance à être plus élevée pour les modèles directionnels. Comme pour le MAE, les ordres plus élevés présentent encore une fois des performances inférieures.

**Distribution des erreurs** Une autre façon de représenter les résultats présentés aux tableaux 4.2, 4.3 et 4.4 est d'étudier la distribution des erreurs. Les Figures 4.4(a) et 4.4(b) montrent les distributions des erreurs du site #20, pour les horizons  $h = 1$  et  $h = 6$ . Dans les deux cas, on remarque nettement la réduction du biais : les distributions sont beaucoup plus centrées et symétriques pour les données filtrées que pour les prévisions brutes du modèle de PNT. Les distributions sont également plus étroites et moins évasées pour les modèles développés, ce qui résulte en des MAE et RMSE réduits.

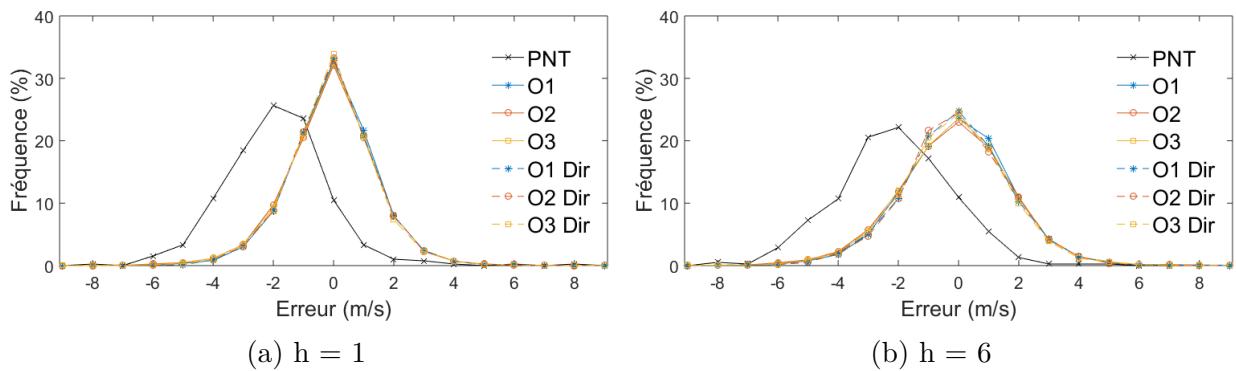


Figure 4.4 Distributions des erreurs sur la vitesse pour le site #20

L'observation du comportement des prévisions en fonction du temps permet de voir que les filtres directionnels sont plus instables que ceux qui ne dépendent pas de la direction. Par *instabilité*, on entend une sur-sensibilité de la méthode de régression, ce qui peut provoquer des écarts soudains dans la prévision par rapport au pas de temps précédent. Il est possible de constater la différence entre les comportements des deux types de modèles à la Figure 4.5 : les filtres conventionnels n'incluant pas la direction sont plus lisses, alors que les filtres directionnels montrent des comportements plus instables.

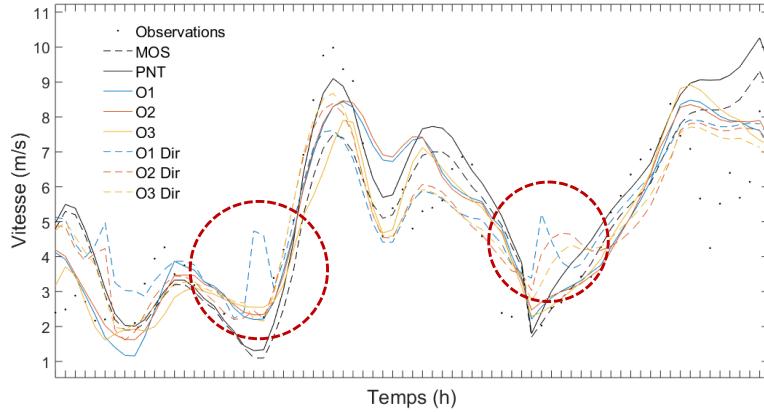


Figure 4.5 Exemple d'instabilité pour le site #4

À la Figure 4.6 cependant, l'ajout de la direction permet, à l'opposé, de détecter certaines subtilités dues à la directionnalité du vent que les modèles non directionnels ne parviennent pas à identifier. D'autres exemples sont donnés à l'Annexe C.

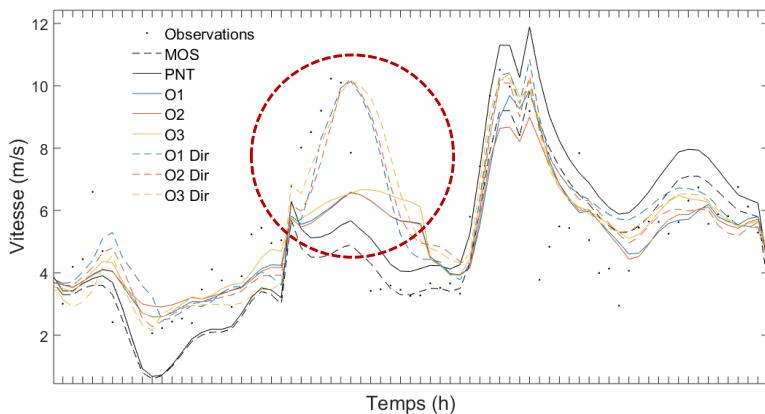


Figure 4.6 Exemple de détection pour le site #7

Ces instabilités peuvent être expliquées par le nombre plus élevé de coefficients dans les approches directionnelles (voir le tableau 4.5). En effet, comme décrit à la section 3.3.1,

l'approche utilisée pour rendre l'équation du biais dépendante de la direction consiste à diviser chaque coefficient en 3 nouveaux coefficients. Ainsi,  $\alpha_t$  devient  $\alpha_{0,t} + \alpha_{1,t} \cdot \sin\theta_{t,PNT} + \alpha_{2,t} \cdot \cos\theta_{t,PNT}$ . Par conséquent, chaque version directionnelle d'un modèle possède 3 fois plus de coefficients à estimer que son homonyme non directionnel. Généralement, lorsqu'on effectue une régression, l'ajout de paramètres dans un modèle rend la régression plus sensible, et donc plus prompte aux instabilités.

Tableau 4.5 Nombre de coefficients à évaluer pour chaque modèle

Modèle	Ordre 1	Ordre 2	Ordre 3	Ordre 1 $f(\theta)$	Ordre 2 $f(\theta)$	Ordre 3 $f(\theta)$
<b>Nb. de coefficients</b>	2	3	4	6	9	12

Somme toute, l'ajout de la direction dans les filtres de Kalman améliore les prévisions. Ces modèles parviennent à détecter l'influence de la direction du vent et améliorer les prévisions à certains moments, mais sont toutefois plus instables que les modèles non directionnels, ce qui limite leur performance. De plus, on observe que plus l'ordre est élevé, plus les erreurs (MAE et RMSE) sont grandes.

#### 4.4.2 Performance en fonction de l'horizon

Dans cette section, une analyse des erreurs en fonction de l'horizon est présentée. Afin d'étudier la performance globale des différents modèles, les indicateurs sont moyennés sur tous les sites. Par exemple, le RMSE du modèle d'ordre 1 non directionnel pour l'horizon  $h = 1$  correspond à la moyenne du RMSE à  $h = 1$  sur *tous les sites*, pour ce modèle.

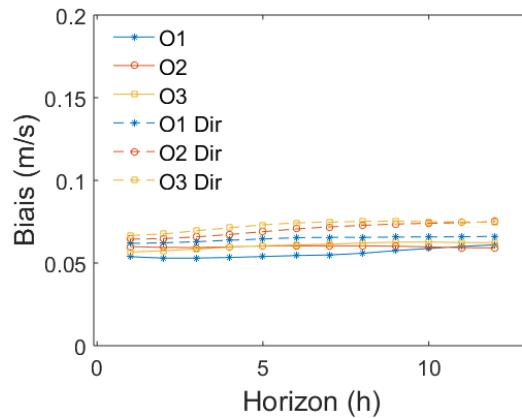


Figure 4.7 Biais moyen en fonction de l'horizon

Premièrement, la Figure 4.7 donne le biais moyen en fonction de l'horizon de prévision. Dans cette figure, l'échelle utilisée n'est pas la même que pour les MAE et RMSE aux

Figures 4.8(a) et 4.8(b) : elle est légèrement agrandie afin de distinguer plus facilement les différentes courbes. Il est à noter que le biais peut être négatif lorsque les modèles ont tendance à sous-prédire. Ici, pour calculer la moyenne, la valeur absolue de ce biais est utilisée. On peut voir que le biais est considérablement réduit pour tous les horizons. Les filtres directionnels semblent présenter un biais légèrement plus élevé ; cependant, tel que mentionné plus tôt, il s'agit d'un indicateur préliminaire, ne permettant pas de conclure quant à la performance d'un modèle.

Le MAE et le RMSE en fonction de l'horizon sont donnés aux Figures 4.8(a) et 4.8(b). La première observation pouvant en être déduite est que, tel que noté précédemment, les modèles directionnels performent en moyenne mieux, et ce, pour tous les horizons.

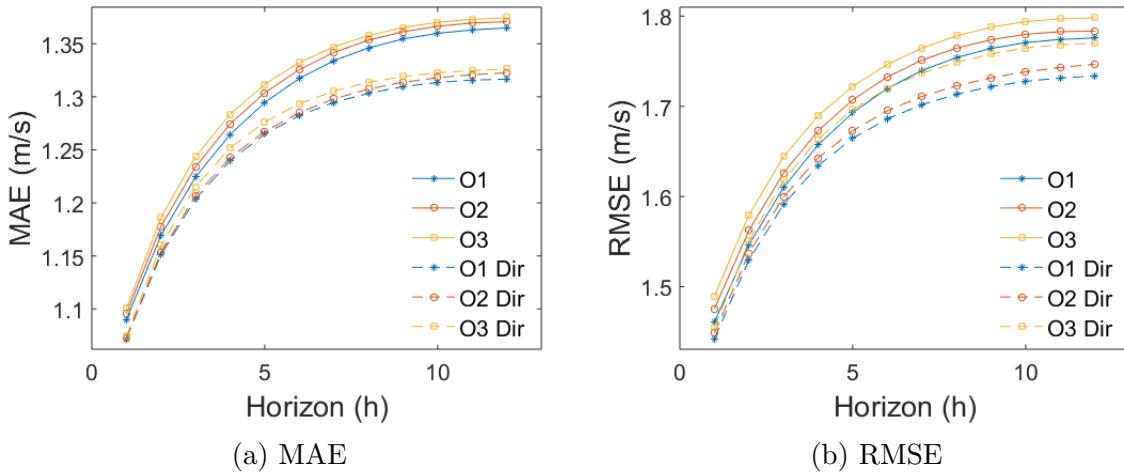


Figure 4.8 MAE et RMSE moyens en fonction de l'horizon

Dans la Figure 4.8(a), les modèles directionnels et non directionnels sont divisés en deux groupes nettement définis, confirmant que l'ajout de la direction est bénéfique pour les filtres de Kalman. Il est intéressant de noter que plus l'horizon de prévision augmente, plus l'écart entre les performances des deux types de modèles augmente.

La Figure 4.8(b) montre la même tendance pour le RMSE, toutefois de façon un peu moins définie que pour le MAE. Comme le RMSE caractérise l'erreur sous forme quadratique, il donne plus d'importance aux grandes erreurs. Ainsi, puisque les modèles directionnels présentent davantage d'instabilités, caractérisées par des écarts plus élevés et soudains dans la prévision, le RMSE est légèrement moins réduit que le MAE. En ce qui concerne l'ordre des modèles, comme il en a été déduit des tableaux 4.3 et 4.4, les modèles d'ordres inférieurs performent en moyenne mieux que les modèles d'ordres supérieurs pour tous les horizons.

Finalement, les Figures 4.9(a) et 4.9(b) présentent ces mêmes résultats sous forme d'amélioration moyenne par rapport au modèle de PNT. Il est intéressant de remarquer qu'en moyenne sur tous les sites, les MAE et RMSE sont significativement réduits pour tous les horizons étudiés, soit jusqu'à  $h = 12$ . Pour  $h = 1$ , les modèles améliorent de plus de 47% le MAE et de 44% le RMSE.

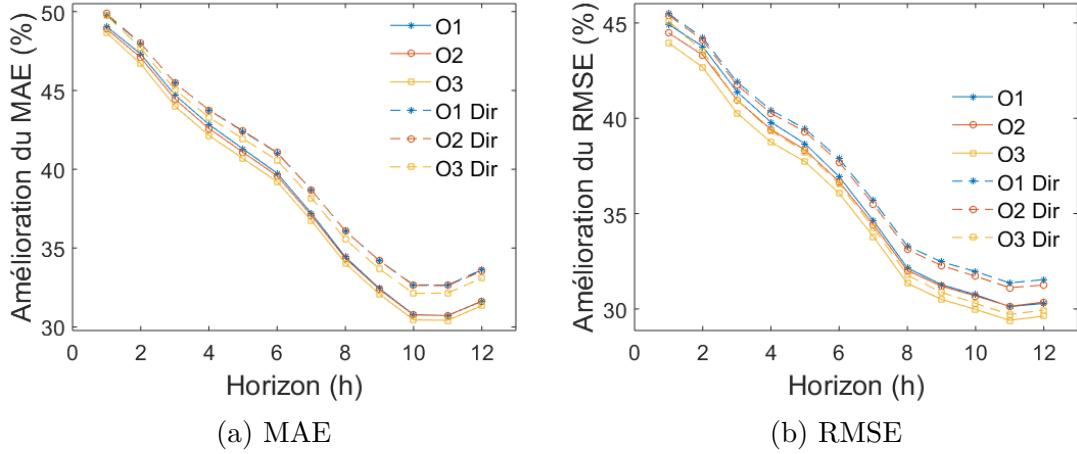


Figure 4.9 Amélioration moyenne par rapport aux PNTs en fonction de l'horizon

Afin d'étudier les distributions d'erreurs de façon globale pour tous les sites, des graphiques de marge d'erreur sont donnés. Cette représentation permet de montrer la proportion des erreurs contenues à l'intérieur d'une certaine marge. Ici, on considère que les erreurs supérieures à 4 m/s sont anormalement élevées, et que le pourcentage d'erreurs supérieures à cette valeur devrait être très faible. Les Figures 4.10(a) et 4.10(b) montrent les moyennes des pourcentages (ou fréquence) d'erreurs inférieures à  $\pm 1$  m/s et à  $\pm 4$  m/s en fonction de l'horizon.

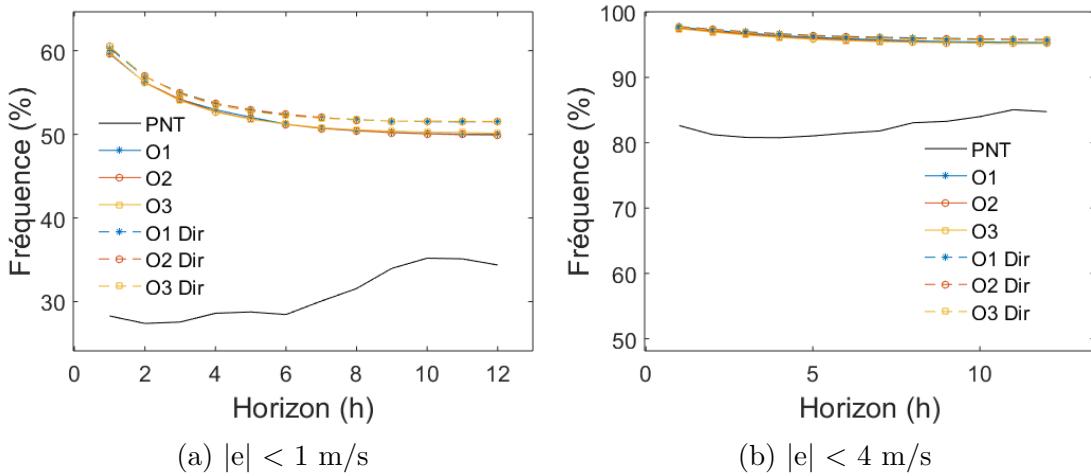


Figure 4.10 Distributions des erreurs sur la vitesse

La proportion d'erreurs contenues dans ces marges pour les six modèles développés est située entre 50-61% pour 1 m/s, et entre 95-98% pour 4 m/s. En opposition, cette proportion pour les PNTs ne dépasse pas les 35% et 85% pour les marges de 1 m/s et de 4 m/s respectivement (Figure 4.11). La distribution des erreurs est donc nettement plus étroite pour tous les modèles de filtre de Kalman comparativement aux PNTs. Puisque les biais sont réduits à des valeurs presque nulles, la distribution est aussi davantage centrée pour les filtres de Kalman.

Dans les Figures 4.11(a) et 4.11(b), la portion des figures précédentes contenant seulement les modèles statistiques a été agrandie afin de mieux constater la différence entre les différents modèles.

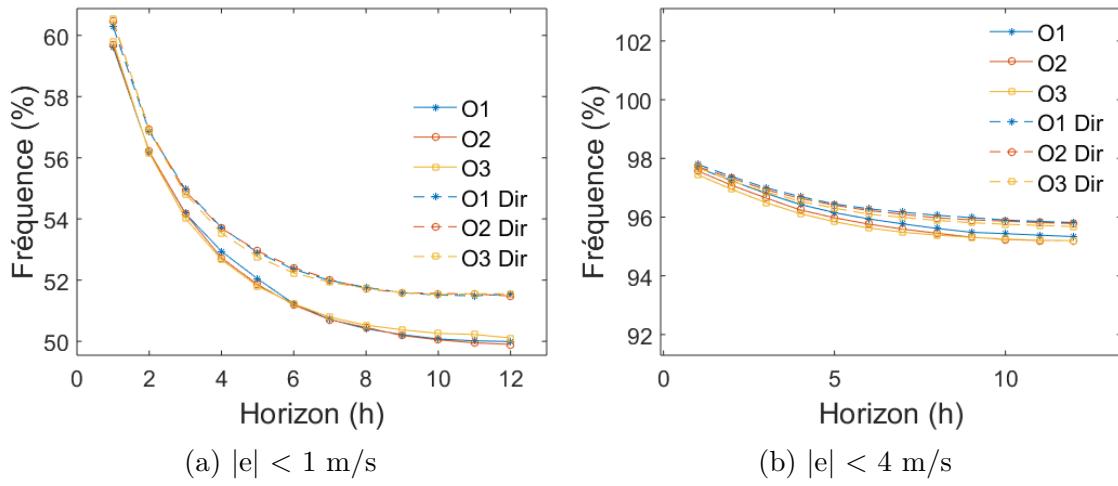


Figure 4.11 Distributions des erreurs sur la vitesse

L'analyse de la proportion d'erreurs contenues à l'intérieur de deux marges de tailles différentes permet de comparer la partie centrale de la distribution ainsi que son évasement. En comparant les deux graphiques, il est possible d'en déduire que les approches directionnelles produisent plus de faibles erreurs que les approches non directionnelles, ce qui signifie que la partie centrale des distributions des approches directionnelles est plus haute et plus étroite. D'un autre côté, la fréquence d'erreurs inférieures à 4 m/s est très similaire pour tous les modèles : l'évasement de la distribution n'est donc pas nettement plus prononcé pour aucun des modèles. En d'autres termes, la proportion d'erreurs anormalement élevées, soit supérieures à 4 m/s, se situe entre 2% et 5% pour tous les modèles et tous les horizons. Cela indique, en somme, que malgré les instabilités des filtres directionnels, ceux-ci ne génèrent pas davantage d'erreurs anormalement élevées. La fréquence de tels événements demeure faible, et même légèrement inférieure à celle des modèles non directionnels.

#### 4.4.3 Choix du meilleur modèle

Somme toute, suite aux analyses présentées précédemment, les ordres inférieurs démontrent une meilleure précision de façon globale, et l'introduction de la direction dans les modèles se montre également bénéfique.

Il ne faut pas oublier que ces résultats correspondent à des valeurs moyennes de performance pour les 20 sites étudiés : il s'agit donc uniquement d'une tendance. Comme il a été montré plus tôt, la performance de chaque modèle varie d'un site à l'autre. Bien que l'ordre 1 directionnel donne de meilleurs résultats en moyenne, il n'est pas absolument meilleur pour tous les sites étudiés. Par exemple, pour le site #18, le modèle d'ordre 3 directionnel permet d'atteindre les erreurs les plus faibles de façon globale, alors que pour le site #1, c'est plutôt le modèle d'ordre 2 non directionnel qui parvient aux meilleurs résultats (voir les tableaux 4.3 et 4.4). Cela suggère encore une fois que les performances des modèles sont fortement dépendantes de la position géographique et de la complexité du terrain étudié.

Par ailleurs, la précision des modèles varie aussi en fonction de l'horizon de prévision. Par exemple, pour le site #9 présenté à la Figure 4.12 ci-dessous, on voit qu'avant  $h = 3$ , les deux filtres d'ordre 1 ont des erreurs similaires, alors qu'après  $h = 3$ , le filtre d'ordre 1 directionnel montre le RMSE le plus faible. Puis, à  $h = 6$  l'ordre 2 les surpasse, et finalement, c'est l'ordre 1 non directionnel qui performe le mieux à partir de  $h = 10$ . Ainsi, il n'est pas toujours possible d'identifier un seul modèle qui minimise l'erreur mieux les autres pour tous les horizons.

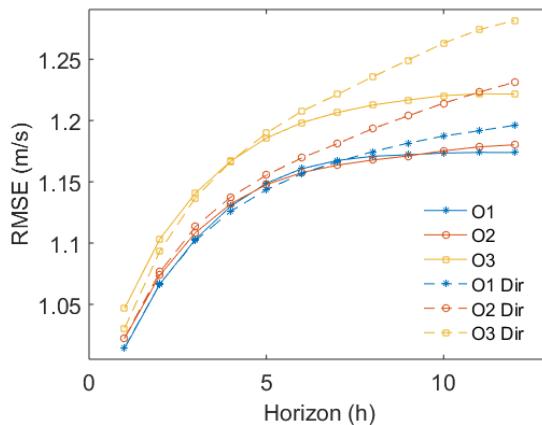


Figure 4.12 RMSE moyen en fonction de l'horizon pour le site #9

Parallèlement, la performance des modèles peut aussi varier en fonction du temps. L'instabilité des modèles directionnels en est un bon exemple : ils permettent à certains moments de détecter des variations dues à la directionnalité du vent que les autres modèles ne réussissent pas à prédire, alors qu'à d'autres moments, leur instabilité occasionne des erreurs plus élevées que les modèles non directionnels.

Une façon de répondre en partie aux problématiques mentionnées ci-dessus serait de tester tous les filtres sur un ensemble de données historiques d'un site spécifique, afin de choisir le modèle le plus précis, puis utiliser ce dernier pour réaliser les prévisions. Toutefois, cette approche réduit l'attrait du filtre de Kalman venant du fait qu'il peut être appliqué rapidement et sans besoin de données historiques. Par ailleurs, elle n'adresse pas non plus la question de la variation de la performance en fonction de l'horizon. Une approche suggérée pour résoudre ces problématiques est la combinaison des modèles proposée par Sanchez [63] et décrite à la section 3.4 de ce mémoire. Elle permettrait de rendre le choix des modèles spécifique à chaque site et chaque horizon de prévision, et ce, de façon adaptative (variable dans le temps).

#### 4.4.4 Combinaison des modèles

L'approche de combinaison est très intéressante par sa facilité d'application. En effet, lorsqu'on désire implémenter un filtre de Kalman sur un nouveau site, tous les modèles peuvent être immédiatement appliqués, et l'algorithme choisit le meilleur d'entre eux, ou la meilleure combinaison, de façon automatique et adaptative.

#### Analyse des erreurs

Les modèles individuels performent en majorité très bien comparativement aux PNTs pour tous les horizons. Pour  $h = 1$  à  $h = 6$ , l'amélioration moyenne du RMSE entre le pire et le meilleur modèle de filtre de Kalman peut cependant atteindre 16%, ce qui est significatif au niveau de la qualité des prévisions. Définir le modèle le plus précis est donc essentiel.

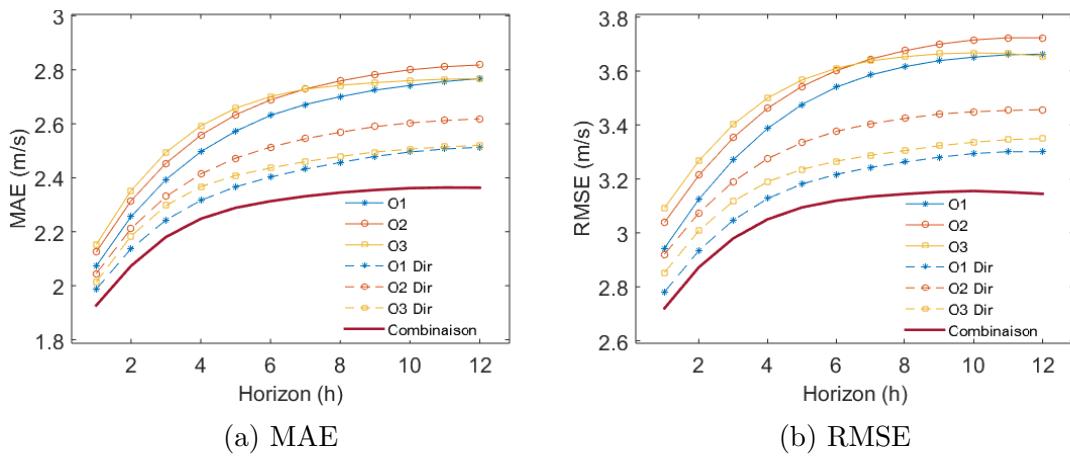


Figure 4.13 Combinaison des modèles pour le site #17

L'application de la méthode de combinaison permet donc de pondérer les modèles de façon adaptative et en fonction de l'horizon afin d'obtenir des performances égales ou supérieures au meilleur des six modèles développés. Les Figures 4.13(a) et 4.13(b) ci-dessus montrent un exemple de résultats de l'approche de combinaison proposée pour le site #17.

Le tableau 4.6 présente les résultats finaux de l'approche hybride incluant les filtres de Kalman directionnels et non directionnels combinés à l'aide de la méthode proposée par Sanchez, et ce, sous forme de moyenne sur tous les sites. Les améliorations (*Impr*) par rapport au modèle de PNT, au MOS, à la persistance ainsi que par rapport au pire et au meilleur modèle (parmi les 6 filtres de Kalman proposés) y sont données. À titre de rappel, l'équation définie à la section 2.5 pour le calcul d'amélioration (*improvement*) est la suivante :

$$Impr(h) = \frac{RMSE^{ref}(h) - RMSE^{KF-comb}(h)}{RMSE^{ref}(h)} \quad (4.4)$$

où  $RMSE^{ref}(h)$  représente le RMSE de la méthode de référence (PNT, MOS, persistance, meilleur et pire modèle), et  $RMSE^{KF-comb}(h)$  celui associé à la combinaison des filtres de Kalman. Ainsi, une valeur négative de la valeur  $Impr(h)$  signifie que le modèle est moins précis que la méthode de référence au niveau du RMSE.

Tableau 4.6 Amélioration du RMSE (m/s) sur la vitesse (avec combinaison), moyenne de h=1 à h=6\*

#	Amélioration par rapport à				
	PNT (%)	MOS (%)	persistance (%)	pire modèle (%)	meilleur modèle (%)
1	14,05	13,03	14,81	6,16	3,66
2	17,19	8,53	11,47	6,13	3,24
3	54,75	23,89	8,77	4,91	1,90
4	73,82	66,34	-11,70	8,89	6,68
5	73,57	65,47	-9,39	11,56	6,91
6	48,98	18,30	14,84	3,86	2,48
7	41,28	27,30	10,36	5,21	3,26
8	46,74	26,36	11,15	5,37	2,07
9	52,39	23,86	16,52	6,59	3,31
10	61,12	32,32	19,42	6,84	3,11
11	50,59	24,63	17,29	6,89	3,66
12	47,54	23,97	6,74	7,94	4,19
13	26,07	7,08	21,60	10,33	2,89
14	43,35	16,59	18,36	3,68	2,00
15	55,82	29,48	19,58	8,56	3,85
16	54,85	21,87	16,26	6,79	3,32
17	35,37	8,52	-36,67	12,74	2,47
18	11,25	2,86	-20,46	12,08	5,92
19	29,34	13,81	10,11	7,98	5,48
20	47,28	36,62	6,11	16,20	8,79
<b>Moyenne</b>	<b>44,3%</b>	<b>24,5%</b>	<b>7,3%</b>	<b>7,9%</b>	<b>4,0%</b>

\*Plus l'amélioration moyenne est élevée, meilleures sont les prévisions.

L'amélioration moyenne du RMSE par rapport au modèle de PNT passe d'entre 39,9% et 41,6% pour les modèles individuels (voir la dernière ligne du tableau 4.4) à 44,3% lorsque la combinaison est appliquée. De plus, le RMSE est réduit pour tous les sites comparativement au modèle MOS utilisé par WPred, en moyenne de 24,5%.

Dans l'optique où on ne connaît pas le modèle le plus précis pour un site en particulier, il est intéressant de comparer l'approche de combinaison au pire modèle ayant pu être choisi pour ce site. En moyenne, l'approche permet de réduire le RMSE de 7,9% en moyenne par rapport au pire modèle, mais peut dépasser 16% pour un site individuel. Plus encore, la performance globale de la solution combinée est toujours supérieure à celle du meilleur modèle possible, soit de 4,0% en moyenne (et peut atteindre 8% de façon individuelle).

En étudiant les résultats du tableau 4.6, certains sites ressortent du lot : les #4, #5, #17, et #18. Pour ceux-ci, l'approche de combinaison est moins précise que la persistance pour  $h = 1$  à  $h = 6$ . Ce sont des sites pour lesquels le modèle de PNT ne parvient pas à bien prédire la vitesse du vent au départ, et leurs valeurs de RMSE avant filtrage sont parmi les plus élevées du lot : entre 2,9 m/s et 7,9 m/s. Il est intéressant de noter que les sites #4 et #5 constituent la région **B**, alors que #17 et #18 forment la région **G** (voir le tableau 4.1). Cette observation suggère encore une fois que la localisation géographique a une influence majeure sur la capacité des modèles à bien prédire les vitesses de vent.

Pour la région **B**, le modèle de PNT est à la base très peu performant : les biais moyens sont de -6,8 m/s et -7,4 m/s, et le RMSE dépasse les 7 m/s pour les deux sites (voir les tableaux 4.2, 4.3 et 4.4). Bien que les filtres de Kalman permettent de réduire le RMSE de plus de 70% en comparaison au modèle de PNT et que les biais finaux se situent entre 0,1 m/s et 0,2 m/s pour ces sites, ce n'est pas suffisant pour surpasser la persistance pour les premières heures d'horizon.

Pour la région **G**, le modèle de PNT rencontre encore une certaine difficulté à prévoir la vitesse du vent. Ici, les filtres de Kalman parviennent tout de même à réduire le biais et le RMSE, mais pas assez pour surpasser le modèle de persistance.

Dans les cas où le modèle physique de départ (PNT) prédit mal les vitesses de vent, une approche purement statistique comme la persistance ou un modèle ARMA pourrait améliorer les prévisions. Cependant, cette dernière option serait uniquement possible dans le cas où un ensemble de données historiques serait disponible, puisque les techniques ARMA nécessitent une calibration préalablement à leur application.

## Performance en fonction de l'horizon

Les Figures 4.14, 4.15(a) et 4.15(b) présentent les biais, MAE et RMSE moyens pour tous les sites en fonction de l'horizon pour l'approche de combinaison, ainsi que pour les modèles précédents.

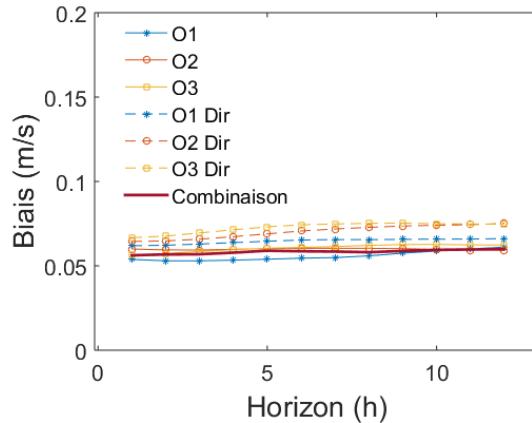
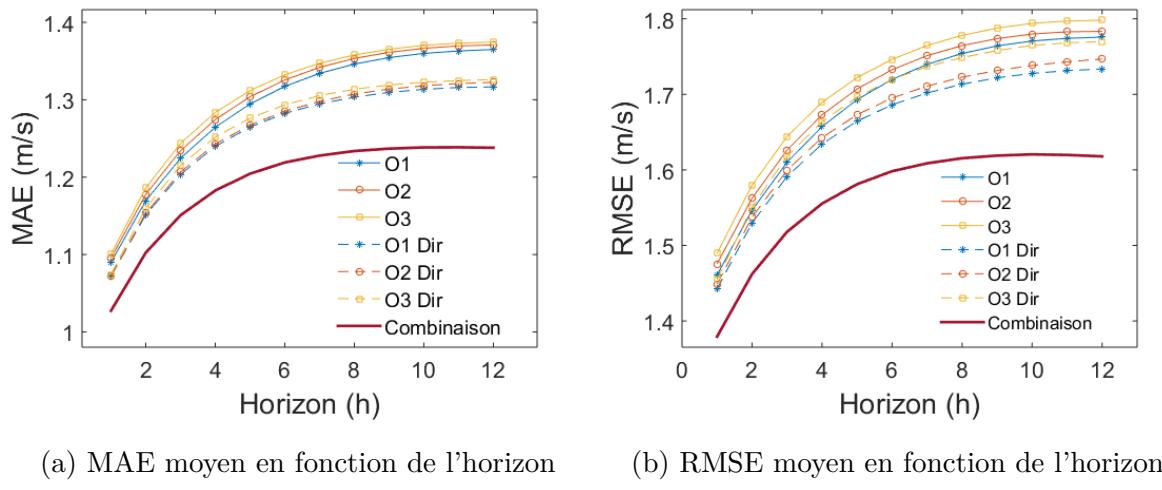


Figure 4.14 Biais moyen en fonction de l'horizon pour la combinaison

D'abord, on remarque que les prévisions obtenues par la méthode de combinaison conservent un biais très faible, réduit à des valeurs très près de 0 pour tous les horizons. Le RMSE et le MAE, quant à eux, sont nettement réduits, et ce, pour tous les horizons de prévision étudiés.



(a) MAE moyen en fonction de l'horizon

(b) RMSE moyen en fonction de l'horizon

Figure 4.15 MAE et RMSE en fonction de l'horizon

La Figure 4.16 montre les améliorations par rapport au modèle de PNT d'Environnement Canada. L'approche de combinaison permet d'améliorer nettement les MAE et RMSE pour tous les horizons, même comparativement au meilleur modèle individuel. Pour  $h=1$ , elle

permet d'atteindre plus de 52% d'amélioration en moyenne pour le MAE, et plus de 47% pour le RMSE, comparativement à 47% et 44% respectivement pour les modèles individuels.

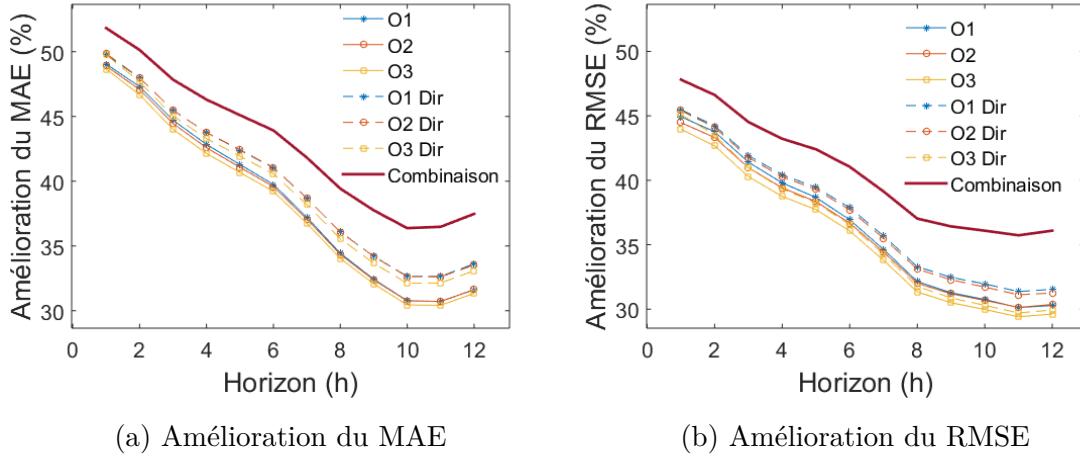


Figure 4.16 Amélioration de la combinaison par rapport aux PNTs

La proportion d'erreurs inférieures à  $\pm 1$  m/s et  $\pm 4$  m/s (en %) sont données aux Figures 4.17(a) et 4.17(b). On remarque que la combinaison des modèles augmente nettement la fréquence des erreurs comprises dans ces intervalles. Cela signifie qu'en moyenne, les distributions d'erreurs sont encore plus étroites et moins évasées lorsque la combinaison est appliquée.

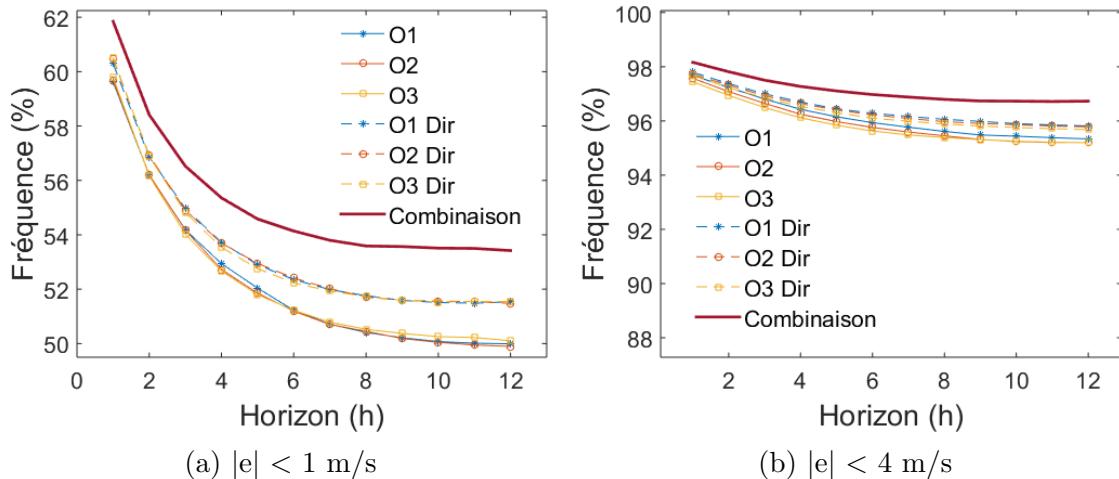


Figure 4.17 Distributions des erreurs sur la vitesse

La réduction significative des MAE et RMSE peut être expliquée par la réduction du nombre d'instabilités (voir la Figure 4.19). En effet, il est possible de voir à la Figure 4.19 que

la combinaison permet d'éviter les instabilités dues aux filtres directionnels. L'ajout de la combinaison semble aussi avoir un certain effet de *lissage* sur les prévisions.

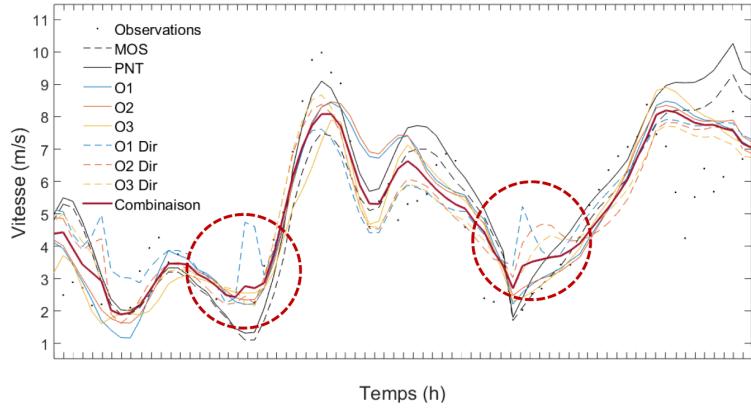


Figure 4.18 Réduction des instabilités

À la Figure 4.19, la combinaison permet à l'opposé de détecter les subtilités associées à la direction du vent. D'autres exemples sont disponibles à l'annexe D.

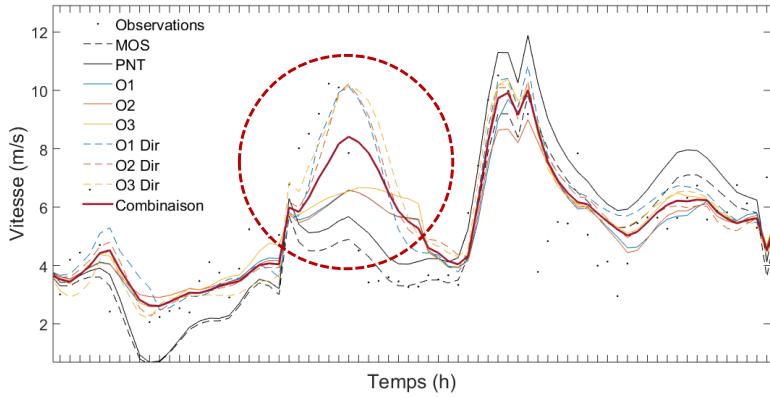


Figure 4.19 Réduction des instabilités

Somme toute, pour la majorité des sites étudiés, le modèle hybride FK-FK( $\theta$ )-Combinaison améliore nettement la précision des prévisions comparativement au modèle de prévision numérique du temps. L'ajout de la direction dans les modèles s'est montré avantageux, et les modèles d'ordre 1 performent mieux de façon globale. Néanmoins, comme la performance des modèles est très dépendante des sites étudiés, conserver les six modèles pour l'étape de combinaison permet d'adapter le choix des modèles en temps réel, selon leurs performances récentes. Ainsi, la prévision finale parvient à détecter certaines subtilités dues à la direction du vent, tout en réduisant les instabilités des filtres directionnels.

## CHAPITRE 5 PRÉVISION DE LA PUISSANCE

Dans ce chapitre, la performance des modèles développés pour la prévision de la puissance produite par les éoliennes est étudiée. Les trois approches résumées à la section 3.3.3 sont analysées (elles sont résumées au tableau 5.1 ci-dessous).

Tableau 5.1 Résumé des approches appliquées à la puissance

<b>Approche A1</b>	1. Vitesse ( <b>v</b> ) prédite corrigée par FK 2. Conversion en puissance ( <b>p</b> ) par la courbe de puissance (CP)
<b>Approche A2</b>	<b>v non disponible</b> 1. <b>p</b> observée transformée en <b>v</b> observée fictive avec la CP inverse 2. Correction de <b>v</b> fictive avec un FK 3. Conversion de <b>v</b> fictive en <b>p</b> à l'aide de la CP
<b>Approche A3</b>	<b>v non disponible</b> 1. <b>p</b> prédite corrigée par FK

Afin d'alléger le texte, les trois approches sont dénotées **A1**, **A2** et **A3** dans les prochaines sections.

Tout d'abord, la performance du premier modèle étudié dans le chapitre précédent est analysée. Pour ce faire, les vitesses de vent corrigées par le filtre de Kalman sont converties en prévision de puissance grâce à la courbe de puissance (approche **A1**). Par la suite, les deux modèles développés pour la correction de la puissance décrits aux sections 2.4.1 et 2.4.2 sont étudiés (**A2** et **A3**). Ces deux approches permettent de corriger la prévision lorsqu'aucune donnée de vent observée n'est disponible, d'une part par l'utilisation de la courbe de puissance inversée, et de l'autre par l'application des filtres directement sur la puissance. Les trois approches seront d'abord évaluées individuellement, puis comparées entre elles. Il est à noter que les sites #4, #5 et #13 ne sont pas étudiés dans cette section, puisque les données de puissance observées ne sont pas disponibles pour ces sites (tel que mentionné au tableau 4.1 du chapitre 4).

Comme il a été mentionné à la section 2.5, les indicateurs (ME, MAE, RMSE) associés à la puissance sont calculés en pourcentage de la puissance nominale du parc ( $\%P_{nom}$ ), tel que défini à l'équation (2.9). Cette manière de calculer les indicateurs permet d'obtenir des valeurs d'erreurs normalisées, ce qui rend possible la comparaison des indicateurs entre des parcs de puissances installées différentes.

## 5.1 Approche A1 - Filtre de Kalman sur la vitesse

Dans cette première section, les vitesses de vent corrigées par les modèles étudiés au chapitre précédent sont converties en prévision de puissance à l'aide de la courbe de puissance (CP). Autrement dit, aucun nouveau modèle n'est implémenté pour cette première approche : il s'agit d'étudier les performances des modèles appliqués à la vitesse lorsque celles-ci sont transformées en puissance. Les résultats pourront servir de comparaison aux approches **A2** et **A3**.

### 5.1.1 Conversion de la vitesse du vent en puissance

Les courbes de puissance fournies par WPred pour cette analyse sont sous forme de tables : la puissance associée à chaque vitesse de vent est donnée, avec une résolution de 0,5 m/s (voir la Figure 5.1(a)). L'interpolation linéaire est utilisée pour déterminer les valeurs entre les points connus.

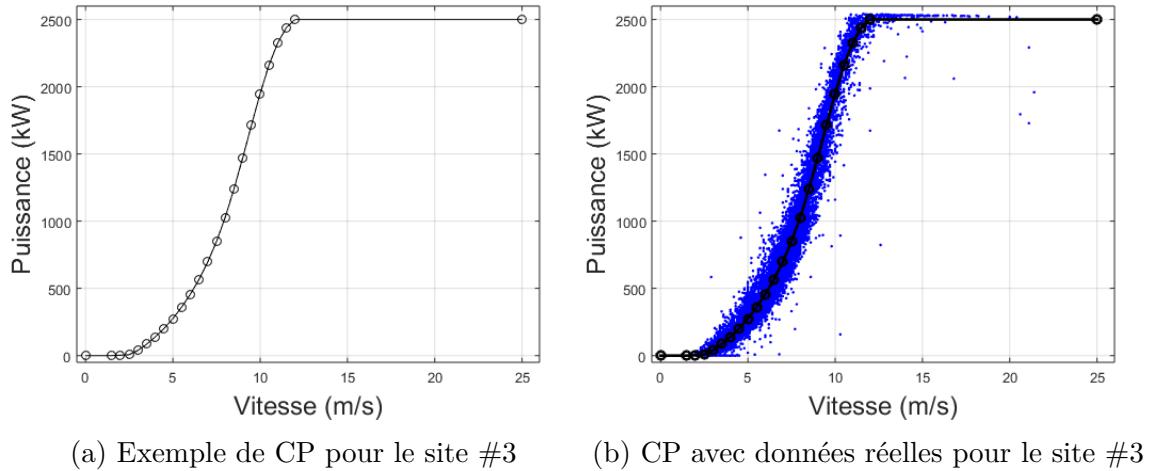


Figure 5.1 Courbes de puissance (CP)

En réalité, les mesures ne suivent pas exactement la courbe de puissance : plusieurs facteurs environnementaux, mécaniques, et géométriques (par exemple l'effet de sillage) entrent en jeu lors de la conversion de la vitesse du vent en puissance générée. Par ailleurs, la puissance est mesurée au niveau du parc entier et non individuellement pour chaque turbine, ce qui implique une courbe de puissance moyenne moins précise. Une relation unique sous la forme  $p = f(v)$  n'est donc pas exacte. Dans la Figure 5.1(b), on peut voir un exemple de données réelles superposées à la courbe de puissance du site #3 à titre d'exemple (les données observées sont tracées en bleu). Ainsi, une certaine erreur peut être introduite lors de la conversion des vitesses de vent en puissance.

### 5.1.2 Analyse des résultats

Pour cette approche, on s'attend à ce que les performances relatives des six modèles développés soient similaires à celles de la vitesse étudiée au chapitre précédent, puisque la conversion en puissance est la seule transformation appliquée aux données. Les indicateurs de performance (en pourcentage de puissance nominale) pour cette première approche sont fournis aux tableaux 5.2, 5.3 et 5.4. Dans ces tableaux, l'amélioration par rapport aux PNTs est également donnée, telle que décrite à l'équation (2.12).

Tableau 5.2 A1 - ME sur la puissance, moyenne de h=1 à h=6\*

# Site	PNT (%P <sub>nom</sub> )	Ordre 1		Ordre 2		Ordre 3	
		Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )	Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )	Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )
1	0,70	<b>-0,73</b>	<b>-0,73</b>	-0,90	-0,79	-0,97	-0,89
2	3,46	-0,34	-0,25	-0,56	-0,36	-0,37	<b>-0,21</b>
3	23,13	-1,05	-0,84	-0,89	-0,74	-0,87	<b>-0,55</b>
6	18,88	-0,39	<b>0,01</b>	-0,54	-0,06	-0,42	0,02
7	10,78	-0,95	-0,70	<b>-0,39</b>	-0,49	-0,90	-0,42
8	10,81	-2,25	-1,79	-1,99	<b>-1,60</b>	-2,14	-1,82
9	13,18	-0,47	-0,52	-0,52	<b>-0,31</b>	-0,42	-0,40
10	21,92	-0,51	<b>-0,46</b>	-0,49	-0,75	-0,61	-0,73
11	13,03	<b>-0,28</b>	-0,42	-0,34	-0,55	-0,32	-0,62
12	12,02	-0,75	-0,74	-0,91	<b>-0,66</b>	-0,71	<b>-0,70</b>
14	13,21	<b>-0,74</b>	-0,79	-0,87	-1,21	-1,05	-1,08
15	15,48	-0,56	<b>-0,49</b>	-0,51	-0,67	-0,61	-0,71
16	17,10	-0,29	0,06	-0,29	-0,08	-0,18	<b>-0,04</b>
17	18,34	-1,51	<b>-1,21</b>	-1,48	-1,88	-1,83	-1,88
18	9,47	-1,45	<b>-1,37</b>	-2,19	-2,08	-2,18	-2,03
19	8,08	-1,57	-1,57	<b>-1,49</b>	-2,14	-1,55	-1,98
20	-21,56	-1,75	<b>-1,74</b>	-2,23	-1,87	-2,22	-2,59
<b>Biais moyen</b>		<b>0,9</b>	<b>0,8</b>	<b>1,0</b>	<b>1,0</b>	<b>1,0</b>	<b>1,0</b>

\*Plus le biais moyen est **faible**, meilleures sont les prévisions. Les erreurs minimales pour chacun des sites sont en gras.

Tableau 5.3 A1 - MAE sur la puissance, moyenne de h=1 à h=6\*

# Site	PNT (%P <sub>nom</sub> )	Ordre 1		Ordre 2		Ordre 3	
		Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )	Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )	Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )
1	9,23	8,93	<b>8,82</b>	8,92	<b>8,82</b>	8,96	8,87
2	9,53	8,87	<b>8,82</b>	8,96	8,91	9,05	<b>8,97</b>
3	26,59	10,98	<b>10,66</b>	10,92	10,71	11,01	10,72
6	20,50	9,29	9,33	<b>9,27</b>	9,35	9,30	9,38
7	19,88	12,87	<b>12,50</b>	12,88	12,54	12,79	12,53
8	20,20	12,44	11,94	12,39	<b>11,93</b>	12,49	12,17
9	15,07	6,81	<b>6,68</b>	6,81	6,70	6,87	6,84
10	22,97	7,90	7,79	7,84	<b>7,65</b>	7,88	7,79
11	15,67	7,70	<b>7,64</b>	7,72	7,70	7,75	7,76
12	15,60	8,03	8,08	<b>8,01</b>	8,04	8,14	8,11
14	16,23	8,34	<b>8,28</b>	8,40	8,29	8,43	8,31
15	17,80	7,56	7,44	7,68	<b>7,40</b>	7,72	7,58
16	18,76	7,92	7,81	7,81	<b>7,73</b>	7,88	7,83
17	27,33	18,77	<b>17,55</b>	19,07	18,11	19,31	17,82
18	20,75	17,69	<b>16,88</b>	17,91	17,26	18,29	17,08
19	13,23	11,97	11,96	12,10	12,09	12,21	<b>11,91</b>
20	23,02	14,36	<b>13,84</b>	14,45	13,91	14,48	14,01
<b>Amélioration moyenne</b>		<b>39,6%</b>	<b>40,8%</b>	<b>39,4%</b>	<b>40,5%</b>	<b>38,9%</b>	<b>40,3%</b>

\*Plus l'amélioration est **élevée**, meilleures sont les prévisions. Les erreurs minimales pour chacun des sites sont en gras.

Tableau 5.4 **A1** - RMSE sur la puissance, moyenne de h=1 à h=6\*

#	PNT (%P <sub>nom</sub> )	Ordre 1		Ordre 2		Ordre 3	
		Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )	Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )	Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )
1	13,44	13,04	<b>12,89</b>	13,01	<b>12,89</b>	13,16	13,03
2	14,94	13,26	<b>13,14</b>	13,40	13,49	13,55	13,56
3	35,54	16,00	<b>15,58</b>	15,96	15,65	16,07	15,64
6	27,28	13,95	13,96	<b>13,94</b>	13,98	14,09	14,11
7	26,84	18,78	<b>18,27</b>	18,83	18,32	18,62	18,42
8	26,64	17,94	17,26	17,83	<b>17,14</b>	18,01	17,56
9	20,05	10,25	<b>10,05</b>	10,25	10,13	10,42	10,36
10	30,21	11,94	11,88	11,80	<b>11,70</b>	11,84	12,10
11	20,41	11,28	<b>11,24</b>	11,27	11,36	11,36	11,50
12	20,72	<b>11,70</b>	11,94	11,80	11,94	11,93	12,15
14	22,95	13,16	<b>13,14</b>	13,23	13,27	13,27	13,30
15	24,08	10,96	<b>10,77</b>	11,16	10,82	11,28	11,21
16	24,12	11,49	11,40	11,36	<b>11,31</b>	11,51	11,53
17	35,83	26,81	<b>25,19</b>	27,31	26,16	27,54	25,60
18	28,04	25,08	<b>24,25</b>	25,58	24,79	26,05	24,64
19	18,93	17,49	17,43	17,67	17,70	17,69	<b>17,37</b>
20	30,11	20,17	<b>19,54</b>	20,16	19,66	20,12	19,75
<b>Amélioration moyenne</b>		<b>35,5%</b>	<b>36,6%</b>	<b>35,2%</b>	<b>36,0%</b>	<b>34,7%</b>	<b>35,6%</b>

\*Plus l'amélioration est élevée, meilleures sont les prévisions. Les erreurs minimales pour chacun des sites sont en gras.

**Biais** Ici aussi, le biais (ME) est significativement amélioré pour les 6 premières heures d'horizon. Il est réduit à environ 1% de la puissance nominale et ce, pour les six modèles de filtre de Kalman, comparativement à 13,6% en moyenne pour le modèle de prévision numérique du temps. Pour donner une idée de l'amélioration en valeur absolue, supposons un parc puissance nominale de 20 MW ; le biais moyen des PNTs serait donc équivalent à environ 2,7 MW, alors qu'il est réduit à 0,2 MW pour les modèles de filtre de Kalman.

**MAE et RMSE** Les modèles développés permettent en moyenne de réduire le MAE entre 38,9% et 40,8%, et le RMSE entre 34,7% et 36,6% comparativement au modèle de PNT. Les filtres directionnels réduisent les erreurs des filtres non directionnels du même ordre, et les modèles d'ordres plus élevés augmentent les erreurs de prévision, comme démontré au chapitre précédent pour la vitesse.

**Distribution des erreurs** Afin de représenter ces erreurs de façon plus visuelle, les distributions d'erreurs pour les horizons  $h = 1$  et  $h = 6$  sont données aux Figures 5.2(a) et 5.2(b) pour le site #20 à titre d'exemple. Les distributions des données filtrées sont encore une fois nettement plus centrées, symétriques et étroites que pour les prévisions brutes des PNTs. Dans la prochaine section, la différence entre les distributions des différents modèles de filtres de Kalman est étudiée plus en détail.

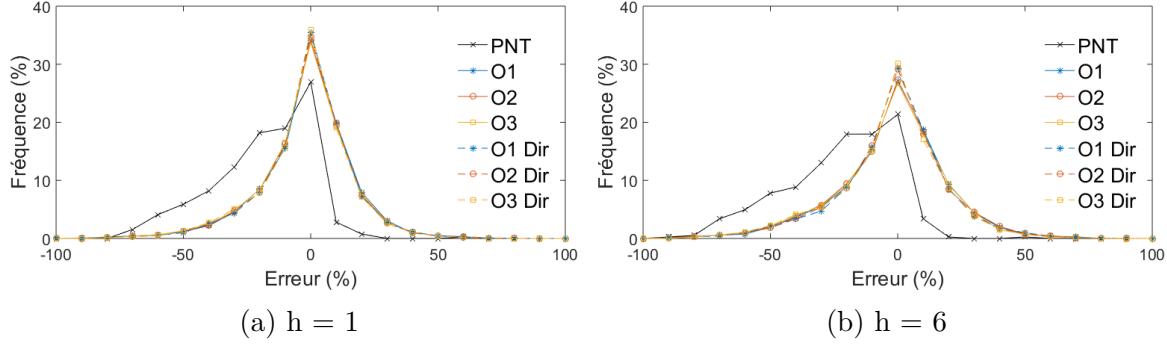


Figure 5.2 A1 - Distribution des erreurs sur la puissance pour le site #20

### 5.1.3 Performance en fonction de l'horizon et combinaison des modèles

Les résultats des six modèles ainsi que de leur combinaison sont présentés dans cette section de la même manière que pour les prévisions de vitesse au chapitre précédent. L'évolution des ME, MAE et RMSE en fonction de l'horizon de prévision, sous forme de moyenne sur tous les sites étudiés, est donnée aux Figures 5.3, 5.4(a) et 5.4(b). Il est à noter que la moyenne du biais pour tous les sites correspond à une moyenne de leur valeur absolue, ce qui est plus représentatif de la performance globale des modèles. Encore une fois, dans ce chapitre, l'échelle des figures présentant le biais est légèrement augmentée par rapport à celles des MAE et RMSE afin de mieux discerner les différentes courbes.

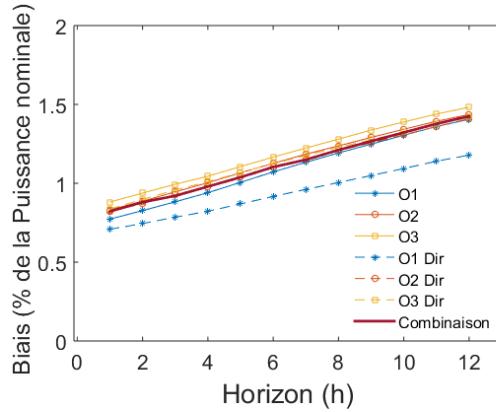


Figure 5.3 A1 - Biais (ME) moyen en fonction de l'horizon

Le biais est réduit de façon similaire pour tous les modèles, soit aux environs de 1% sur tous les horizons. Puisque la méthode de combinaison est conçue pour réduire l'erreur au carré, elle ne parvient pas à réduire le biais de façon optimale (voir la Figure 5.3), mais demeure néanmoins à des valeurs très faibles.

Au niveau des MAE et RMSE, il est possible de constater à la Figure 5.4(a) une division nette entre les MAE des modèles directionnels et non directionnels. Cette division est également

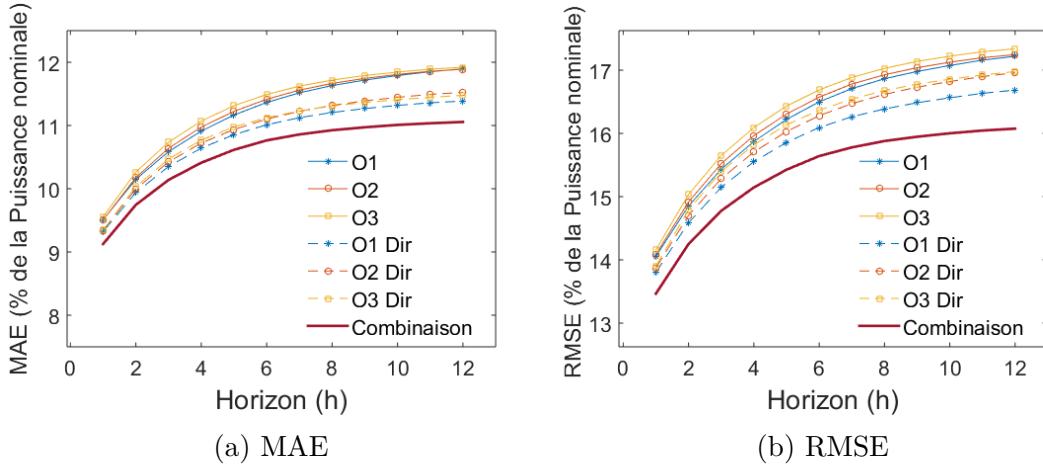


Figure 5.4 A1 - MAE et RMSE moyens en fonction de l'horizon

présente pour le RMSE, quoique légèrement moins définie. Ces résultats permettent d'abord d'affirmer que, de la même manière qu'au chapitre précédent, les ordres inférieurs performent mieux en moyenne. Mais encore, l'ajout de la direction dans les modèles se montre avantageux pour tous les horizons étudiés. Par ailleurs, lorsque la combinaison est appliquée sur ces modèles, les MAE et RMSE moyens sont réduits de façon significative comparativement au meilleur modèle.

À  $h = 1$ , l'amélioration comparativement au modèle de PNT vaut approximativement 45% pour le MAE, et 40% pour le RMSE. Lorsque la combinaison est appliquée, elles augmentent à environ 47% et 43% respectivement (voir les Figures 5.5(a) et 5.5(b)).

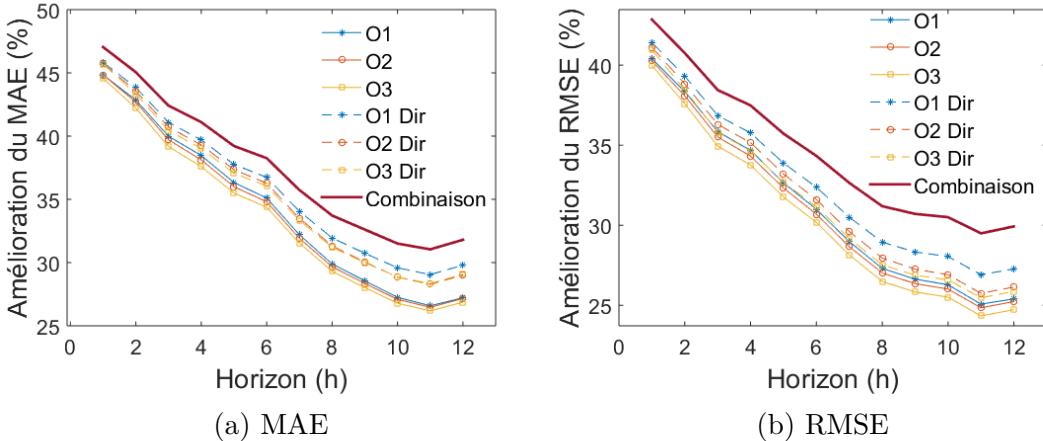
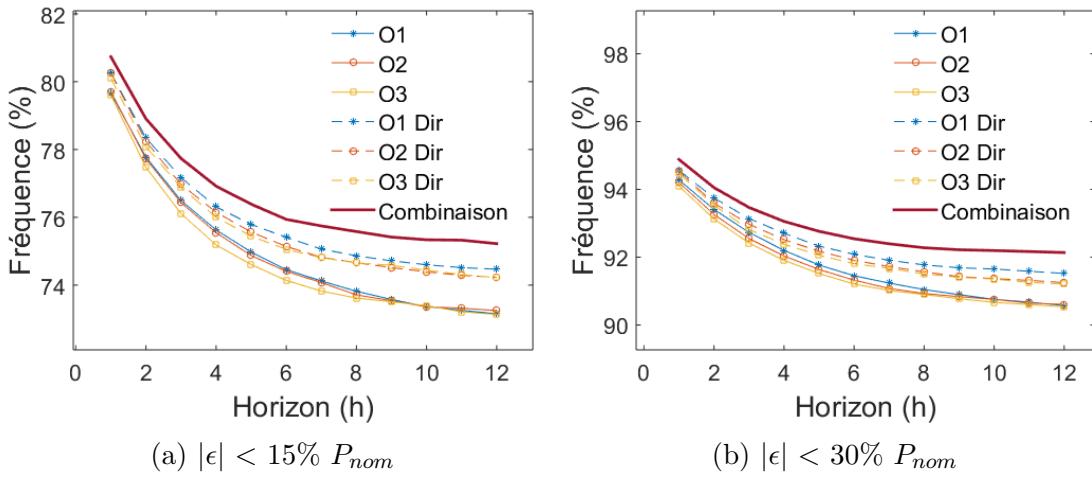


Figure 5.5 A1 - Amélioration des MAE et RMSE moyens en fonction de l'horizon

Afin d'étudier la distribution des erreurs de façon globale, des marges de 15% et de 30% de la puissance nominale sont définies, et les proportions (ou fréquence) des erreurs contenues

à l'intérieur de ces marges sont données aux Figures 5.6(a) et 5.6(b). Les erreurs supérieures à 30% de  $P_{nom}$  sont donc considérées anormalement élevées. On remarque que pour tous les modèles directionnels, ces fréquences sont plus élevées : en d'autres termes, la partie centrale de leurs distributions d'erreurs est en moyenne plus haute, plus étroite et moins évasée que pour les modèles non directionnels. En ce qui regarde la combinaison, elle permet encore une fois d'augmenter la proportion d'erreurs contenue dans ces marges comparativement aux six modèles étudiés.



Similairement au chapitre précédent, il est difficile d'identifier un seul modèle surpassant absolument les autres pour tous les sites étudiés, pour tous les horizons et tous les moments de l'année. Comme le démontrent les tableaux 5.2, 5.3 et 5.4, les meilleurs résultats ne sont pas à tous coups obtenus par le modèle d'ordre 1 directionnel, bien qu'il soit plus précis en moyenne, ce qui confirme l'importance de la combinaison des modèles. Les résultats numériques de cette combinaison sont présentés au tableau 5.5, sous forme d'amélioration du RMSE.

L'amélioration du RMSE par rapport aux PNTs passe de 36,6% en moyenne pour le meilleur modèle (voir le tableau 5.4), à 38,3% lorsque la combinaison est appliquée. Le RMSE est réduit en moyenne de 16,1% par rapport au modèle MOS et de 7,4% comparativement à la persistance. En général, la persistance prédit très bien le vent pour les horizons de 6 heures et moins : il s'agit donc d'un modèle de référence approprié pour évaluer nos résultats et éventuellement les comparer à d'autres études [59]. Il est aussi possible de remarquer que pour les sites #1 et #2, l'approche proposée ne permet pas de réduire significativement le RMSE comparativement au MOS. Pour ces deux sites, le modèle MOS performe à la base très bien, il est donc difficile de le surpasser.

Tableau 5.5 **A1** - Amélioration du RMSE sur la puissance (avec combinaison), moyenne de  $h=1$  à  $h=6^*$

#	Amélioration par rapport à				
	PNT (%)	MOS (%)	persistance (%)	pire modèle (%)	meilleur modèle (%)
1	7,74	0,87	14,75	5,83	3,84
2	14,42	-3,56	13,69	6,06	3,03
3	57,21	37,81	10,77	5,50	2,53
6	49,88	10,86	15,32	3,25	2,07
7	29,94	20,19	4,62	0,25	-2,76
8	32,58	15,35	6,21	0,38	-4,67
9	50,86	20,63	17,22	5,44	1,90
10	62,34	28,77	20,01	6,07	2,84
11	46,82	22,85	14,86	5,63	3,45
12	45,06	9,50	9,47	6,27	2,71
14	42,53	8,91	3,80	1,10	-0,12
15	55,80	23,40	19,57	5,64	1,14
16	54,56	7,43	14,94	4,96	3,04
17	32,21	15,89	-27,47	11,78	3,56
18	17,57	12,31	-15,34	11,25	4,64
19	11,89	12,04	5,18	5,94	4,16
20	39,03	30,67	-2,55	9,01	6,09
<b>Moyenne</b>	<b>38,3%</b>	<b>16,1%</b>	<b>7,4%</b>	<b>5,5%</b>	<b>2,2%</b>

\*Plus l'amélioration est élevée, meilleures sont les prévisions.

Bien que l'approche de combinaison améliore les résultats en général (soit de 2,2% en moyenne par rapport au meilleur modèle), il est possible de remarquer que dans certains cas individuels, elle ne permet pas de surpasser le meilleur modèle. Supposons un couple d'observations vitesse-puissance éloigné de la courbe de puissance, en raison de facteurs environnementaux ou mécaniques quelconques. L'approche de combinaison peut déterminer un modèle  $X$  comme le pire modèle pour le temps  $t$ , puisque la puissance mesurée est éloignée de la puissance prévue. En revanche, la vitesse prédite par ce modèle  $X$ , quant à elle, pourrait être très près de sa vraie valeur. À ce moment, comme la combinaison pondère les modèles selon leur performance récente au niveau de la *puissance* produite, elle aura tendance à donner un poids très faible au modèle  $X$ , alors que la prévision de vitesse était très précise. La combinaison n'atteint donc pas des résultats optimaux, puisqu'il y a une étape de conversion (par la courbe de puissance) entre les sorties du modèle et les données utilisées pour la combinaison.

La Figure 5.7 présente un exemple de comportement des six modèles développés et de leur combinaison, comparativement aux modèles MOS et de PNT, pour  $h = 1$ . En somme, les résultats obtenus par cette première approche sont très similaires à ceux obtenus pour les vitesses de vent au chapitre précédent puisque, comme mentionné plus tôt, ce sont les données de vitesse du vent issues des modèles présentés au chapitre 4 qui sont utilisées pour calculer la puissance prédite.

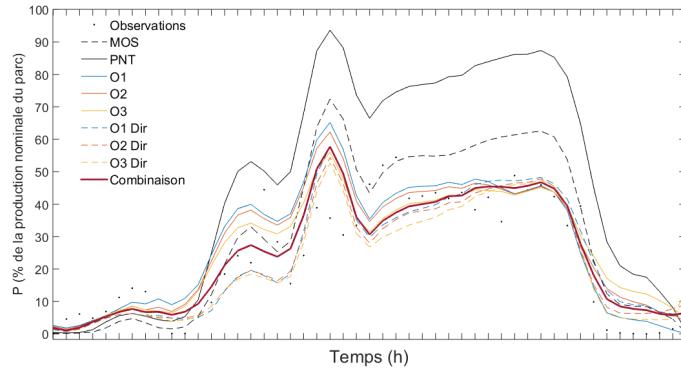


Figure 5.7 A1 - Puissance en fonction du temps pour le site #15 ( $h = 1$ )

## 5.2 Approche A2 - Inversion de la courbe de puissance

Comme certains sites ne fournissent pas les données de vent en temps réel, il est possible que seules les données de puissance soient disponibles pour corriger les prévisions. Ainsi, cette section explore une nouvelle méthode de correction de la puissance sans données de vent, et l'approche A1 présentée à la section précédente pourra servir de méthode de référence.

Dans un article publié en 2014, Messner introduit une méthode permettant de convertir les données de puissance en vitesses de vent *fictives* afin de modéliser les courbes de puissance de façon linéaire [52]. Dans cette section, il est question d'étudier une nouvelle approche, selon laquelle la méthode de Messner est appliquée dans l'objectif de corriger les prévisions de puissance.

### 5.2.1 Conversion de puissances en vitesses de vent

Pour l'approche A2, des observations de vitesses de vent fictives sont générées à partir des observations de puissance. Cela permet de simuler des mesures de vitesse, afin d'appliquer un filtre de Kalman sur la vitesse de la même façon qu'au chapitre 4. Puis, une fois la prévision de vent calibrée, cette dernière est retransformée en prévision de puissance à l'aide de la courbe de puissance. Ainsi, le biais mesuré est redéfini comme la différence entre la vitesse de vent prédite par le modèle de prévision numérique du temps et la vitesse fictive, de la façon suivante :

$$\mathbf{y}_t = \hat{\mathbf{v}}_{t|t-1, PNT} - \mathbf{v}^*_t \quad (5.1)$$

où  $\mathbf{v}^*_t$  est la vitesse de vent fictive. Cette méthode est intéressante, puisqu'elle permet d'appliquer le filtre sur un phénomène météorologique directement, soit la vitesse, plutôt que sur

la puissance. Tel que mentionné à la section 2.4.1, l'inversion peut être interprétée selon le système d'équations suivant :

$$\mathbf{v}_t = f^{-1}(\mathbf{p}_t) = \begin{cases} \mathbf{v}_{cut-in}, & \mathbf{v}_t^* \leq \mathbf{v}_{cut-in} \\ \mathbf{v}_t^*, & \mathbf{v}_{cut-in} < \mathbf{v}_t^* < \mathbf{v}_{nom} \\ \mathbf{v}_{nom}, & \mathbf{v}_t^* \geq \mathbf{v}_{nom} \end{cases} \quad (5.2)$$

où les vitesses faibles et élevées sont limitées aux vitesses de *cut-in* et de *cut-out* respectivement.

Les courbes de puissance IEC fournies par WPred sont utilisées pour effectuer la transformation inverse (voir la section 2.3.1), et les données entre les points de la courbe sont déterminées par interpolation linéaire. Pour cette transformation inverse, la densité de l'air n'est pas considérée puisqu'elle n'améliore pas significativement les résultats [52]. Une fois les observations fictives de vitesses de vent calculées, les filtres directionnels et non directionnels d'ordre 1 à 3 sont appliqués de la même manière qu'au chapitre 4.

Il est aussi important de noter que lorsque les vitesses de vent sont très élevées ou très faibles, elles sont limitées aux vitesses de *cut-out* et de *cut-in*, ce qui peut affecter les résultats des filtres de Kalman. Par ailleurs, lorsqu'elles dépassent la vitesse de *cut-out* et que l'éolienne est arrêtée afin d'éviter les dommages potentiels, la puissance enregistrée est égale à zéro. Cela signifie qu'à ce moment, le modèle calcule la vitesse fictive comme  $\mathbf{v}_t^* = \mathbf{v}_{cut-in}$ , bien que la vitesse réelle soit au-delà de la vitesse de *cut-out*.

Ces événements sont toutefois ponctuels et généralement peu fréquents, mais lorsqu'ils se manifestent, peuvent influencer légèrement la performance des modèles. Dans cette étude, comme ces cas sont rares, la précision des modèles n'en est pas significativement affectée. Dans des travaux futurs, il serait intéressant de développer une démarche cherchant à identifier (lorsque la puissance mesurée est nulle) si la vitesse du vent est très élevée ou très faible, sachant la vitesse prédite par le modèle de PNT.

### 5.2.2 Analyse des résultats

Les biais, MAE et RMSE des différents modèles sont rassemblés dans les tableaux 5.6, 5.7 et 5.8 ci-dessous.

**Biais** Le biais est, encore une fois, significativement réduit (aux environs de 1% de la puissance nominale) pour tous les modèles, similairement à l'approche **A1**. Il est possible de remarquer que les biais sont en général négatifs. Cette tendance peut être expliquée par

l'utilisation de courbes de puissance : les CP utilisées ne permettent pas de prédire des valeurs supérieures à la puissance nominale des éoliennes, alors qu'il arrive parfois que les puissances enregistrées par les systèmes SCADA soient légèrement supérieures aux puissances nominales. Cela a donc comme effet de faire tendre le biais vers des valeurs négatives.

Tableau 5.6 **A2** - ME sur la puissance, moyenne de h=1 à h=6\*

# Site	PNT (%P <sub>nom</sub> )	Ordre 1		Ordre 2		Ordre 3	
		Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )	Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )	Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )
1	0,70	-1,15	-0,89	-1,28	<b>-0,85</b>	-1,24	-1,24
2	3,46	-0,36	-0,21	<b>-0,07</b>	-0,10	<b>0,07</b>	0,22
3	22,82	-1,23	-0,96	-0,68	-0,57	<b>-0,48</b>	-0,52
6	18,88	-0,83	-0,46	-0,64	<b>-0,21</b>	-0,72	-0,26
7	10,78	-2,08	-1,96	<b>-1,66</b>	-1,74	-1,94	-1,75
8	10,81	-2,05	-1,48	-1,65	<b>-1,31</b>	-1,86	-1,59
9	13,18	-0,77	-0,63	-0,68	<b>-0,43</b>	-0,76	-0,59
10	21,92	<b>0,00</b>	-0,25	-0,15	-0,44	-0,21	-0,38
11	13,03	-0,49	-0,53	-0,43	<b>-0,39</b>	-0,46	-0,51
12	12,02	-0,62	-0,57	-0,70	<b>-0,43</b>	-0,53	-0,76
14	13,21	<b>-0,92</b>	-1,17	-1,12	-1,18	-1,17	-1,2
15	15,48	-0,8	<b>-0,61</b>	-0,67	<b>-0,61</b>	-0,77	-0,81
16	17,10	-0,36	-0,05	-0,25	0,01	-0,25	<b>0,00</b>
17	18,34	<b>-0,25</b>	-0,42	-1,04	-0,78	-1,00	-1,20
18	9,70	-0,94	<b>0,25</b>	0,59	-0,52	3,04	-1,19
19	8,08	-0,54	-0,61	<b>-0,48</b>	-0,79	-0,62	-0,82
20	-21,56	-1,22	-1,12	-1,05	-1,33	<b>-0,86</b>	-1,61
<b>Biais moyen</b>		<b>0,9</b>	<b>0,7</b>	<b>0,8</b>	<b>0,7</b>	<b>0,9</b>	<b>0,9</b>

\*Plus le biais moyen est **faible**, meilleures sont les prévisions. Les erreurs minimales pour chacun des sites sont en gras.

Tableau 5.7 **A2** - MAE sur la puissance, moyenne de h=1 à h=6\*

# Site	PNT (%P <sub>nom</sub> )	Ordre 1		Ordre 2		Ordre 3	
		Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )	Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )	Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )
1	9,23	8,78	8,77	8,87	8,82	8,90	<b>8,70</b>
2	9,53	8,88	<b>8,85</b>	8,93	8,97	9,00	8,89
3	26,24	10,58	10,40	10,53	<b>10,37</b>	10,74	10,44
6	20,50	<b>9,12</b>	9,25	9,15	9,25	9,17	9,26
7	19,88	12,63	12,29	12,52	12,39	12,45	<b>12,25</b>
8	20,20	12,31	11,82	12,28	<b>11,74</b>	12,16	11,80
9	15,07	<b>6,69</b>	6,71	6,73	6,80	6,73	6,78
10	22,97	7,99	7,75	7,91	<b>7,70</b>	8,05	<b>7,70</b>
11	15,67	7,55	<b>7,48</b>	7,57	7,59	7,55	7,64
12	15,60	8,02	7,96	<b>7,95</b>	7,99	8,08	7,97
14	16,23	8,17	<b>8,11</b>	8,22	8,21	8,23	8,29
15	17,80	7,57	<b>7,38</b>	7,66	7,45	7,66	7,51
16	18,76	7,82	<b>7,75</b>	7,76	7,79	7,86	7,80
17	27,33	18,81	<b>17,73</b>	19,22	17,89	19,32	18,16
18	20,76	17,54	17,25	18,33	17,49	18,84	<b>17,05</b>
19	13,23	11,29	<b>11,11</b>	11,39	11,26	11,59	11,19
20	23,02	13,30	13,85	13,10	13,13	13,18	<b>13,08</b>
<b>Amélioration moyenne</b>		<b>40,7%</b>	<b>41,4%</b>	<b>40,3%</b>	<b>41,2%</b>	<b>39,9%</b>	<b>41,4%</b>

\*Plus l'amélioration est **élevée**, meilleures sont les prévisions. Les erreurs minimales pour chacun des sites sont en gras.

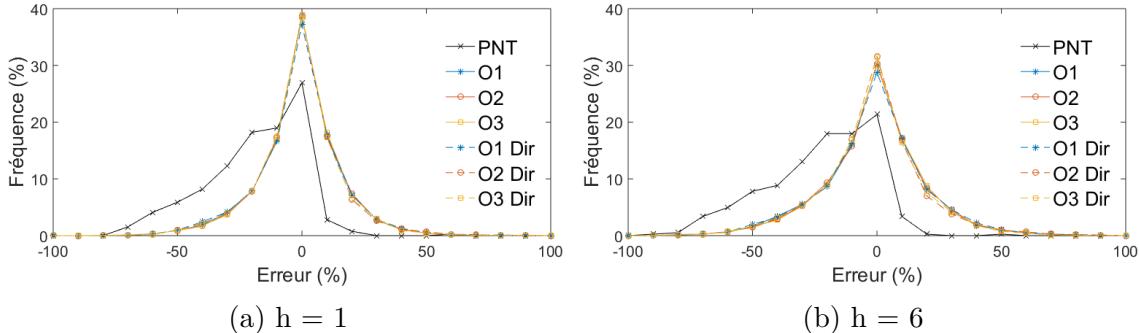
Tableau 5.8 **A2** - RMSE sur la puissance, moyenne de  $h=1$  à  $h=6^*$ 

#	PNT (% $P_{nom}$ )	Ordre 1		Ordre 2		Ordre 3	
		Classique (% $P_{nom}$ )	Avec $\theta$ (% $P_{nom}$ )	Classique (% $P_{nom}$ )	Avec $\theta$ (% $P_{nom}$ )	Classique (% $P_{nom}$ )	Avec $\theta$ (% $P_{nom}$ )
1	13,44	12,84	12,90	12,95	12,92	13,12	<b>12,82</b>
2	14,94	13,41	<b>13,36</b>	13,48	13,67	13,55	13,51
3	35,22	15,57	15,39	15,50	<b>15,38</b>	16,01	15,51
6	27,28	13,79	13,99	<b>13,75</b>	13,91	13,85	13,94
7	26,84	18,37	<b>17,93</b>	18,25	18,20	18,32	18,11
8	26,64	17,72	<b>16,96</b>	17,73	16,97	17,70	17,13
9	20,05	<b>10,11</b>	10,15	10,17	10,31	10,30	10,33
10	30,21	11,97	11,75	11,82	<b>11,55</b>	12,08	11,83
11	20,41	11,13	<b>11,07</b>	11,14	11,16	11,11	11,33
12	20,72	<b>11,65</b>	11,69	11,69	11,79	11,86	11,92
14	22,95	<b>12,70</b>	12,83	12,86	13,02	12,97	13,19
15	24,08	11,03	<b>10,79</b>	11,13	10,91	11,13	11,16
16	24,12	11,42	<b>11,29</b>	11,30	11,44	11,48	11,41
17	35,83	26,87	<b>25,21</b>	27,63	25,72	27,80	26,00
18	28,02	24,72	24,60	26,14	25,06	27,10	<b>24,50</b>
19	18,93	16,75	16,46	16,90	16,70	17,05	<b>16,45</b>
20	30,11	18,71	19,49	<b>18,39</b>	18,76	18,59	18,60
<b>Amélioration moyenne</b>		<b>36,5%</b>	<b>37,1%</b>	<b>36,1%</b>	<b>36,6%</b>	<b>35,3%</b>	<b>36,6%</b>

\*Plus l'amélioration est élevée, meilleures sont les prévisions. Les erreurs minimales pour chacun des sites sont en gras.

**MAE et RMSE** Les autres indicateurs sont réduits comparativement aux PNTs entre 39,9% et 41,4% pour le MAE, et entre 35,3% et 37,1% pour le RMSE. De la même façon que pour l'approche **A1**, on remarque que les modèles directionnels permettent en moyenne de réduire les MAE et RMSE en comparaison aux modèles non directionnels. Encore une fois, les modèles d'ordre 1 ont tendance à présenter des précisions accrues, comparativement aux modèles d'ordres plus élevés. De façon individuelle, il est possible de voir que la majorité des erreurs minimales sont associées aux modèles non directionnels (65% des sites pour le MAE et 76% pour le RMSE). Au niveau de l'ordre des modèles, les MAE et RMSE minimaux sont associés à l'ordre 1 pour plus de 50% des sites.

**Distribution des erreurs** Les distributions d'erreurs présentées aux Figures 5.8(a) et 5.8(b) permettent aussi de conclure que les modèles entraînent une distribution d'erreur plus centrée et étroite.

Figure 5.8 **A2** - Distributions des erreurs sur la puissance pour le site #20

### 5.2.3 Performance en fonction de l'horizon et combinaison des modèles

Comme il a été démontré dans les tableaux ci-dessus, la performance des modèles varie en fonction des sites étudiés. L'étape de combinaison est donc aussi appliquée pour cette approche. Dans la Figure 5.9, on remarque que le biais est toujours considérablement réduit, pour tous les modèles.

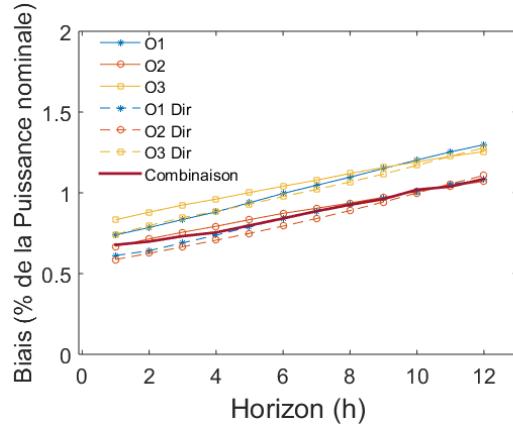


Figure 5.9 **A2** - Biais (ME) moyen en fonction de l'horizon

Comme les modèles appliqués pour cette approche sont les mêmes que ceux appliqués à l'approche **A1**, il n'est pas surprenant de remarquer que les performances relatives des six modèles soient très similaires dans ce cas-ci (voir les Figures 5.10(a) et 5.10(b)). Par ailleurs, il est possible de noter encore une fois que plus l'horizon augmente, plus la différence de performance entre les modèles directionnels et non directionnels augmente.

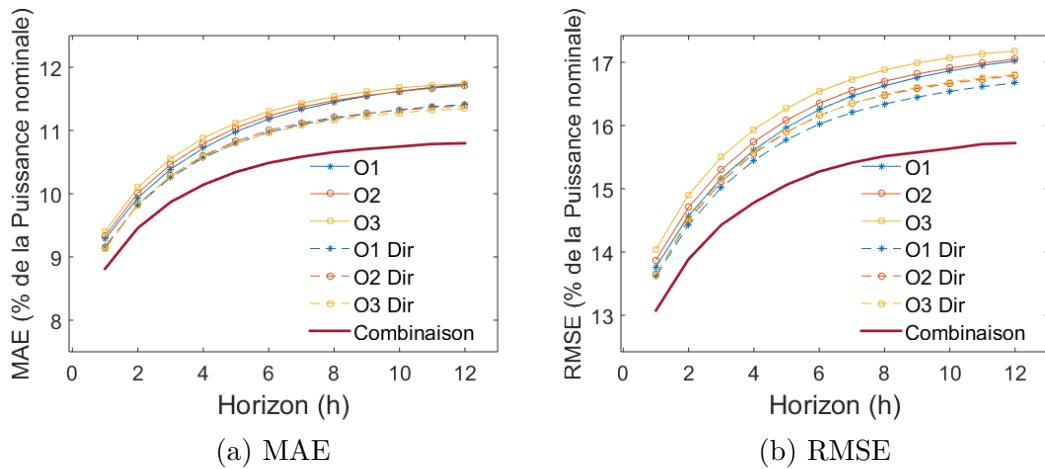


Figure 5.10 **A2** - MAE et RMSE moyens en fonction de l'horizon

L'ajout de la combinaison permet de trouver une solution pour laquelle les MAE et RMSE sont réduits significativement. Son biais moyen est similaire à celui de toutes les approches individuelles, soit environ 1% de la puissance nominale pour les 12 premières heures d'horizon.

Les MAE et RMSE, sous forme d'amélioration par rapport aux PNTs, sont fournis à la Figure 5.11. On remarque que tous les indicateurs sont significativement réduits comparativement au modèle physique. À  $h = 1$  par exemple, le MAE est réduit de plus de 45%, et le RMSE de plus de 40%. La combinaison, quant à elle, permet d'augmenter ces valeurs à environ 49% et 44% respectivement.

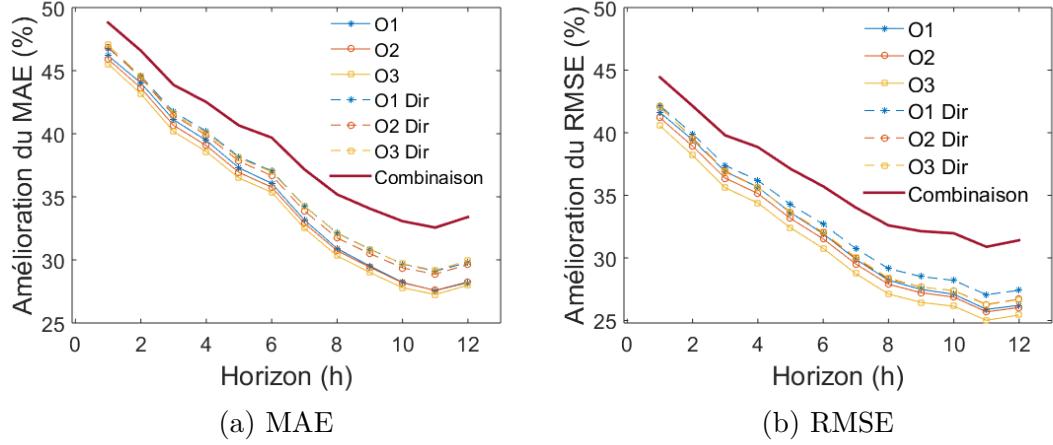


Figure 5.11 A2 - Amélioration des MAE et RMSE moyens en fonction de l'horizon

Aux Figures 5.12(a) et 5.12(b), l'étude des marges d'erreur permet de constater que les modèles directionnels mènent encore une fois à des distributions d'erreurs plus étroites, centrées et moins évasées que les modèles non directionnels. La même tendance peut être observée pour les ordres inférieurs par rapport aux ordres plus élevés, cependant de façon moins significative.

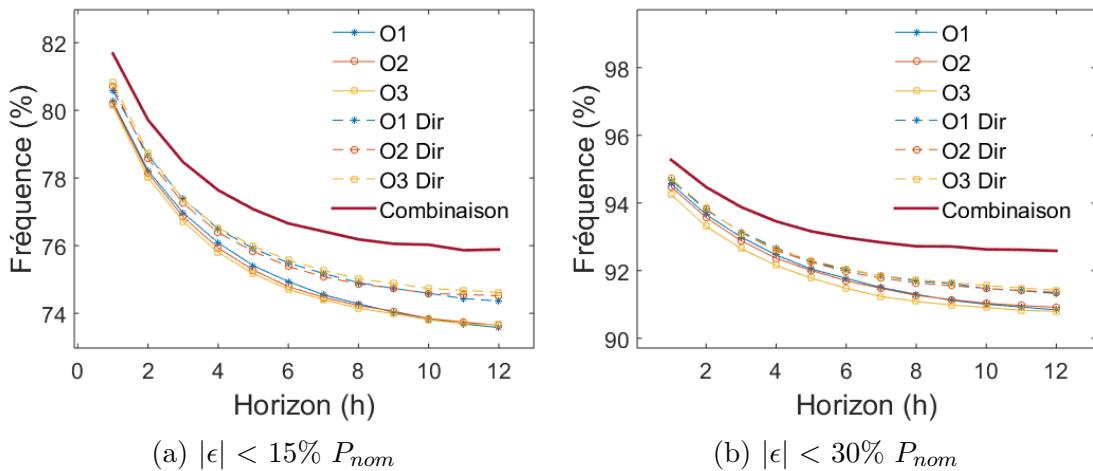


Figure 5.12 A2 - Distributions des erreurs sur la puissance

La combinaison, quant à elle, améliore également la distribution des erreurs comparativement à tous les modèles individuels. Essentiellement, cela indique qu'elle permet de réduire le nombre d'erreurs élevées de façon notable.

Dans le tableau 5.9, les résultats numériques de la combinaison des 6 modèles étudiés dans cette section sont résumés. Le RMSE est réduit de plus de 39% par rapport au modèle de PNT, comparativement à une moyenne d'environ 36% pour le meilleur modèle (voir le tableau 5.8). Par ailleurs, l'étape de combinaison réduit en moyenne le RMSE de 6,9% par rapport au pire modèle ayant pu être choisi pour un site en particulier. De plus, la combinaison permet, pour tous les sites, de réduire le RMSE comparativement au meilleur modèle, soit de 3,3% en moyenne (et jusqu'à 7,1% individuellement). Ces résultats démontrent encore une fois l'avantage d'ajouter l'étape de combinaison.

Tableau 5.9 **A2** - Amélioration du RMSE sur la puissance (avec combinaison), moyenne de  $h=1$  à  $h=6$ \*

#	Amélioration par rapport à				
	PNT (%)	MOS (%)	persistance (%)	pire modèle (%)	meilleur modèle (%)
1	8,27	1,44	15,21	6,09	3,92
2	13,85	-4,26	13,24	6,18	3,98
3	57,62	38,26	11,55	6,93	3,11
6	50,35	11,69	16,16	3,35	1,65
7	34,64	25,55	10,75	4,63	2,30
8	36,65	20,45	11,60	4,89	0,59
9	50,81	20,57	17,27	4,51	2,44
10	62,63	29,31	20,59	6,62	2,35
11	47,71	24,15	16,46	5,74	3,55
12	45,80	10,71	10,82	5,77	3,60
14	45,35	13,37	8,62	5,14	1,47
15	56,08	23,88	20,10	5,24	1,98
16	55,08	8,48	16,06	5,59	4,03
17	32,67	16,46	-26,45	13,19	4,27
18	17,78	12,03	-15,68	14,93	5,91
19	15,93	16,06	9,85	6,88	3,44
20	43,28	35,51	5,10	12,32	7,08
<b>Moyenne</b>	<b>39,7%</b>	<b>17,9%</b>	<b>9,5%</b>	<b>6,9%</b>	<b>3,3%</b>

\*Plus l'amélioration est élevée, meilleures sont les prévisions.

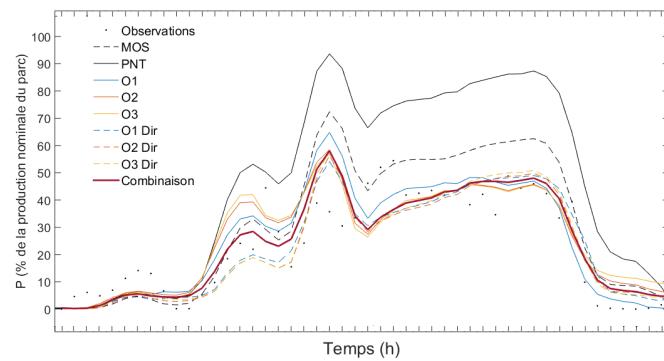


Figure 5.13 **A2** - Puissance en fonction du temps pour le site #15 ( $h = 1$ )

Finalement, la Figure 5.13 présente un exemple d'application des modèles ainsi que de la combinaison, sous forme de puissance en fonction du temps. Il est intéressant de noter que le comportement des différents modèles est très similaire à ceux de l'approche **A1** (voir la Figure 5.7).

En résumé, l'approche développée dans cette section permet d'atteindre des performances comparables à celles de l'approche **A1**, bien qu'aucune mesure de vitesse de vent ne soit disponible. En outre, l'introduction de la direction du vent dans les modèles s'est également montrée avantageuse.

### 5.3 Approche A3 - Filtre de Kalman sur la puissance

Le filtre de Kalman appliqué à la puissance directement n'est étudié que depuis très récemment : à ce jour, un seul article a été publié à ce sujet [15]. Conséquemment, très peu de résultats quantitatifs (ME, MAE, RMSE ou amélioration) sont disponibles. L'objectif de cette étude est donc de présenter des résultats quantitatifs de l'implémentation de ces modèles, ainsi que comparer les différents ordres polynomiaux. Par ailleurs, l'ajout de la direction comme paramètre d'entrée sera également considéré, afin de déterminer s'il permet d'améliorer les modèles appliqués à la puissance.

#### 5.3.1 Méthodologie

Dans le cadre de ce projet, le filtre de Kalman est alors appliqué aux prévisions de puissance. Pour ce faire, le biais sur la puissance est modélisé comme un polynôme d'ordre 1, 2 et 3, sous forme directionnelle ou non directionnelle, de la même manière que pour la vitesse au chapitre précédent (voir les équations 3.31 – 3.36). Ainsi, il est redéfini par l'équation  $\mathbf{y}_t = \hat{\mathbf{p}}_{t|t-1,PNT} - \mathbf{p}_t$ , où  $\hat{\mathbf{p}}_{t|t-1,PNT}$  est la prévision de puissance calculée à partir des prévisions de vent du modèle de PNT, et  $\mathbf{p}_t$  est la puissance mesurée. Les équations polynomiales utilisées pour modéliser le biais non directionnel sont donc données par les équations (5.3), (5.4), (5.5) :

$$y_t = \alpha_{0,t} + \beta_{0,t} \cdot \hat{p}_{t,PNT} + m_t \quad (5.3)$$

$$y_t = \alpha_{0,t} + \beta_{0,t} \cdot \hat{p}_{t,PNT} + \gamma_{0,t} \cdot \hat{p}_{t,PNT}^2 + m_t \quad (5.4)$$

$$y_t = \alpha_{0,t} + \beta_{0,t} \cdot \hat{p}_{t,PNT} + \gamma_{0,t} \cdot \hat{p}_{t,PNT}^2 + \eta_{0,t} \cdot \hat{p}_{t,PNT}^3 + m_t \quad (5.5)$$

et pour les équations directionnelles :

$$y_t = (\alpha_{0,t} + \alpha_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \alpha_{2,t} \cdot \cos \hat{\theta}_{t,PNT}) \\ + (\beta_{0,t} + \beta_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \beta_{2,t} \cdot \cos \hat{\theta}_{t,PNT}) \cdot \hat{p}_{t,PNT} + m_t \quad (5.6)$$

$$y_t = (\alpha_{0,t} + \alpha_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \alpha_{2,t} \cdot \cos \hat{\theta}_{t,PNT}) \\ + (\beta_{0,t} + \beta_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \beta_{2,t} \cdot \cos \hat{\theta}_{t,PNT}) \cdot \hat{p}_{t,PNT} \\ + (\gamma_{0,t} + \gamma_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \gamma_{2,t} \cdot \cos \hat{\theta}_{t,PNT}) \cdot \hat{p}_{t,PNT}^2 + m_t \quad (5.7)$$

$$y_t = (\alpha_{0,t} + \alpha_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \alpha_{2,t} \cdot \cos \hat{\theta}_{t,PNT}) \\ + (\beta_{0,t} + \beta_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \beta_{2,t} \cdot \cos \hat{\theta}_{t,PNT}) \cdot \hat{p}_{t,PNT} \\ + (\gamma_{0,t} + \gamma_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \gamma_{2,t} \cdot \cos \hat{\theta}_{t,PNT}) \cdot \hat{p}_{t,PNT}^2 \\ + (\eta_{0,t} + \eta_{1,t} \cdot \sin \hat{\theta}_{t,PNT} + \eta_{2,t} \cdot \cos \hat{\theta}_{t,PNT}) \cdot \hat{p}_{t,PNT}^3 + m_t \quad (5.8)$$

Le filtre a donc été implémenté de façon très similaire à celui utilisé pour la vitesse du vent (décrit à la section 3.3), en utilisant toutefois les prévisions et observations de puissance en entrée, plutôt que la vitesse du vent. De prime abord, cette approche est intéressante puisqu'elle pourrait permettre de corriger également les incertitudes introduites par la conversion de la vitesse de vent en puissance par l'entremise de la courbe de puissance.

### 5.3.2 Analyse des résultats

Les tableaux 5.10, 5.11 et 5.12 résument les résultats de cette approche.

Tableau 5.10 **A3** - ME sur la puissance, moyenne de h=1 à h=6\*

# Site	PNT (%P <sub>nom</sub> )	Ordre 1		Ordre 2		Ordre 3	
		Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )	Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )	Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )
1	0,70	-1,14	-1,34	-1,14	<b>-1,12</b>	-1,29	-1,37
2	3,46	<b>0,01</b>	-0,60	-0,37	-1,04	-0,80	-1,12
3	22,82	-2,22	-2,43	-1,89	<b>-1,2</b>	-1,45	-2,00
6	18,88	1,91	<b>0,35</b>	2,90	1,84	1,73	0,92
7	10,78	<b>-0,04</b>	<b>-0,04</b>	-0,52	-0,61	-1,45	-1,34
8	10,81	-1,04	-0,80	-1,21	<b>-0,79</b>	-1,75	-1,16
9	13,18	-0,99	-1,05	<b>-0,29</b>	-1,06	-0,80	-0,98
10	21,92	-0,37	-0,25	1,69	0,86	0,82	<b>-0,01</b>
11	13,03	0,79	<b>0,04</b>	0,07	-0,16	-0,90	-1,08
12	12,02	-1,00	-0,70	-0,43	<b>-0,40</b>	-1,19	-0,97
14	13,21	2,70	1,41	1,29	-0,51	<b>-0,06</b>	-0,86
15	15,48	-0,40	-0,58	1,30	-0,66	<b>0,01</b>	-0,50
16	17,10	3,30	1,17	1,47	0,39	-0,11	<b>-0,03</b>
17	18,34	10,41	2,19	4,91	<b>-0,72</b>	2,34	-1,37
18	9,70	<b>-0,14</b>	-2,02	-0,52	-0,48	-2,12	0,53
19	8,08	2,17	2,79	0,92	<b>0,53</b>	-0,84	-0,98
20	-21,56	-5,20	-5,24	-3,67	-3,81	<b>-3,42</b>	-3,44
<b>Biais moyen</b>		<b>2,0</b>	<b>1,4</b>	<b>1,4</b>	<b>1,0</b>	<b>1,2</b>	<b>1,1</b>

\*Plus le biais moyen est **faible**, meilleures sont les prévisions. Les erreurs minimales pour chacun des sites sont en gras.

Tableau 5.11 **A3** - MAE sur la puissance, moyenne de h=1 à h=6\*

# Site	PNT (%P <sub>nom</sub> )	Ordre 1		Ordre 2		Ordre 3	
		Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )	Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )	Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )
1	9,23	9,05	8,99	9,22	9,18	8,89	<b>8,81</b>
2	9,53	9,52	9,24	9,34	<b>9,23</b>	9,31	9,37
3	26,24	<b>12,29</b>	12,53	12,52	12,48	12,87	12,41
6	20,50	11,35	11,20	11,86	11,33	10,79	<b>10,44</b>
7	19,88	13,44	13,57	13,44	13,29	13,03	<b>12,93</b>
8	20,20	13,59	13,72	13,47	13,59	13,01	<b>12,93</b>
9	15,07	7,26	7,21	7,05	7,07	7,00	<b>6,94</b>
10	22,97	9,66	9,82	9,77	9,09	9,41	<b>8,58</b>
11	15,67	8,80	8,57	8,68	8,21	8,34	<b>7,85</b>
12	15,60	8,51	8,75	8,57	8,74	8,30	<b>8,25</b>
14	16,23	10,28	9,63	9,58	8,85	8,81	<b>8,55</b>
15	17,80	8,62	8,48	9,46	8,29	8,64	<b>7,87</b>
16	18,76	10,75	9,64	9,77	8,83	8,56	<b>8,30</b>
17	27,33	23,20	20,01	21,80	<b>19,24</b>	20,96	19,36
18	20,76	17,95	<b>17,49</b>	18,31	17,65	17,90	18,11
19	13,23	12,00	12,70	12,34	11,89	11,93	<b>11,83</b>
20	23,02	13,91	13,58	13,44	<b>13,15</b>	13,31	13,24
<b>Amélioration moyenne</b>		<b>33,6%</b>	<b>34,9%</b>	<b>34,0%</b>	<b>36,5%</b>	<b>36,5%</b>	<b>38,0%</b>

\*Plus l'amélioration est élevée, meilleures sont les prévisions. Les erreurs minimales pour chacun des sites sont en gras.

Tableau 5.12 **A3** - RMSE sur la puissance, moyenne de h=1 à h=6\*

#	PNT (%P <sub>nom</sub> )	Ordre 1		Ordre 2		Ordre 3	
		Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )	Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )	Classique (%P <sub>nom</sub> )	Avec $\theta$ (%P <sub>nom</sub> )
1	13,44	13,48	13,38	13,62	13,59	13,10	<b>13,07</b>
2	14,94	14,84	14,22	14,25	<b>14,08</b>	14,29	14,58
3	35,22	<b>18,42</b>	19,04	18,78	18,86	19,29	18,80
6	27,28	16,79	16,70	17,72	17,03	16,59	<b>16,02</b>
7	26,84	19,31	19,42	19,18	19,09	18,90	<b>18,74</b>
8	26,64	19,32	19,50	19,01	19,14	18,65	<b>18,55</b>
9	20,05	10,99	11,00	<b>10,58</b>	10,75	10,70	10,60
10	30,21	15,33	15,28	15,27	14,27	14,92	<b>13,47</b>
11	20,41	13,06	12,69	12,84	12,12	12,42	<b>11,63</b>
12	20,72	12,72	12,84	12,63	12,90	12,42	<b>12,31</b>
14	22,95	15,67	14,76	15,11	13,91	14,07	<b>13,69</b>
15	24,08	12,74	12,57	13,85	12,18	12,92	<b>11,57</b>
16	24,12	15,37	14,21	14,52	13,22	12,98	<b>12,58</b>
17	35,83	32,06	28,30	31,17	<b>27,66</b>	30,33	28,06
18	28,02	25,03	<b>24,62</b>	25,81	25,18	25,35	26,05
19	18,93	<b>17,62</b>	18,91	18,52	17,80	17,96	17,83
20	30,11	19,71	19,560	19,38	18,92	19,01	<b>18,85</b>
<b>Amélioration moyenne</b>		<b>28,7%</b>	<b>29,8%</b>	<b>28,8%</b>	<b>31,3%</b>	<b>30,8%</b>	<b>32,4%</b>

\*Plus l'amélioration est élevée, meilleures sont les prévisions. Les erreurs minimales pour chacun des sites sont en gras.

**Biais** Le biais associé à cette approche est encore une fois nettement réduit comparativement aux PNTs : il vaut en moyenne entre 1% et 2% pour tous les modèles (voir le tableau 5.10). Il est cependant légèrement supérieur au biais moyen des approches **A1** et **A2**, qui ne dépasse pas 1%.

**MAE et RMSE** Une conclusion majeure pouvant être tirée des tableaux 5.11 et 5.12 est que, contrairement aux approches **A1** et **A2**, le modèle d'ordre 3 permet d'obtenir les meilleures performances. Les erreurs minimales pour les MAE et RMSE sont associées, pour environ 70% des sites, au modèle d'ordre 3 directionnel. Il est possible de constater une corrélation entre l'ordre des modèles et la performance : plus l'ordre est élevé, plus le modèle permet de réduire l'erreur (en moyenne). De plus, l'ajout de la direction permet aussi d'augmenter la précision des modèles pour tous les ordres polynomiaux.

**Distribution des erreurs** Un exemple de distribution des erreurs pour le site #20 est présenté aux Figures 5.14(a) et 5.14(b). On remarque que la distribution est légèrement plus asymétrique que pour les approches **A1** et **A2** (voir les Figures 5.2 et 5.8).

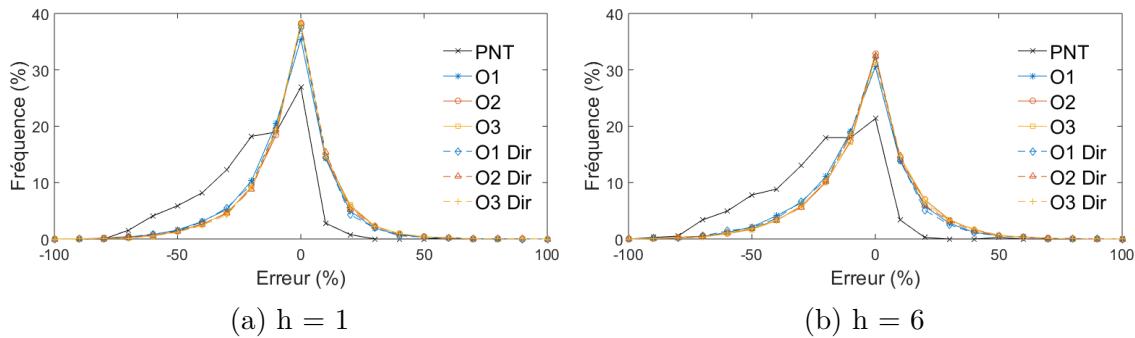


Figure 5.14 **A3** - Distributions des erreurs sur la vitesse pour le site #20

### 5.3.3 Performance en fonction de l'horizon et combinaison des modèles

Les figures suivantes présentent les résultats présentés à la section précédente en fonction de l'horizon de prévision.

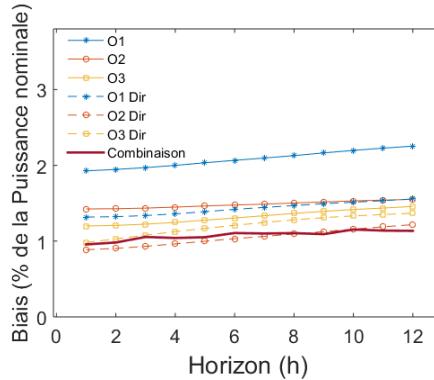


Figure 5.15 **A3** - Biais (ME) moyen en fonction de l'horizon

D'abord, le biais est réduit significativement pour tous les modèles. On remarque toutefois que l'ordre 1 ne parvient pas à modéliser le biais aussi adéquatement que les ordres plus élevés. Au niveau de MAE et RMSE, plus l'ordre augmente, plus ils sont réduits, et ce, pour tous les horizons de prévision étudiés (voir la Figure 5.16). Il en est de même pour l'ajout de la direction dans les modèles : pour tous les ordres, les versions directionnelles des modèles réduisent davantage les erreurs moyennes que les filtres non directionnels du même ordre.

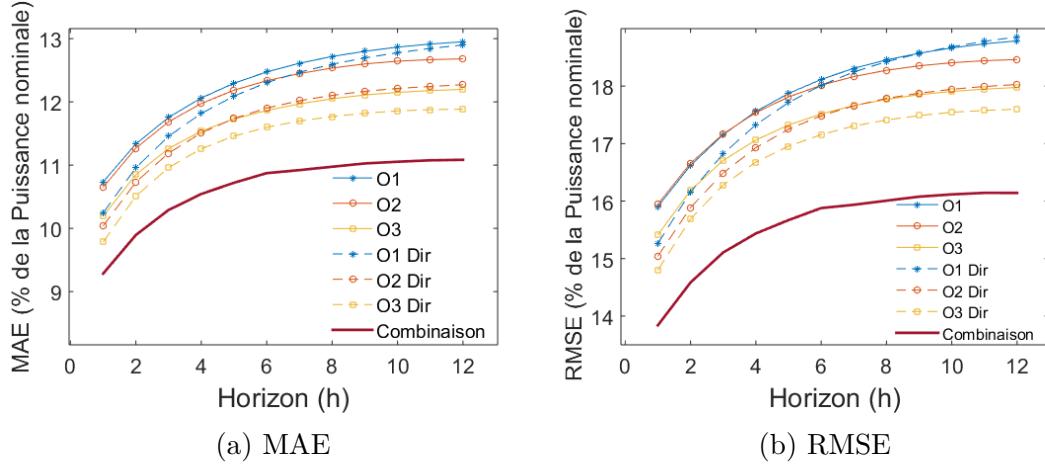
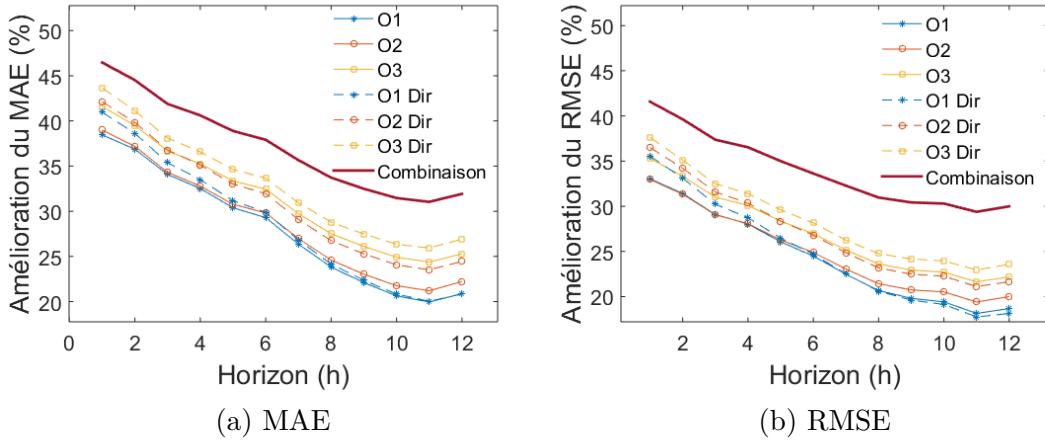


Figure 5.16 A3 - MAE et RMSE moyens en fonction de l'horizon

Ces résultats sont aussi présentés sous forme d'amélioration par rapport aux PNTs à la Figure 5.17. Pour  $h = 1$ , les modèles individuels réduisent les MAE et le RMSE de plus de 33%, alors que la combinaison permet de les réduire d'environ 46% et 42% respectivement.



Les résultats présentés aux Figures 5.18(a) et 5.18(b) ci-dessous démontrent que les distributions d'erreurs sont plus étroites et centrées pour les versions directionnelles des modèles. Cependant, contrairement aux approches précédentes, on n'observe pas de regroupement net entre les différentes approches.

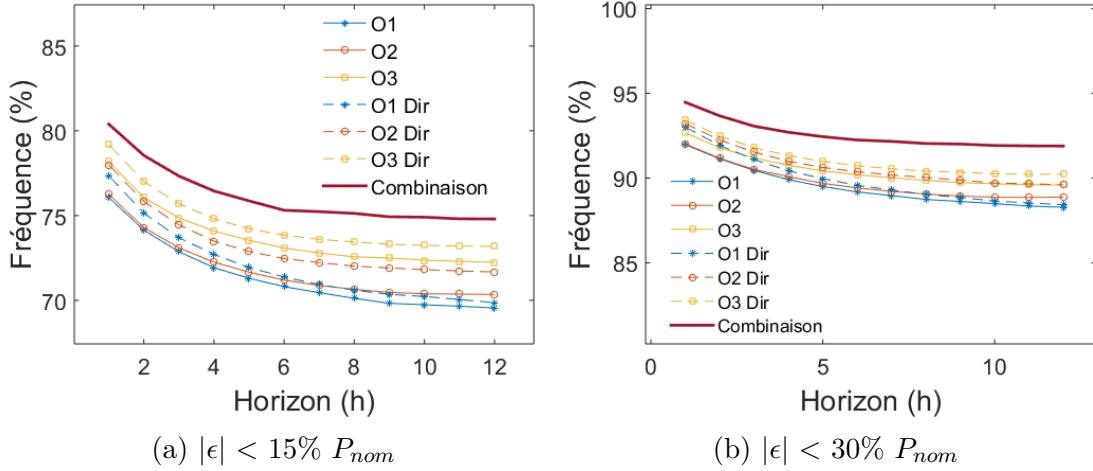


Figure 5.18 A3 - Distributions des erreurs sur la puissance

L'ajout de l'étape de combinaison dans ce cas-ci se montre tout aussi important (voir le tableau 5.13). L'amélioration comparativement aux PNTs atteint 37,3% pour la combinaison, comparativement à 32,4% en moyenne pour le meilleur modèle. Les performances entre les différents modèles varient nettement plus que pour les approches précédentes. En moyenne, l'amélioration comparativement au pire modèle vaut plus de 14%. Encore une fois, la combinaison permet, pour tous les sites étudiés, d'obtenir un RMSE inférieur au meilleur modèle, soit de 6,4% en moyenne.

Tableau 5.13 A3 - Amélioration du RMSE sur la puissance (avec combinaison), moyenne de h=1 à h=6\*

#	Amélioration par rapport à				
	PNT (%)	MOS (%)	persistance (%)	pire modèle (%)	meilleur modèle (%)
1	7,62	0,74	14,62	8,90	5,04
2	11,24	-7,40	10,41	10,94	6,13
3	50,50	27,91	-2,61	9,83	5,58
6	46,54	4,92	9,84	17,82	9,07
7	33,59	24,35	9,07	8,32	5,00
8	34,23	17,41	8,30	10,26	5,67
9	51,50	21,65	18,23	11,55	8,08
10	58,58	21,66	12,03	18,46	7,24
11	46,57	22,50	14,74	16,46	6,19
12	45,47	10,16	10,18	12,42	8,18
14	44,13	11,46	5,63	18,33	6,53
15	54,65	21,40	17,52	21,16	5,63
16	51,11	0,39	8,50	23,24	6,25
17	26,21	8,45	-39,15	17,55	4,42
18	17,08	11,29	-17,38	10,76	5,57
19	13,15	13,29	6,34	13,21	6,85
20	41,80	33,82	2,03	11,15	7,09
<b>Moyenne</b>	<b>37,3%</b>	<b>14,4%</b>	<b>5,2%</b>	<b>14,1%</b>	<b>6,4%</b>

\*Plus l'amélioration est élevée, meilleures sont les prévisions.

Bien que le modèle d'ordre 3 directionnel surpassé en moyenne les autres modèles pour tous les horizons et presque tous les sites, la combinaison améliore les résultats, ce qui suggère que la performance des différents modèles varie en fonction du temps.

Comme il est démontré à la Figure 5.19, les filtres de Kalman appliqués à la puissance sont moins précis que ceux appliqués aux vitesses de vent. Puisque la puissance est proportionnelle à la vitesse au cube (voir l'équation 1.1), la forte variabilité du vent est amplifiée au niveau de la puissance, ce qui rend le biais plus difficile à prédire.

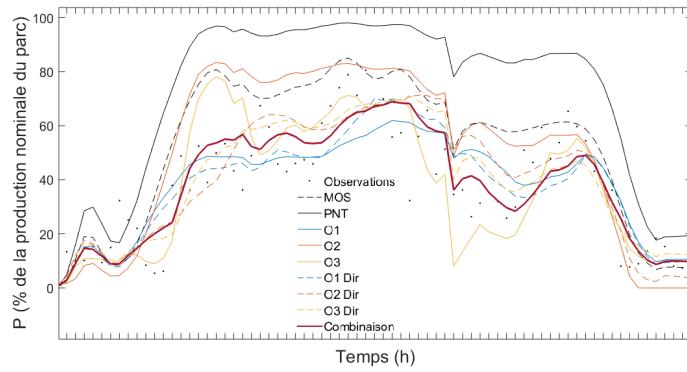


Figure 5.19 **A3** - Puissance en fonction du temps pour le site #15 ( $h = 1$ )

La Figure 5.20 permet de comparer le comportement des filtres implémentés pour cette approche avec ceux associés à **A1** et **A2** pour le même site et la même plage horaire (voir les Figures 5.7 et 5.13). La différence entre les comportements des filtres appliqués à la vitesse et celui appliqué à la puissance est notable.

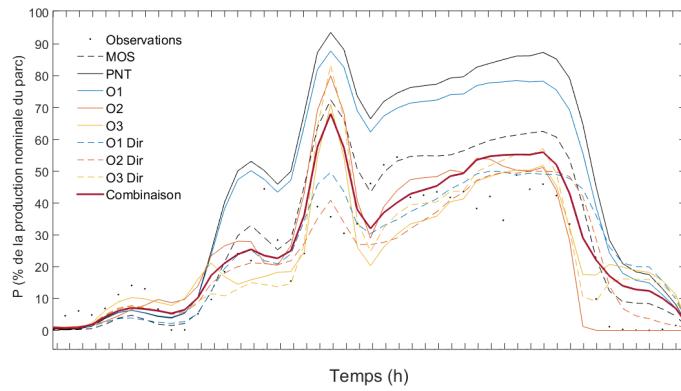


Figure 5.20 **A3** - Puissance en fonction du temps pour le site #15 ( $h = 1$ )

En conclusion, l'ajout de la direction est bénéfique pour les modèles de filtre de Kalman corrigéant la puissance, et les ordres plus élevés permettent de réduire les erreurs de prévision

comparativement aux ordres inférieurs. Les résultats présentés dans cette section indiquent toutefois qu'il est difficile de prédire le biais sur la puissance, ce qui résulte en des précisions globales nettement inférieures aux approches précédentes.

## 5.4 Comparaison des approches de prévision de la puissance

Dans cette dernière section, les trois approches proposées pour prédire la puissance générée par les éoliennes sont comparées. L'objectif est d'évaluer les meilleurs modèles et les combinaisons des nouvelles méthodes développées, afin de déterminer s'il est possible d'atteindre des performances similaires à l'approche **A1** lorsque les vitesses de vent ne sont pas disponibles.

### 5.4.1 Meilleurs modèles

Il a été démontré dans les sections précédentes que, pour les modèles utilisant les filtres de Kalman appliqués à la vitesse (**A1** et **A2**), l'ordre 1 directionnel donne de meilleures performances en général, alors que lorsqu'il est appliqué à la puissance (**A3**), l'ordre 3 directionnel permet d'atteindre les meilleures précisions. Les figures suivantes présentent les différents indicateurs de performance en fonction de l'horizon pour les meilleurs modèles des trois approches étudiées. Ici, l'approche **A1** est représentée à des fins de comparaison, afin de déterminer la performance relative des approches pour lesquelles les observations de vitesse de vent ne sont pas disponibles.

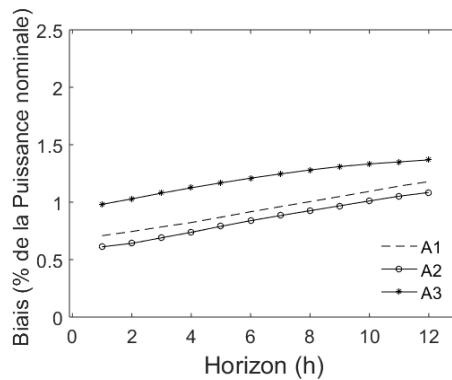


Figure 5.21 Biais (ME) moyen des meilleurs modèles pour A1, A2 et A3

Aux Figures 5.21, 5.22(a), et 5.22(b), on remarque que l'approche **A2**, selon laquelle le filtre de Kalman est appliqué sur des vitesses *fictives*, permet d'atteindre des performances très similaires à l'approche **A1**, bien que la vitesse du vent observée ne soit pas disponible. Le meilleur modèle de l'approche **A3**, quant à lui, donne des MAE et RMSE nettement plus élevés que les deux autres approches.

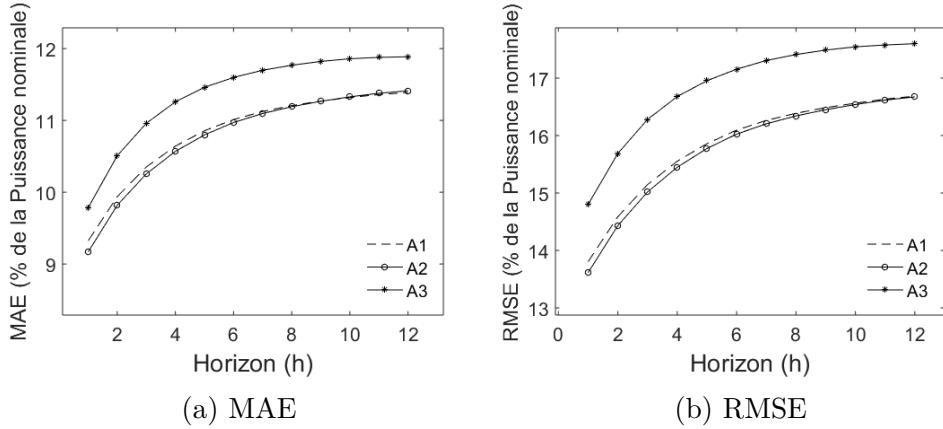


Figure 5.22 MAE et RMSE moyens des meilleurs modèles pour A1, A2 et A3

Cette tendance est également visible aux Figures 5.23(a) et 5.23(b), qui démontrent que la proportion d'erreurs comprises dans les marges de  $15\% P_{nom}$  et  $30\% P_{nom}$  est toujours plus élevée pour les deux premières approches. Cela signifie que la partie centrale de la distribution d'erreurs pour l'approche **A3** est moins étroite, et que le bas de la distribution est plus évasé.

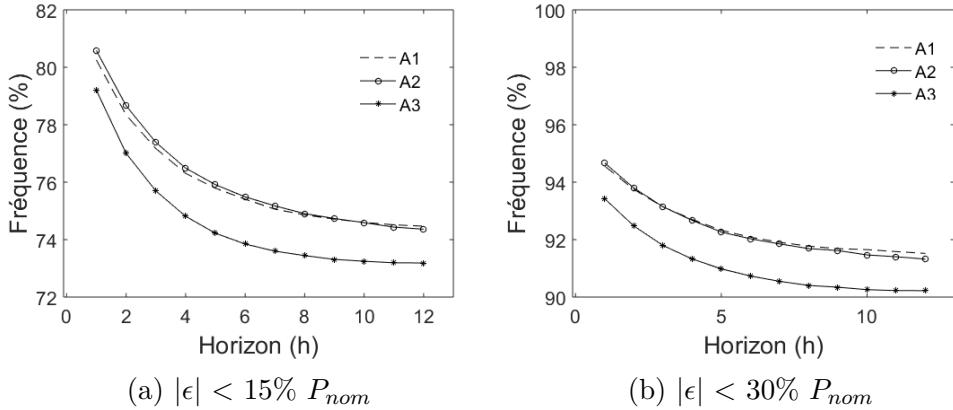


Figure 5.23 Distributions des erreurs des meilleurs modèles pour A1, A2 et A3

En d'autres termes, le nombre d'erreurs anormalement élevées est plus important lorsque le filtre de Kalman est directement appliqué à la correction du biais de la puissance. Ceci résulte du fait que pour **A3**, les erreurs de prévision de vitesse des modèles de PNT sont amplifiées de façon fortement non linéaire lorsqu'elles sont converties en puissance, puisque la puissance contenue dans le vent est proportionnelle à sa vitesse au cube (voir l'équation (1.1)). Les grandes erreurs sont donc amplifiées (d'où la distribution plus évasée) et les filtres de Kalman réussissent moins bien à prédire et corriger ces fortes variations. Par ailleurs, il est possible de démontrer que la distribution des erreurs du modèle de PNT pour la puissance n'est pas gaussienne, comparativement aux erreurs sur la vitesse (ce qui est intuitif, étant donné la

transformation non linéaire appliquée pour convertir les vitesses en puissance). Puisque le filtre de Kalman est optimal pour des bruits blancs, donc gaussiens, il n'est pas surprenant de constater qu'il soit moins précis pour la prévision du biais sur la puissance.

#### 5.4.2 Combinaison des modèles

Les Figures 5.24, 5.25 et 5.26 montrent les performances de la *combinaison* des filtres de Kalman pour chacune des approches **A1**, **A2** et **A3** en fonction de l'horizon. Le biais est encore une fois réduit de façon similaire pour toutes les approches. On note cependant, autant au niveau du MAE, RMSE et de la distribution des erreurs, que l'approche **A2** surpassé les deux autres lorsque la combinaison est appliquée.

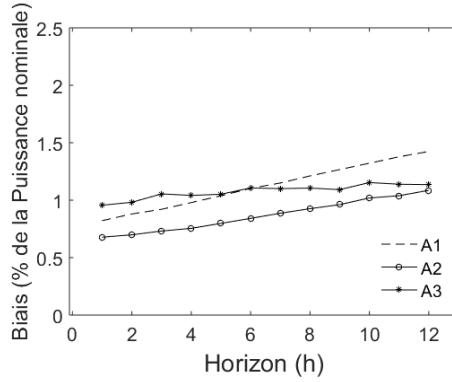


Figure 5.24 Biais (ME) moyen des combinaisons pour A1, A2 et A3

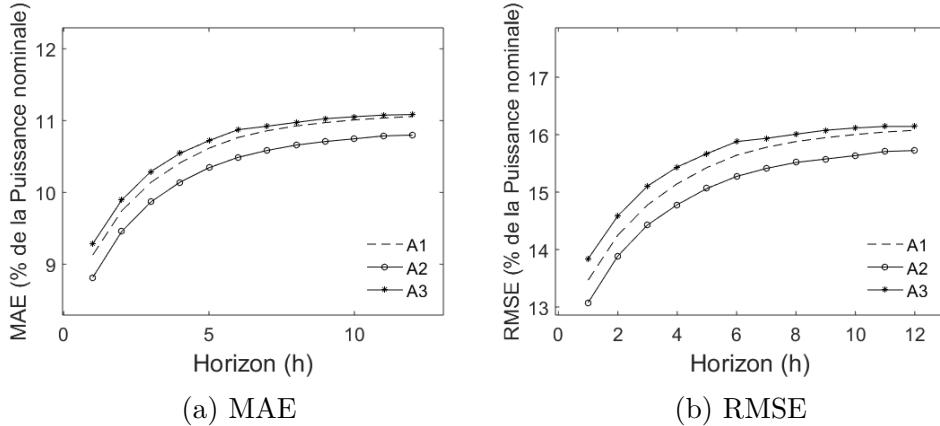


Figure 5.25 MAE et RMSE moyens des combinaisons pour A1, A2 et A3

Tel qu'expliqué à la sous-section 5.1.3, l'approche **A1** applique les modèles sur les données de vitesse, alors que la combinaison pondère les modèles en fonction de leur performance sur la puissance. La combinaison est par conséquent moins performante que pour l'approche **A2** (où les données sont les observations de puissance).

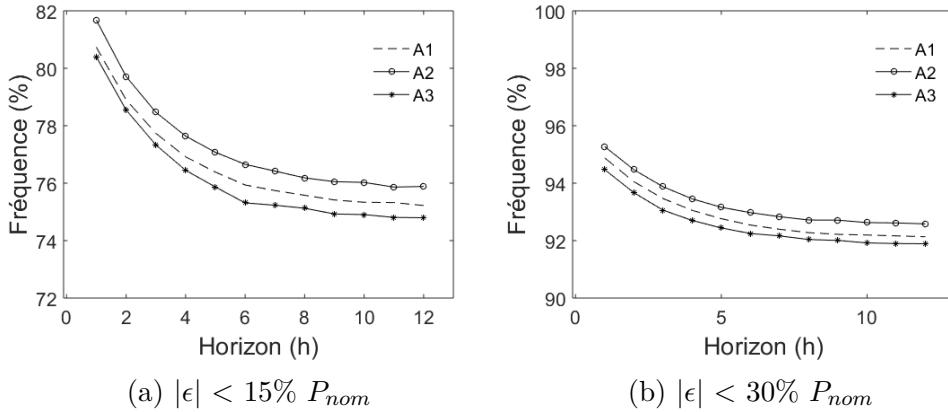


Figure 5.26 Distributions des erreurs des combinaisons pour A1, A2 et A3

Au tableau 5.14, les améliorations moyennes du RMSE comparativement aux PNTs des meilleurs modèles ainsi que des combinaisons de tous les modèles sont données pour chaque approche. Cela permet de constater à nouveau que la combinaison des modèles est bénéfique dans tous les cas.

Tableau 5.14 Amélioration du RMSE avec et sans combinaison pour **A1**, **A2**, et **A3**, moyenne de  $h=1$  à  $h=6^*$

	<b>A1</b>	<b>A2</b>	<b>A3</b>
<b>Meilleur modèle</b>	36,6%	37,1%	32,4%
<b>Combinaison</b>	38,3%	39,7%	37,3%

\*Plus l'amélioration est élevée, meilleures sont les prévisions.

Finalement, le tableau 5.15 résume les performances globales de la combinaison pour les trois modèles, sous forme de moyenne pour les horizons  $h = 1$  à  $h = 6$ .

Tableau 5.15 Amélioration du RMSE de la combinaison pour **A1**, **A2**, et **A3**, moyenne de  $h=1$  à  $h=6^*$

	<b>A1</b>	<b>A2</b>	<b>A3</b>
<b>PNT :</b>	38,3%	39,7%	37,3%
<b>MOS :</b>	16,1%	17,9%	14,4%
<b>Persistante :</b>	7,4%	9,5%	5,2%
<b>Pire modèle :</b>	5,5%	6,9%	14,1%
<b>Meilleur modèle :</b>	2,2%	3,27%	6,4%

\*Plus l'amélioration est élevée, meilleures sont les prévisions.

Les principales conclusions de ce chapitre sont, d'abord, que le filtre de Kalman appliqué aux données de puissance ne permet pas d'atteindre des résultats similaires aux deux autres

approches. L'approche selon laquelle la puissance observée est convertie en vitesse de vent fictive montre des performances très similaires à l'approche de référence, selon laquelle le filtre de Kalman est appliqué sur les observations réelles de vitesse de vent. Lorsque la combinaison des modèles est appliquée, l'inversion de la courbe de puissance permet même de surpasser l'approche de référence.

## CHAPITRE 6 CONCLUSION

### 6.1 Synthèse des travaux

Pour conclure, le projet a permis de développer de nouvelles approches améliorant une technique existante de prévision du vent et de la puissance à court terme. Des filtres de Kalman modélisant les biais entre les observations et les prévisions du modèle de prévision numérique du temps (PNT) sous forme polynomiale sont étudiés. Plus encore, la direction est introduite comme paramètre d'entrée dans les modèles de filtre de Kalman, ce qui n'a encore jamais été exploré à ce jour. Enfin, de nouvelles approches pour la correction de la puissance sont introduites et examinées.

Une conclusion majeure du projet est que l'ajout de la direction permet d'améliorer nettement la précision des prévisions de vitesses de vent. Par ailleurs, il est démontré qu'une modélisation du biais selon un polynôme d'ordre 1 permet d'atteindre de meilleures précisions pour la prévision du vent. Le meilleur modèle, celui d'ordre 1 directionnel, permet de réduire le RMSE par rapport au modèle physique de 41,6% en moyenne pour les six premières heures d'horizon. Cette réduction atteint environ 46% pour  $h = 1$ . En revanche, lorsque les filtres sont utilisés pour corriger directement le biais sur la prévision de puissance, le biais modélisé selon l'ordre 3 permet d'obtenir de meilleures prévisions que les ordres inférieurs. En outre, l'ajout de la direction dans le modèle appliqué à la puissance permet également d'augmenter ses performances.

Deux nouvelles approches ont été développées pour prédire la puissance lorsque les données de vitesses de vent observées ne sont pas disponibles. Leur comparaison permet de déterminer qu'il est plus avantageux de transformer les observations de puissances en vitesses de vent par l'approche d'inversion de la courbe de puissance, pour ensuite appliquer le filtre sur la vitesse, que de modéliser la puissance directement. La grande variabilité des données de puissance ne permet pas au filtre de s'adapter adéquatement et de demeurer stable. Pour les six premières heures d'horizon, la première approche réduit le RMSE sur la puissance de 37,1% de la puissance nominale en moyenne, alors qu'il est réduit seulement de 32,4% de  $P_{nom}$  pour la deuxième.

L'étude d'un grand nombre de sites mène à la conclusion que la performance des modèles (différents ordres et intégration de la direction) varie en fonction du temps, de l'horizon ainsi que de la localisation géographique. L'utilisation d'une approche combinant les modèles de façon adaptative et en fonction de l'horizon permet de répondre à ces problématiques. Les

prévisions obtenues à partir de la combinaison réduisent en moyenne le RMSE sur la vitesse et la puissance de plus de 7% par rapport au pire modèle, et surpassent toujours le meilleur modèle de plus de 3% en moyenne.

Au final, l'approche KF-KF( $\theta$ )-Combinaison permet de réduire significativement le RMSE par rapport au modèle de prévision numérique du temps, soit de 44,3% en moyenne pour la vitesse, et de 39,7% pour la puissance. Comparativement au modèle MOS, les RMSE sont réduits de 24,5% et de 17,9% pour la vitesse et la puissance respectivement. De plus, le RMSE est réduit significativement comparativement à la persistance, une approche généralement difficile à surpasser pour les horizons de 6 heures et moins. Relativement à la persistance, le RMSE est réduit en moyenne sur les six premières heures d'horizon de 7,3% pour la vitesse, et 9,5% pour la puissance.

## 6.2 Limitations de la solution proposée

La solution proposée possède néanmoins certaines limitations. En réalité, les données d'observation reçues en temps réel ne sont pas parfaites : il arrive fréquemment que certaines données soient absentes de façon ponctuelle. Plusieurs facteurs peuvent occasionner une telle situation, notamment un détecteur défectueux ou une erreur lors de l'envoi des données. Essentiellement, cela peut susciter davantage d'instabilités dans les filtres et en réduire la performance. Il arrive aussi parfois que les données observées soient absentes pendant une période de temps plus prolongée (plusieurs heures ou quelques jours). Le dernier état du filtre peut être utilisé sans mise à jour pour quelques heures seulement ; lorsque la période sans observation est trop longue, il ne peut plus être appliqué.

De plus, puisque la correction des prévisions par filtre de Kalman est basée sur la prévision du biais entre les PNTs et les mesures réelles, la performance des modèles est fortement influencée par la précision du modèle physique. Lorsque ce dernier présente initialement une erreur très élevée, les filtres parviennent à réduire cette erreur significativement, mais pas de façon optimale.

## 6.3 Principales contributions du mémoire

Ce projet a donc permis de développer une nouvelle méthodologie pour la prévision de la vitesse du vent et de la production éolienne. Il s'agit d'une poursuite du travail de Louka et Galanis sur l'application du filtre de Kalman à la prévision de la vitesse du vent. Cette section résume les principales contributions de ce mémoire.

1. Il a été possible de vérifier les modèles de filtre de Kalman proposés par Louka et Galanis sur un plus grand ensemble de données. Dans le cadre de leur étude, les données de vitesse de vent historiques pour deux parcs éoliens seulement étaient disponibles. Leurs résultats suggèrent que des prévisions plus précises sont atteintes lorsque le biais est modélisé selon un polynôme d'ordre 3. Toutefois, les performances des modèles de prévision étant en général très dépendantes de l'emplacement géographique, l'étude de deux sites seulement ne permet pas de tirer des conclusions suffisamment générales. Ainsi, pour ce projet, les modèles ont pu être évalués sur les données de 20 parcs éoliens en Europe et en Amérique du Nord, situés sur des terrains plus ou moins complexes. Cette grande quantité de données a permis d'obtenir des résultats significatifs et il a été possible de déterminer qu'en général, un biais modélisé selon un polynôme d'ordre 1 permet d'atteindre les meilleures précisions.
2. Une analyse préliminaire a démontré que l'erreur du modèle de PNT est fortement corrélée à la direction du vent. Afin de bonifier le modèle de Louka et Galanis, il est proposé d'ajouter la direction vent au modèle de filtre de Kalman pour augmenter la précision de la prévision. L'analyse des erreurs des modèles directionnels permet de confirmer cette hypothèse : tous les ordres polynomiaux (1, 2 et 3) atteignent de meilleures précisions lorsqu'ils incluent la direction.
3. Les filtres de Kalman directionnels ont aussi été évalués pour la prévision de la puissance. Dans une première approche, les vitesses prédites par le filtre de Kalman sont directement converties en puissance. Deux nouvelles approches sont développées pour les cas où les observations de vitesses de vent ne sont pas disponibles : (i) la création de vitesses fictives par inversion de la courbe de puissance, et (ii) l'application directe d'un filtre de Kalman à la correction du biais sur la puissance. Le biais sur la puissance est cependant très difficile à prédire, notamment puisque le filtre de Kalman n'est optimal que pour une distribution d'erreurs normale, ce qui n'est pas le cas pour la puissance. Au final, l'approche indirecte par la création de vitesses fictives permet quant à elle d'atteindre des précisions très similaires au scénario où les vitesses de vent sont disponibles. Cette méthode est donc priorisée si les vitesses observées ne sont pas disponibles. Enfin, pour toutes les approches considérées, l'analyse des erreurs démontre que la direction permet encore une fois d'améliorer la précision pour tous les modèles.
4. Une combinaison linéaire de tous les modèles développés a été étudiée pour la prévision de la vitesse du vent et de la puissance. Cette combinaison est spécifique à chaque site, chaque horizon de prévision, et adaptative dans le temps selon les performances récentes des modèles combinés. Les précisions atteintes par la combinaison dépassent largement les précisions atteintes par les meilleurs modèles individuellement et ce, pour tous les sites étudiés.

Cela confirme d'abord que la performance des modèles est fortement dépendante du moment, de l'horizon et de l'emplacement géographique, mais plus encore, permet de contourner ces problématiques.

#### 6.4 Améliorations futures

Il a été démontré que pour les filtres de Kalman appliqués à la puissance, une augmentation de l'ordre améliore la performance. Pour des études futures, il serait intéressant de vérifier si des biais d'ordres supérieurs permettraient d'atteindre des précisions accrues.

Par ailleurs, dans la littérature, plusieurs articles étudient la stabilité des filtres de Kalman, ainsi que les méthodes visant à l'améliorer [18], [39]. L'utilisation de certaines de ces approches pourrait se montrer efficace quant à la réduction des erreurs associées aux instabilités dans les modèles développés.

Finalement, les filtres de Kalman ne parviennent pas à surpasser la persistance dans les six premières heures d'horizon pour certains sites spécifiques. Lors de travaux futurs, une reformulation du modèle de combinaison incluant les filtres de Kalman, mais aussi le MOS et la persistance pourrait être bénéfique. Un poids maximum devrait être alloué à la persistance afin d'éviter que les prévisions soient basées à 100% sur cette valeur. Par ailleurs, sachant que les approches statistiques sont moins adaptées au long terme, mais que l'horizon où l'on devrait passer de Kalman au modèle de PNT est très dépendant du site, l'ajout du MOS ou du modèle de PNT dans la combinaison serait profitable. Cette démarche permettrait de choisir automatiquement et de façon adaptative sur quels horizons le filtre de Kalman est appliqué, ainsi qu'à partir de quel moment l'on devrait faire plus confiance aux modèles physiques.

## RÉFÉRENCES

- [1] O. Abedinia et N. Amjadi, “Short-term wind power prediction based on Hybrid Neural Network and chaotic shark smell optimization”, *International Journal of Precision Engineering and Manufacturing-Green Technology*, vol. 2, no. 3, pp. 245–254, 2015. DOI : 10.1007/s40684-015-0029-4
- [2] M. C. Alexiadis, P. S. Dokopoulos, H. S. Sahsamanoglou, et I. M. Manousaridis, “Short-Term Forecasting of Wind Speed and Related Electrical Power”, vol. 63, no. 1, pp. 61–68, 1998.
- [3] N. Amjadi, F. Keynia, et H. Zareipour, “Wind Power Prediction by a New Forecast Engine Composed of Modified Hybrid Neural Network and Enhanced Particle Swarm Optimization”, *IEEE Transactions on Sustainable Energy*, vol. 2, no. 3, pp. 265–276, Juil. 2011. DOI : 10.1109/TSTE.2011.2114680
- [4] A. Bagchi, *Optimal Control of Stochastic Systems*, 1<sup>e</sup> éd., série Prentice Hall international series in systems and control engineering. New York : Prentice Hall, 1993, oCLC : 27223012.
- [5] M. Bilgili, B. Sahin, et A. Yasar, “Application of artificial neural networks for the wind speed prediction of target station using reference stations data”, *Renewable Energy*, vol. 32, no. 14, pp. 2350–2360, Nov. 2007. DOI : 10.1016/j.renene.2006.12.001
- [6] G. Bishop et G. Welch, “An Introduction to the Kalman Filter”, 2001.
- [7] Bloomberg New Energy Finance, “New Energy Outlook 2017”, Rapp. tech., Juin 2017.
- [8] R. G. Brown, P. Y. C. Hwang, et R. G. Brown, *Introduction to Random Signals and Applied Kalman Filtering*, 2<sup>e</sup> éd. New York : J. Wiley, 1992.
- [9] T. Burton, éd., *Wind Energy : Handbook*. Chichester ; New York : J. Wiley, 2001.
- [10] Canadian Wind Energy Association (CANWEA), “Une énergie abordable - Canadian Wind Energy Association”, <https://canwea.ca/fr/leolien-les-faits/une-energie-abordable/>, 2017.
- [11] F. Cassola et M. Burlando, “Wind speed and wind energy forecast through Kalman filtering of Numerical Weather Prediction model output”, *Applied Energy*, vol. 99, pp.

- 154–166, 2012. DOI : 10.1016/j.apenergy.2012.03.054
- [12] J. P. S. Catalão, H. M. I. Pousinho, et V. M. F. Mendes, “An Artificial Neural Network Approach for Short-Term Wind Power Forecasting in Portugal”, dans *2009 15th International Conference on Intelligent System Applications to Power Systems*, Nov. 2009, pp. 1–5. DOI : 10.1109/ISAP.2009.5352853
- [13] ——, “Hybrid Wavelet-PSO-ANFIS Approach for Short-Term Wind Power Forecasting in Portugal”, *IEEE Transactions on Sustainable Energy*, vol. 2, no. 1, pp. 50–59, Jan. 2011. DOI : 10.1109/TSTE.2010.2076359
- [14] ——, “Short-term wind power forecasting in Portugal by neural networks and wavelet transform”, *Renewable Energy*, vol. 36, no. 4, pp. 1245–1251, 2011. DOI : 10.1016/j.renene.2010.09.016
- [15] Y. Che, X. Peng, L. Delle Monache, T. Kawaguchi, et F. Xiao, “A wind power forecasting system based on the weather research and forecasting model and Kalman filtering over a wind-farm in Japan”, *Journal of Renewable and Sustainable Energy*, vol. 8, no. 1, p. 013302, Jan. 2016. DOI : 10.1063/1.4940208
- [16] C. K. Chui et G. Chen, *Kalman Filtering : With Real-Time Applications*, 4e éd. Berlin : Springer, 2009.
- [17] A. Costa, A. Crespo, J. Navarro, G. Lizcano, H. Madsen, et E. Feitosa, “A review on the young history of the wind power short-term prediction”, *Renewable and Sustainable Energy Reviews*, vol. 12, no. 6, pp. 1725–1744, Août 2008. DOI : 10.1016/j.rser.2007.01.015
- [18] E. F. Costa et A. Astolfi, “On the stability of the recursive Kalman filter for linear time-invariant systems”, dans *2008 American Control Conference*, Juin 2008, pp. 1286–1291. DOI : 10.1109/ACC.2008.4586670
- [19] P. Crochet, “Adaptive Kalman filtering of 2-metre temperature and 10-metre wind-speed forecasts in Iceland”, *Meteorological Applications*, vol. 11, pp. 173–187, 2004. DOI : 10.1017/S1350482704001252
- [20] I. G. Damousis, M. C. Alexiadis, J. B. Theocharis, et P. S. Dokopoulos, “A fuzzy model for wind speed prediction and power generation in wind parks using spatial correlation”, *IEEE Transactions on Energy Conversion*, vol. 19, no. 2, pp. 352–361, Juin 2004. DOI : 10.1109/TEC.2003.821865

- [21] Department of Energy, “Advantages and Challenges of Wind Energy”, <https://energy.gov/eere/wind/advantages-and-challenges-wind-energy>, 2016.
- [22] Environnement Canada, “Cartes de prévisions numériques”, [https://meteo.gc.ca/model\\_forecast/about\\_these\\_products\\_f.html](https://meteo.gc.ca/model_forecast/about_these_products_f.html), Avr. 2013.
- [23] ——, “Données numériques haute résolution - Ensemble SPENA- Format GRIB2”, [https://meteo.gc.ca/grib/grib2\\_glb\\_25km\\_f.html](https://meteo.gc.ca/grib/grib2_glb_25km_f.html), Avr. 2013.
- [24] A. M. Foley, P. G. Leahy, A. Marvuglia, et E. J. McKeogh, “Current methods and advances in forecasting of wind power generation”, *Renewable Energy*, vol. 37, no. 1, pp. 1–8, 2012. DOI : [10.1016/j.renene.2011.05.033](https://doi.org/10.1016/j.renene.2011.05.033)
- [25] G. Galanis, P. Louka, P. Katsafados, I. Pytharoulis, et G. Kallos, “Applications of Kalman filters based on non-linear functions to numerical weather predictions”, *Annales Geophysicae*, vol. 24, pp. 2451–2460, 2006. DOI : [10.5194/angeo-24-2451-2006](https://doi.org/10.5194/angeo-24-2451-2006)
- [26] G. Galanis et M. Anadranistakis, “A one-dimensional Kalman filter for the correction of near surface temperature forecasts”, *Meteorological Applications*, vol. 9, pp. 437–441, 2002. DOI : [10.1017/S1350482702004061](https://doi.org/10.1017/S1350482702004061)
- [27] C. Gallego, P. Pinson, H. Madsen, A. Costa, et A. Cuerva, “Influence of local wind speed and direction on wind power dynamics – Application to offshore very short-term forecasting”, *Applied Energy*, vol. 88, no. 11, pp. 4087–4096, Nov. 2011. DOI : [10.1016/j.apenergy.2011.04.051](https://doi.org/10.1016/j.apenergy.2011.04.051)
- [28] G. Giebel, “The State-Of-The-Art in Short-Term Prediction of Wind Power”, 2009.
- [29] Global Wind Energy Council (GWEC), “Global Wind Report 2016”, GWEC, Ulaanbaatar, Mongolie, Rapp. tech. 8th National Renewable Energy Forum, Mai 2017.
- [30] E. Hau, *Wind Turbines : Fundamentals, Technologies, Application, Economics*, 2e éd. Berlin Heidelberg : Springer-Verlag, 2006.
- [31] C.-Y. Huang, Y.-W. Liu, W.-C. Tzeng, et P.-Y. Wang, “Short Term Wind Speed Predictions by Using the Grey Prediction Model Based Forecast Method”, *2011 IEEE Green Technologies Conference (IEEE-Green)*, pp. 1–5, 2011. DOI : [10.1109/GREEN.2011.5754856](https://doi.org/10.1109/GREEN.2011.5754856)
- [32] H. Ibrahim, M. Ghandour, M. Dimitrova, A. Ilinca, et J. Perron, “Integration of Wind Energy into Electricity Systems : Technical Challenges and Actual Solutions”, *Energy*

*Procedia*, vol. 6, pp. 815–824, Jan. 2011. DOI : [10.1016/j.egypro.2011.05.092](https://doi.org/10.1016/j.egypro.2011.05.092)

- [33] International Renewable Energy Agency (IRENA), “The Power to Change : Solar and Wind Cost Reduction Potential”, Rapp. tech., Juin 2016.
- [34] J. S. R. Jang, “ANFIS : Adaptive-network-based fuzzy inference system”, *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 23, no. 3, pp. 665–685, Mai 1993. DOI : [10.1109/21.256541](https://doi.org/10.1109/21.256541)
- [35] J. Jung et R. P. Broadwater, “Current status and future advances for wind speed and power forecasting”, *Renewable and Sustainable Energy Reviews*, vol. 31, pp. 762–777, Mars 2014. DOI : [10.1016/j.rser.2013.12.054](https://doi.org/10.1016/j.rser.2013.12.054)
- [36] R. E. Kalman, “A New Approach to Linear Filtering and Prediction Problems”, *Journal of Basic Engineering*, vol. 82, no. 1, pp. 35–35, 1960. DOI : [10.1115/1.3662552](https://doi.org/10.1115/1.3662552)
- [37] G. Kariniotakis, J. Halliday, R. Brownsword, I. Marti, A. Palomares, I. Cruz, H. Madsen, T. Nielsen, H. Nielsen, U. Focken, M. Lange, G. Kallos, P. Louka, N. Hatziargyriou, P. Frayssinet, H.-P. I. Waldl, F. Dierich, G. Giebel, R. Barthelmie, et D. Garrett, *Next Generation Short-Term Forecasting of Wind Power – Overview of the ANEMOS Project.*, Fév. 2006, vol. 3.
- [38] T. Kitajima et T. Yasuno, “Output prediction of wind power generation system using complex-valued neural network”, dans *Proceedings of SICE Annual Conference 2010*, Août 2010, pp. 3610–3613.
- [39] S. Kluge, K. Reif, et M. Brokate, “Stochastic Stability of the Extended Kalman Filter With Intermittent Observations”, *IEEE Transactions on Automatic Control*, vol. 55, no. 2, pp. 514–518, Fév. 2010. DOI : [10.1109/TAC.2009.2037467](https://doi.org/10.1109/TAC.2009.2037467)
- [40] P. Kou et F. Gao, “Sparse heteroscedastic Gaussian process for shortterm wind speed fo- recasting”, dans *The 2012 International Joint Conference on Neural Networks (IJCNN)*, Juin 2012, pp. 1–8. DOI : [10.1109/IJCNN.2012.6252407](https://doi.org/10.1109/IJCNN.2012.6252407)
- [41] A. Kusiak, H. Zheng, et Z. Song, “Wind farm power prediction : A data-mining approach”, *Wind Energy*, vol. 12, no. 3, pp. 275–293, Avr. 2009. DOI : [10.1002/we.295](https://doi.org/10.1002/we.295)
- [42] L. Landberg, G. Giebel, H. A. Nielsen, T. Nielsen, et H. Madsen, “Short-term prediction - An overview”, *Wind Energy*, vol. 6, no. 3, pp. 273–280, 2003. DOI : [10.1002/we.96](https://doi.org/10.1002/we.96)

- [43] M. Lei, L. Shiyan, J. Chuanwen, L. Hongling, et Z. Yan, “A review on the forecasting of wind speed and generated power”, *Renewable and Sustainable Energy Reviews*, vol. 13, no. 4, pp. 915–920, 2009. DOI : 10.1016/j.rser.2008.02.002
- [44] H. Liu, H.-Q. Tian, C. Chen, et Y.-f. Li, “A hybrid statistical method to predict wind speed and wind power”, *Renewable Energy*, vol. 35, no. 8, pp. 1857–1861, Août 2010. DOI : 10.1016/j.renene.2009.12.011
- [45] H. Liu, C. Chen, H.-q. Tian, et Y.-f. Li, “A hybrid model for wind speed prediction using empirical mode decomposition and artificial neural networks”, *Renewable Energy*, vol. 48, pp. 545–556, Déc. 2012. DOI : 10.1016/j.renene.2012.06.012
- [46] L. Ljung et T. Söderström, *Theory and Practice of Recursive Identification*, mit press éd., 1983.
- [47] P. López, R. Velo, et F. Maseda, “Effect of direction on wind speed estimation in complex terrain using neural networks”, *Renewable Energy*, vol. 33, no. 10, pp. 2266–2272, 2008. DOI : 10.1016/j.renene.2007.12.020
- [48] P. Louka, G. Galanis, N. Siebert, G. Kariniotakis, P. Katsafados, I. Pytharoulis, et G. Kallos, “Improvements in wind speed forecasts for wind power prediction purposes using Kalman filtering”, *Journal of Wind Engineering and Industrial Aerodynamics*, vol. 96, no. 12, pp. 2348–2362, 2008. DOI : 10.1016/j.jweia.2008.03.013
- [49] P. Lv et L. Yue, “Short-term wind speed forecasting based on non-stationary time series analysis and ARCH model”, dans *2011 International Conference on Multimedia Technology*, Juil. 2011, pp. 2549–2553. DOI : 10.1109/ICMT.2011.6002447
- [50] M. Lydia, S. S. Kumar, A. I. Selvakumar, et G. E. Prem Kumar, “A comprehensive review on wind turbine power curve modeling techniques”, *Renewable and Sustainable Energy Reviews*, vol. 30, pp. 452–460, Fév. 2014. DOI : 10.1016/j.rser.2013.10.030
- [51] R. J. Meinhold et N. D. Singpurwalla, “Understanding the Kalman Filter”, *The American Statistician*, vol. 37, no. 2, pp. 123–127, 1983. DOI : 10.2307/2685871
- [52] J. W. Messner, A. Zeileis, J. Broecker, et G. J. Mayr, “Probabilistic wind power forecasts with an inverse power curve transformation and censored regression : The inverse power curve transformation and censored regression”, *Wind Energy*, vol. 17, no. 11, pp. 1753–1766, Nov. 2014. DOI : 10.1002/we.1666

- [53] M. Milligan, M. Schwatz, et Y. Wan, “Statistical Wind Power Forecasting Models : Statistical Wind Power Forecasting Models : Results for U . S . Wind Farms”, *National Renewable Energy Laboratory*, no. January 2003, 2003.
- [54] M. A. Mohandes, T. O. Halawani, S. Rehman, et A. A. Hussain, “Support vector machines for wind speed prediction”, *Renewable Energy*, vol. 29, no. 6, pp. 939–947, Mai 2004. DOI : [10.1016/j.renene.2003.11.009](https://doi.org/10.1016/j.renene.2003.11.009)
- [55] H. Mori et E. Kurata, “Application of Gaussian Process to wind speed forecasting for wind power generation”, dans *2008 IEEE International Conference on Sustainable Energy Technologies*, Nov. 2008, pp. 956–959. DOI : [10.1109/ICSET.2008.4747145](https://doi.org/10.1109/ICSET.2008.4747145)
- [56] M. Negnevitsky et C. W. Potter, “Very Short-Term Wind Forecasting for Tasmanian Power Generation”, vol. 21, no. October, pp. 965–972, Mai 2006. DOI : [10.1109/TPWRS.2006.873421](https://doi.org/10.1109/TPWRS.2006.873421)
- [57] E. Panteri et S. Papathanassiou, “Evaluation of two simple wind power forecasting models”, *ResearchGate*, Jan. 2008.
- [58] P. Pinson, C. Chevallier, et G. N. Kariniotakis, “Trading Wind Generation From Short-Term Probabilistic Forecasts of Wind Power”, *IEEE Transactions on Power Systems*, vol. 22, no. 3, pp. 1148–1156, Août 2007. DOI : [10.1109/TPWRS.2007.901117](https://doi.org/10.1109/TPWRS.2007.901117)
- [59] P. Pinson, “Estimation of the Uncertainty in Wind Power Forecasting”, Thèse de doctorat, École Nationale Supérieure des Mines de Paris, 2006.
- [60] C. W. Potter et M. Negnevitsky, “Very short-term wind forecasting for Tasmanian power generation”, *IEEE Transactions on Power Systems*, vol. 21, no. 2, pp. 965–972, Mai 2006. DOI : [10.1109/TPWRS.2006.873421](https://doi.org/10.1109/TPWRS.2006.873421)
- [61] D. J. Reid, “A comparative study of time series prediction techniques on economic data”, Thèse de doctorat, 1969, oCLC : 220358458.
- [62] S. Salcedo-Sanz, Ángel M. Pérez-Bellido, E. G. Ortiz-García, A. Portilla-Figueras, L. Prieto, et D. Paredes, “Hybridizing the fifth generation mesoscale model with artificial neural networks for short-term wind speed prediction”, *Renewable Energy*, vol. 34, no. 6, pp. 1451–1457, Juin 2009. DOI : [10.1016/j.renene.2008.10.017](https://doi.org/10.1016/j.renene.2008.10.017)
- [63] I. Sánchez, “Adaptive combination of forecasts with application to wind energy”, *International Journal of Forecasting*, vol. 24, no. 4, pp. 679–693, Oct. 2008. DOI : [10.1016/j.ijforecast.2008.08.008](https://doi.org/10.1016/j.ijforecast.2008.08.008)

- [64] ——, “Recursive Estimation of Dynamic Models Using Cook’s Distance, With Application to Wind Energy Forecast”, *Technometrics*, vol. 48, no. 1, pp. 61–73, Fév. 2006. DOI : 10.1198/004017005000000364
- [65] A. Sfetsos, “A comparison of various forecasting techniques applied to mean hourly wind speed time series”, *Renewable Energy*, vol. 21, no. 1, pp. 23–35, 2000. DOI : 10.1016/S0960-1481(99)00125-1
- [66] G. Sideratos et N. D. Hatziargyriou, “An Advanced Statistical Method for Wind Power Forecasting”, *IEEE Transactions on Power Systems*, vol. 22, no. 1, pp. 258–265, Fév. 2007. DOI : 10.1109/TPWRS.2006.889078
- [67] Siemens, “Siemens Wind Turbine SWT-2.3-101”, <https://www.siemens.com/global/en/home/markets/wind/turbines-and-services/swt-2-3-101.html>, 2012.
- [68] S. S. Soman, H. Zareipour, O. Malik, et P. Mandal, “A review of wind power and wind speed forecasting methods with different time horizons”, *North American Power Symposium (NAPS)*, pp. 1–8, 2010. DOI : 10.1109/NAPS.2010.5619586
- [69] C. Strathopoulos, A. Kaperoni, G. Galanis, et G. Kallos, “Wind power prediction based on numerical and statistical models”, *Jnl. of Wind Engineering and Industrial Aerodynamics*, vol. 112, no. C, pp. 25–38, 2013. DOI : 10.1016/j.jweia.2012.09.004
- [70] A. Tascikaraoglu et M. Uzunoglu, “A review of combined approaches for prediction of short-term wind speed and power”, *Renewable and Sustainable Energy Reviews*, vol. 34, pp. 243–254, 2014. DOI : 10.1016/j.rser.2014.03.033
- [71] J. L. Torres, A. García, M. De Blas, et A. De Francisco, “Forecast of hourly average wind speed with ARMA models in Navarre (Spain)”, *Solar Energy*, vol. 79, no. 1, pp. 65–77, 2005. DOI : 10.1016/j.solener.2004.09.013
- [72] S. Velázquez, J. A. Carta, et J. M. Matías, “Influence of the input layer signals of ANNs on wind power estimation for a target site : A case study”, *Renewable and Sustainable Energy Reviews*, vol. 15, no. 3, pp. 1556–1566, Avr. 2011. DOI : 10.1016/j.rser.2010.11.036
- [73] M.-D. Wang, Q.-R. Qiu, et B.-W. Cui, “Short-term wind speed forecasting combined time series method and arch model”, dans *2012 International Conference on Machine Learning and Cybernetics*, vol. 3, Juil. 2012, pp. 924–927. DOI : 10.1109/ICMLC.2012.6359477

- [74] X. Wang, P. Guo, et X. Huang, “A review of wind power forecasting models”, *Energy Procedia*, vol. 12, pp. 770–778, 2011. DOI : 10.1016/j.egypro.2011.10.103
- [75] C. S. Watters et P. Leahy, “Influence of wind direction in the downscaling of wind speeds from numerical weather prediction”, *50th AIAA Aerospace Sciences Meeting*, no. January, pp. AIAA 2012–0654, 2012.
- [76] R. L. Welch, S. M. Ruffing, et G. K. Venayagamoorthy, “Comparison of feedforward and feedback neural network architectures for short term wind speed prediction”. IEEE, Juin 2009, pp. 3335–3340. DOI : 10.1109/IJCNN.2009.5179034
- [77] Wind energy generation systems, “IEC 61400-12-1 :2017 - Power performance measurements of electricity producing wind turbines”, <https://collections.iec.ch/std/series/iec61400-12-1%7Bed2.0%7Den.nsf/doc.xsp>, 2017.
- [78] Y.-K. Wu et J.-S. Hong, “A literature review of wind forecasting technology in the world”. IEEE, Juil. 2007, pp. 504–509. DOI : 10.1109/PCT.2007.4538368
- [79] P. Zarchan et H. Musoff, *Fundamentals of Kalman Filtering : A Practical Approach*. American Institute of Aeronautics and Astronautics, Incorporated, 2000.
- [80] Y. Zhang, J. Yang, K. Wang, Z. Zhao, J. Liu, et Y. Wang, “New Progress in Wind Prediction Based on Nonlinear Amendment”, dans *2014 IEEE Fourth International Conference on Big Data and Cloud Computing*, Déc. 2014, pp. 599–603. DOI : 10.1109/BDCloud.2014.13
- [81] Y. Zhang, P. Wang, C. Zhang, et S. Lei, “Wind energy prediction with LS-SVM based on Lorenz perturbation”, *The Journal of Engineering*, vol. 2017, no. 13, pp. 1724–1727, 2017. DOI : 10.1049/joe.2017.0626
- [82] Y. Zhang, J. Yang, K. Wang, Z. Wang, et Y. Wang, “Improved wind prediction based on the Lorenz system”, *Renewable Energy*, vol. 81, pp. 219–226, Sep. 2015. DOI : 10.1016/j.renene.2015.03.039
- [83] P. Zhao, J. Wang, J. Xia, Y. Dai, Y. Sheng, et J. Yue, “Performance evaluation and accuracy enhancement of a day-ahead wind power forecasting system in China”, *Renewable Energy*, vol. 43, pp. 234–241, Juil. 2012. DOI : 10.1016/j.renene.2011.11.051

## ANNEXE A Analyse directionnelle des données historiques

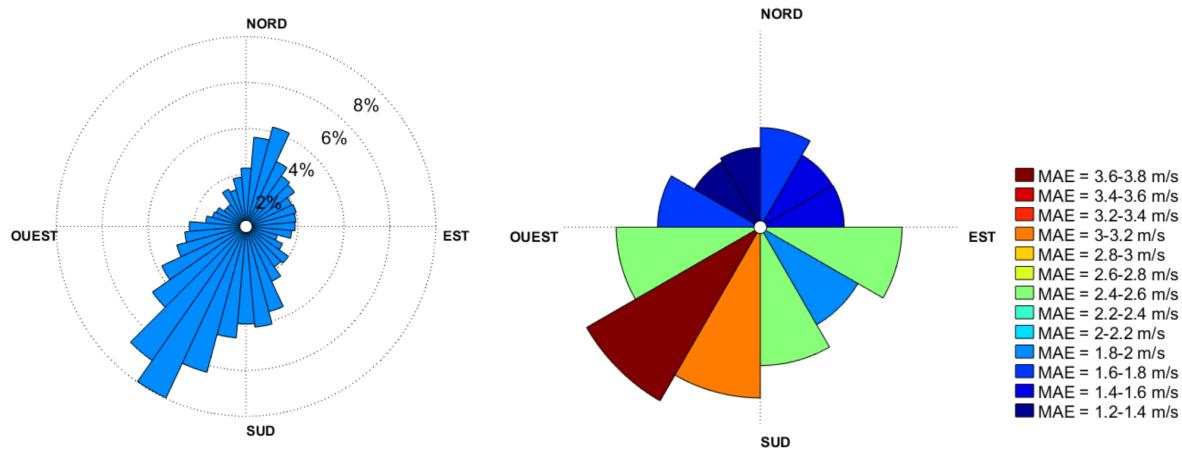


Figure A.1 MAE en fonction de la direction pour le site #10

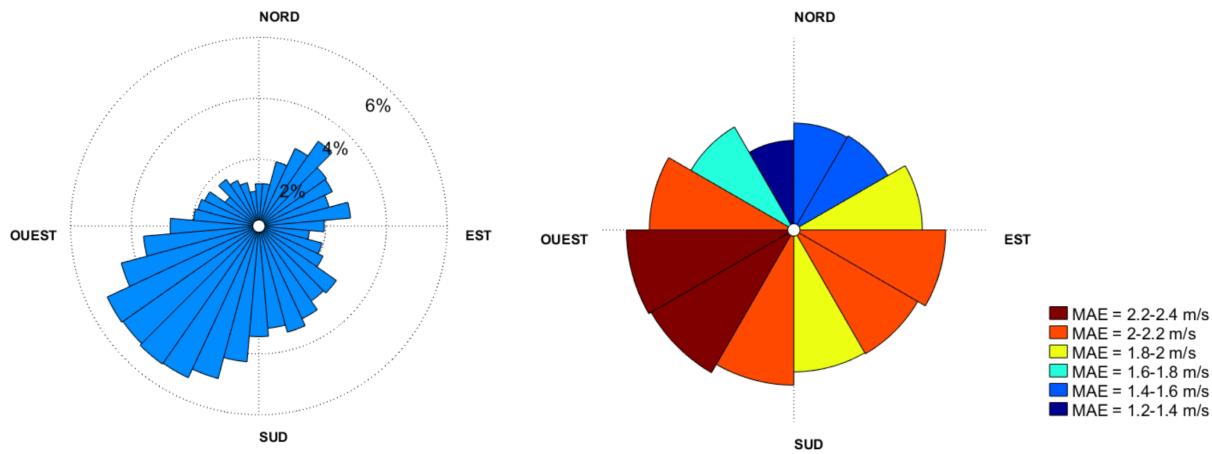


Figure A.2 MAE en fonction de la direction pour le site #11

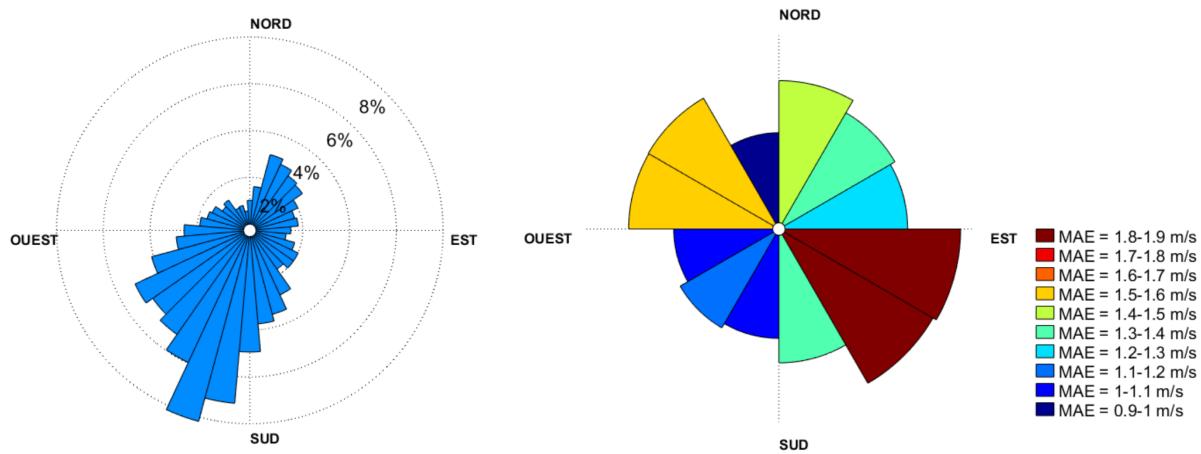


Figure A.3 MAE en fonction de la direction pour le site #13

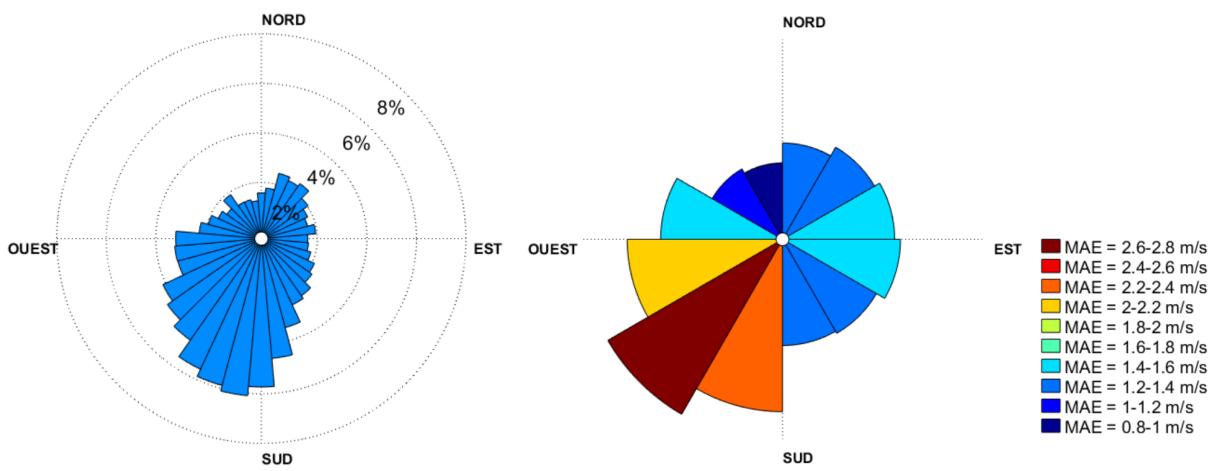
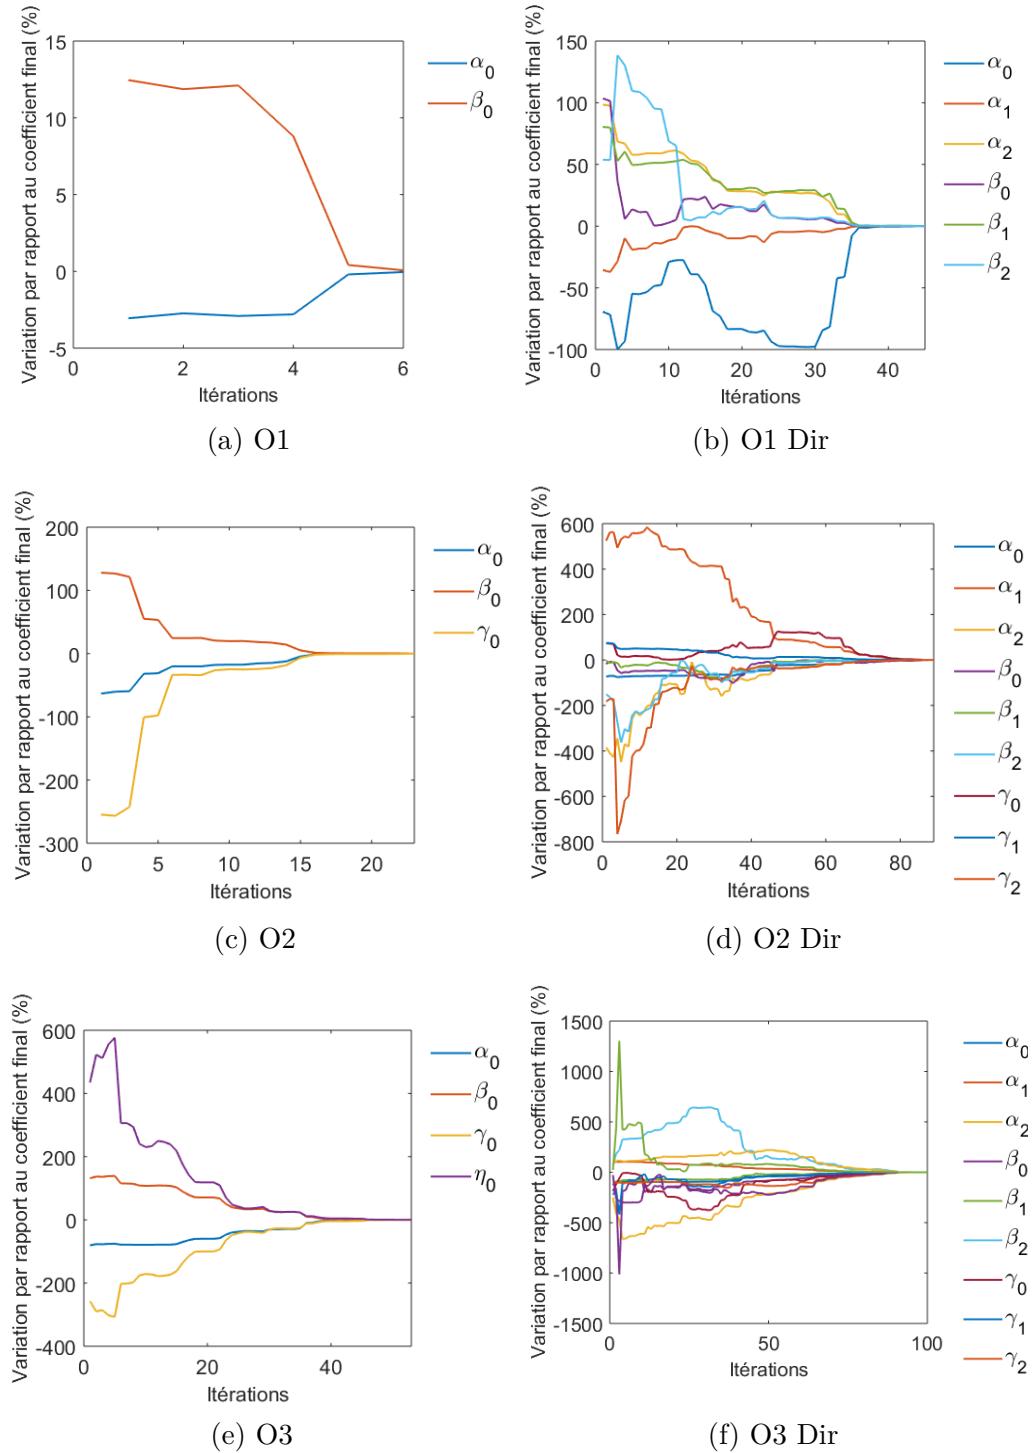


Figure A.4 MAE en fonction de la direction pour le site #14

## ANNEXE B Temps de convergence des coefficients



## ANNEXE C Comportement des modèles : vitesse en fonction du temps

Il est important de noter que dans cette annexe, l'axe du temps est uniformisé pour toutes les figures, alors que l'échelle de l'axe représentant les vitesses de vent peut varier, afin de permettre une meilleure visibilité pour les cas différents.

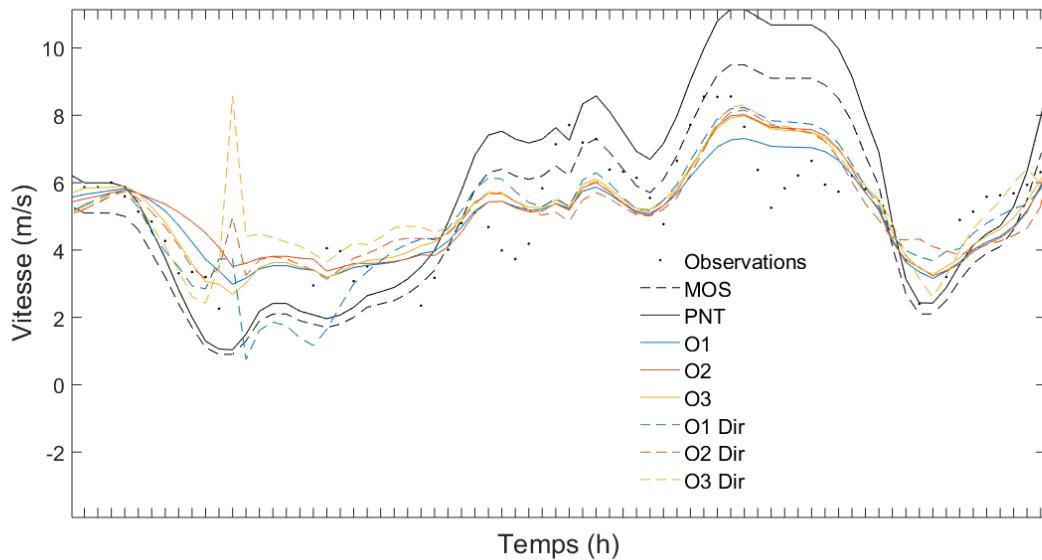


Figure C.1 Exemple d'instabilité

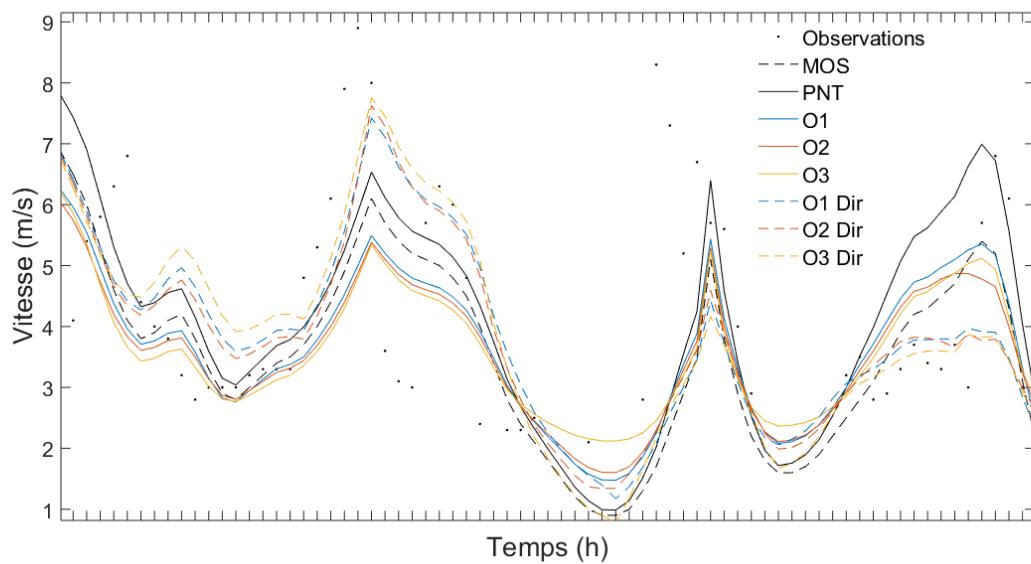


Figure C.2 Exemple de détection

**ANNEXE D Comportement des modèles : vitesse en fonction du temps, avec combinaison**

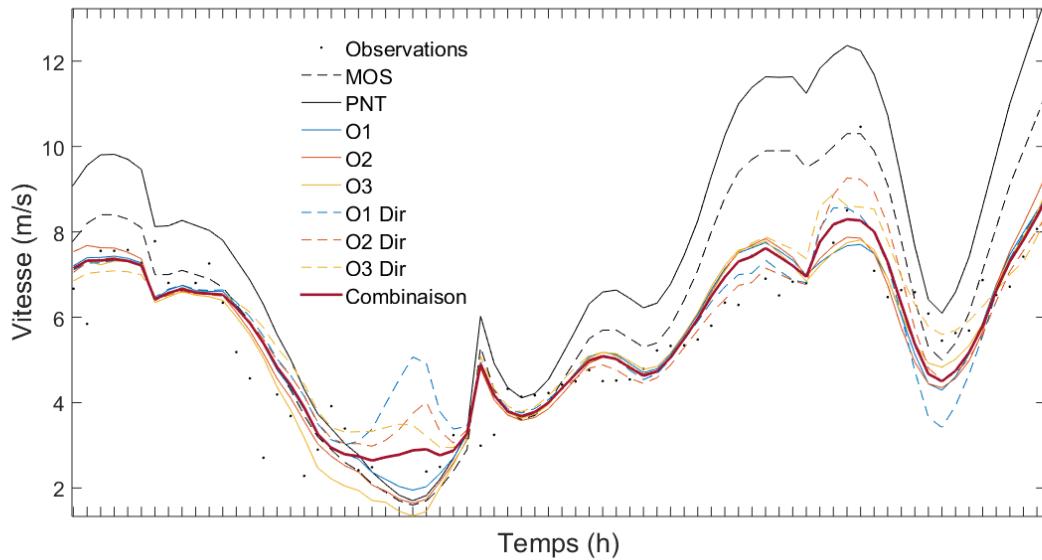


Figure D.1 Combinaison, exemple 1

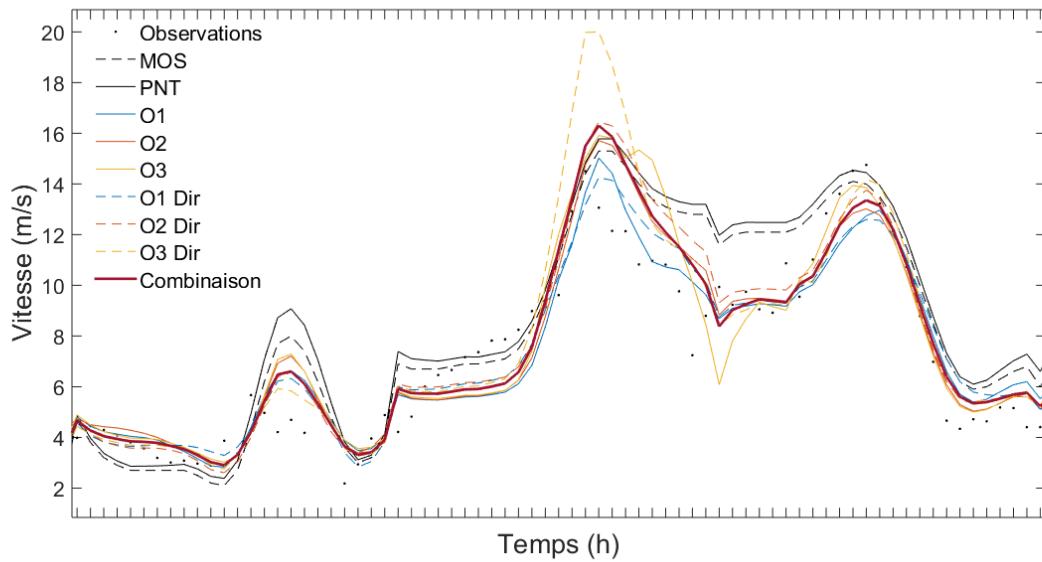


Figure D.2 Combinaison, exemple 2