



République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université Mohamed Boudiaf – M'sila
Faculté de Technologie
Département d'électronique

Thèse

Présentée pour l'obtention du diplôme de :
Doctorat en Sciences en Électronique

TECHNIQUES DE MODÉLISATION AVANCÉES POUR L'ANALYSE DES SIGNAUX D'ÉNERGIES RENOUVELABLES

Par

MEZAACHE Hatem

Ingénieur d'état et Magister en Électronique

Soutenue publiquement le : 07/01/2026 devant le jury composé de :

M. MEZACHE Amar	Professeur	Université M'sila	Président
M. BOUZGOU Hassen	Professeur	Université Batna 2	Rapporteur
M. RAYMOND Christian	Professeur	INSA Rennes, France	Co-rapporteur
M. CHOUDER Aissa	Professeur	Université M'sila	Examineur
M. GAMA Amor	Directeur de recherche	URAER-CDER Ghardaia	Examineur
M. ASSAS Ouarda	Professeur	Université Batna 2	Invitée

JANVIER 2026

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

DÉDICACE

À la mémoire de mes très, très, très chères mère et grand-mère.

À la mémoire de mon très cher beau-père et de ma très chère belle-mère.

À ma femme, pour son soutien, sa patience et ses encouragements constants dans les moments de doute.

À mes enfants, pour leur amour et la joie qu'ils m'apportent chaque jour, source précieuse de motivation et de courage.

À mon très cher père et à mes chers frères.

À toute ma famille.

À tous mes amis.

Et à ma belle aimée,

l'Algérie.

Hatem

REMERCIEMENTS

En premier lieu, je voudrais exprimer ma profonde gratitude et mes remerciements à **ALLAH**, qui m'a accordé la santé et le bien-être tout au long de ce parcours doctoral, ainsi que la force et la persévérance nécessaires pour mener à bien ce travail de recherche.

Je tiens à remercier aussi mon directeur de recherche, le Professeur **Hassen BOUZGOU**, pour sa rigueur scientifique, ses conseils avisés, ainsi que pour la confiance et la liberté qu'il m'a accordées tout au long de ce parcours. Sa disponibilité et son exigence ont été déterminantes dans l'aboutissement de ce travail. Je souhaite également exprimer mes remerciements chaleureux à mon co-rapporteur, le Professeur **Christian RAYMOND**, pour son accueil et ses précieux conseils au cours de mon premier stage.

Je tiens à exprimer ma profonde gratitude aux membres du jury qui ont accepté d'évaluer ce travail de recherche, en l'occurrence le Professeur Amar MEZACHE, le Professeur Aissa CHOUDER, le Professeur Amor GAMA et le Professeur Houcine OUDIRA. Je remercie également le Professeur Ouarda ASSAS pour sa présence en tant qu'invitée. Leur disponibilité, leur expertise scientifique ainsi que la pertinence de leurs observations et remarques critiques ont grandement contribué à l'enrichissement de ce travail.

Un grand merci s'adresse également à Madame le Docteur **Nahed ZEMOURI** pour son aide précieuse et ses conseils avisés tout au long de cette période de travail.

Mes remerciements vont aussi à mes collègues et amis des universités de **Mohamed Bou-diaf – M'sila** et de **Mostafa Ben Boulaid – Batna 2**. Leur soutien et leurs échanges constructifs ont enrichi mon expérience.

Enfin, je tiens à remercier toutes les personnes rencontrées au cours de ce travail, pour leur bienveillance, leur encouragement et leur aide, qui ont grandement contribué à la réalisation de cette thèse.

Hatem

ملخص

تمثل التنبؤات الدقيقة بسرعات الرياح تحديًا استراتيجيًا من أجل تحسين إنتاج الطاقة من المصادر الريحية وضمان استقرار شبكات الكهرباء الذكية. تتناول هذه الأطروحة هذا الإشكال من خلال اقتراح مقارنة مبتكرة تعتمد على تقنيات متقدمة في الذكاء الاصطناعي والتعلم الآلي، بهدف تحسين موثوقية التنبؤات بشكل ملموس. وتتمحور المساهمات الأساسية لهذا العمل حول محورين متكاملين. يركز المحور الأول على تقليص الأبعاد للبيانات المدخلة، وهي خطوة حاسمة لتقليل التكرار المعلوماتي وتعزيز كفاءة النماذج التنبؤية. تم في هذا السياق دراسة ثلاث تقنيات متقدمة ومقارنتها، وهي: تحليل المكونات الرئيسية (PCA)، وتحليل المكونات الرئيسية المعتمد على النواة (KPCA)، والمشققات التلقائية (Autoencoders - AE). وقد تم دمج هذه الأساليب ضمن بني الشبكات العصبية بهدف تقييم أثرها على أداء التنبؤ. أما المحور الثاني، فيتعلق بتفكيك سلاسل الزمن الخاصة بسرعات الرياح، بهدف استخراج المركبات المميزة للإشارات غير الثابتة وغير الخطية. وقد شملت الدراسة ثلاث مقاربات: التحليل التجريبي للنمط (EMD)، والتحليل التبايني للنمط (VMD)، بالإضافة إلى طريقة هجينة متقدمة وهي التحليل التجميعي الكامل المحسّن مع الضوضاء التكيفية (ICEEMDAN). تتيح هذه التقنيات تحويل البيانات الخام إلى أوضاع أكثر قابلية للفهم، مما يُيسّر عملية تعلم النماذج. تمت عملية التحقق من صحة المقاربات المقترحة باستخدام بيانات حقيقية تم جمعها من مواقع ريحية، وتم تقييم أدائها باستخدام مقاييس معيارية معروفة. أظهرت النتائج التجريبية المحققة تحسّنًا ملحوظًا في دقة التنبؤ مقارنة بالطرق التقليدية، مما يؤكد أهمية وفعالية الإسهامات المنهجية التي تقترحها هذه الأطروحة.

الكلمات المفتاحية: الطاقة المتجددة؛ التنبؤ؛ سرعة الرياح؛ السلاسل الزمنية؛ التعلم الآلي؛ التعلم التجميعي؛ التفكيك؛ الدمج التنبؤي؛ تقليص الأبعاد؛ الشبكات العصبية.

Accurate wind speed forecasting is a strategic challenge for optimizing wind energy production and ensuring the stability of smart power grids. This doctoral research addresses this issue by proposing an innovative approach based on advanced artificial intelligence and machine learning techniques, with the aim of significantly improving forecasting reliability. The main contributions of this work are structured around two complementary axes. The first focuses on dimensionality reduction of input data, a critical step to reduce informational redundancy and enhance the efficiency of predictive models. Three advanced techniques were explored and compared in this context : Principal Component Analysis (PCA), Kernel Principal Component Analysis (KPCA), and Autoencoders (AE). These methods were integrated into neural network architectures to assess their impact on predictive performance. The second axis concerns the decomposition of wind speed time series, aiming to isolate the key components of non-stationary and nonlinear signals. Three approaches were investigated : Empirical Mode Decomposition (EMD), Variational Mode Decomposition (VMD), and an advanced hybrid method, Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (ICEEMDAN). These techniques enable the transformation of raw data into more interpretable modes, thereby facilitating model learning. The proposed approaches were validated using real-world data, and evaluated through standard performance metrics. The experimental results demonstrate a significant improvement in forecasting accuracy compared to traditional methods, thereby confirming the methodological relevance and effectiveness of the proposed contributions.

Keywords : *Renewable energy; prediction; wind speed; time series; machine learning; ensemble learning; decomposition; prediction; combination; dimensionality reduction, neural networks.*

La prédiction précise de la vitesse du vent représente un enjeu stratégique pour l'optimisation de la production d'énergie éolienne et la stabilité des réseaux électriques intelligents. Cette thèse s'inscrit dans cette problématique et propose une démarche innovante reposant sur des techniques avancées d'intelligence artificielle et d'apprentissage automatique, dans le but d'améliorer significativement la fiabilité des prévisions. Les contributions principales de ce travail s'articulent autour de deux axes complémentaires. Le premier concerne la réduction de la dimensionnalité des données d'entrée, étape cruciale pour atténuer la redondance informationnelle et accroître l'efficacité des modèles prédictifs. Trois méthodes avancées ont été explorées et comparées dans ce cadre : l'Analyse en Composantes Principales (PCA), l'Analyse en Composantes Principales à Noyau (KPCA), et les Auto-encodeurs (AE). Ces techniques ont été intégrées à des architectures de réseaux neuronaux afin d'évaluer leur contribution à l'amélioration des performances de prédiction. Le second axe porte sur la décomposition des séries temporelles de vitesse du vent, visant à isoler les composantes caractéristiques des signaux non stationnaires et non linéaires. Trois approches ont été étudiées : l'Empirical Mode Decomposition (EMD), la Variational Mode Decomposition (VMD), ainsi qu'une méthode hybride avancée, l'Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (ICEEMDAN). Ces méthodes permettent de structurer les données en modes plus interprétables, facilitant ainsi l'apprentissage des modèles. L'ensemble des approches proposées a été évalué à partir de données réelles, en s'appuyant sur des métriques standards. Les résultats expérimentaux obtenus attestent d'une amélioration notable des performances prédictives par rapport aux techniques classiques, confirmant ainsi la pertinence des contributions méthodologiques de cette recherche.

Mots-clés : *Énergie renouvelable ; Prédiction ; Vitesse du vent ; séries temporelles ; Apprentissage machine ; Apprentissage d'ensembles ; décomposition ; Combinaison des prédictions ; réduction de dimensionnalité ; Réseaux de neurones.*

TABLE DES MATIÈRES

Dédicace	ii
Remerciements	iii
Résumé en Arabe	iv
Abstract	v
Résumé	vi
Liste des figures	xiii
Liste des tableaux	xiv
Liste des acronymes	xv
Liste des symboles	xvii
1 Introduction Générale	1
1.1 Contexte scientifique et technologique	1
1.2 Problématique de recherche	2
1.3 Objectifs généraux de la thèse	2
1.4 Apports et contributions scientifiques	3
1.5 Organisation de la thèse	3
2 Énergie éolienne : contexte et fondamentaux	4
2.1 Introduction	5
2.2 Historique de l'énergie éolienne	5
2.3 Développement de l'énergie éolienne dans le monde	9
2.4 L'énergie éolienne mondiale en chiffres	10
2.5 L'énergie éolienne en Algérie	12
2.6 Principes fondamentaux de l'énergie éolienne	13
2.6.1 Origine du vent	13
2.6.2 Classification des vents	13
2.6.2.1 Vent primaire ou vent planétaire	14
2.6.2.2 Vent secondaire ou vent périodique	14
2.6.2.3 Vent tertiaire ou vent local	14
2.6.3 Types des vents	14
2.6.3.1 Les Alizés	14
2.6.3.2 Les vents d'ouest	14
2.6.3.3 Vents d'est polaires	14
2.6.3.4 Les vents de Mousson	15
2.6.3.5 Brise de terre et brise de mer	15

2.6.3.6	Brise de montagne et brise de vallée	15
2.6.3.7	Vents locaux	15
2.6.4	Caractéristiques du vent	16
2.6.4.1	Vitesse du vent	16
2.6.4.2	Direction du vent	16
2.6.5	Mesure et caractérisation du vent	16
2.6.5.1	Anémomètres	16
2.6.5.2	Girouettes	17
2.6.5.3	Manche à air	17
2.6.5.4	Lidar	17
2.6.6	Définition de l'énergie éolienne	18
2.6.7	Définition d'une éolienne	18
2.6.8	Les composants principaux d'une éolienne	19
2.6.8.1	La fondation	19
2.6.8.2	La tour	20
2.6.8.3	Le rotor et le moyeu	21
2.6.8.4	La nacelle	21
2.6.9	Principe de fonctionnement d'une éolienne	22
2.6.10	Classification des éoliennes	23
2.6.10.1	Alignement de l'axe de rotation	24
2.6.10.2	Emplacement d'installation	26
2.6.10.3	Type de génératrice électrique	27
2.6.10.4	Vitesse de fonctionnement	29
2.6.10.5	Taille et puissance	29
2.7	Quelques équations fondamentales de l'énergie éolienne	29
2.8	Avantages et inconvénients de l'énergie éolienne	31
2.8.1	Avantages	32
2.8.2	Inconvénients	32
2.9	Conclusion	33
3	État de l'art sur la prédiction de la vitesse du vent	34
3.1	Introduction	34
3.2	Classification des méthodes de prédiction de la vitesse du vent	35
3.2.1	Échelle temporelle	35
3.2.2	Objectif de prédiction	36
3.2.3	Nature ou type du modèle	37
3.2.3.1	Modèles déterministes	37
3.2.3.2	Modèles probabilistes	37
3.2.4	Théorie de modélisation	37
3.2.4.1	Modèles physiques	37
3.2.4.2	Modèles statistiques traditionnels	38
3.2.4.3	Modèles basés sur l'intelligence artificielle	38
3.2.4.4	Modèles hybrides	39
3.3	Sources et techniques de prétraitement des données	39
3.3.1	Sources de données	40
3.3.2	Techniques de prétraitement de données	40
3.3.2.1	Techniques basées sur la réduction de la dimensionnalité	40
3.3.2.2	Techniques basées sur la décomposition des séries temporelles	41

3.3.2.3	Techniques basées sur le débruitage de données	41
3.4	Évaluation des performances des modèles de prédiction	42
3.5	Approches de prédiction de la vitesse du vent	42
3.5.1	Prédiction à très court terme	42
3.5.2	Prédiction à court terme	43
3.5.3	Prédiction à moyen terme	43
3.5.4	Prédiction à long terme	44
3.6	Conclusion	45
4	Réduction de dimensionnalité pour la prédiction de la vitesse du vent	46
4.1	Introduction	46
4.2	Techniques de réduction de la dimensionnalité	47
4.2.1	Analyse en composantes principales	47
4.2.2	Analyse en composantes principales à noyau	49
4.2.3	Auto-encodeurs	50
4.3	Réseaux de neurones artificiels pour la prédiction de la vitesse du vent	52
4.3.1	Machines à apprentissage extrême	52
4.3.2	Réseaux neuronaux récurrents : l'approche Elman	54
4.4	Études de cas et résultats expérimentaux	54
4.4.1	Séries temporelles	55
4.4.2	Ensembles de données utilisés	55
4.4.3	Résultats expérimentaux	57
4.4.3.1	Présentation, analyse et discussion des résultats de la première approche	57
4.4.3.2	Présentation, analyse et discussion des résultats de la deuxième approche	58
4.5	Conclusion	61
5	Méthodes de décomposition pour la prédiction de la vitesse du vent	62
5.1	Introduction	63
5.2	Méthodes de décomposition des séries temporelles pour la prédiction de la vitesse du vent	63
5.2.1	Décomposition modale empirique	63
5.2.2	Décomposition modale variationnelle	64
5.2.3	Décomposition en mode empirique d'ensemble complet améliorée avec bruit adaptatif	67
5.3	Sélection des caractéristiques des modes décomposés	68
5.3.1	Entropie d'échantillon pour la sélection des modes	68
5.4	Modèles de prédiction	68
5.4.1	Modèles d'apprentissage automatique	68
5.4.1.1	Réseaux de neurones perceptron multicouches	68
5.4.1.2	Réseaux de neurones à fonction de base radiale	69
5.4.2	Modèles d'apprentissage profond	70
5.4.2.1	Réseaux de neurones récurrents à mémoire long court terme	70
5.4.2.2	Réseaux de neurones récurrents à mémoire long court terme bidirectionnels	72
5.4.2.3	Réseaux de neurones à unités récurrentes fermées	73
5.4.2.4	Réseaux neuronaux récurrents bidirectionnels à portes	75

5.5	Stratégies de fusion des prédictions	76
5.5.1	Scénarios classiques	76
5.5.1.1	Moyenne simple	76
5.5.1.2	Surperformance	76
5.5.1.3	Fusion basée sur l'erreur	77
5.5.1.4	Régression des moindres carrés	77
5.5.1.5	Pondération différentielle	78
5.5.1.6	Technique basée sur la classification	78
5.6	Expérimentation et évaluation des performances	79
5.6.1	Description des données utilisés	79
5.6.1.1	Jeu de données # 1	79
5.6.1.2	Jeu de données # 2	79
5.7	Mesures de performance	80
5.8	Résultats Expérimentaux	81
5.8.1	Modèles hybrides : EMD/VMD et RNA	81
5.8.1.1	Expériences de prédiction	81
5.8.1.2	Résultats des différents modèles et analyse	82
5.8.1.3	Résultats obtenus avec le premier groupe de modèles hybrides	83
5.8.1.4	Résultats obtenus avec le deuxième groupe de modèles hybrides	85
5.8.1.5	Résultats obtenus avec le troisième groupe de modèles hybrides	88
5.8.2	Modèles basée sur la décomposition ICEEMDAN, entropie de l'échantillon et apprentissage profond	90
5.8.2.1	Expériences de prédiction	94
5.8.2.2	Résultats des différents modèles et discussion	94
5.8.2.3	Résultats obtenus avec la première approche	95
5.8.2.4	Résultats obtenus avec la deuxième approche	96
5.8.2.5	Comparaison avec les méthodes existantes dans la littérature	98
5.9	Conclusion	104
6	Conclusions générales et perspectives	105
6.1	Synthèse des travaux et portée scientifique	105
6.2	Contributions majeures de la thèse	106
6.3	Perspectives de recherche	106
	Liste des publications	108
	Bibliographie	122

LISTE DES FIGURES

2.1	Anciens moulins à vent.	6
2.2	Moulin à poteau construit au XVIIIe siècle en France.	6
2.3	Exemples de moulins à vent en bois en Europe.	7
2.4	Eolienne de Charles Brush en 1888.	8
2.5	Prototype de l'éolienne de Poul La Cour.	8
2.6	Éolienne d'Adrar, Algérie.	9
2.7	Atlas mondial des moyennes annuelles de vitesses de vent (en m/s, à 100 m).	10
2.8	Capacité éolienne cumulée installée dans le monde de 2013 à 2022.	11
2.9	Capacité installée cumulée d'énergie éolienne en MW des dix principaux pays producteurs en 2022.	12
2.10	Ferme éolienne Kabertène (Adrar-Algérie).	13
2.11	Configuration globale des vents : vents polaires d'est, vents d'ouest et alizés.	15
2.12	Quelques modèles d'anémomètre.	16
2.13	Modèles de girouettes.	17
2.14	Manche à air et valeurs approximatives de la vitesse du vent.	17
2.15	Lidar.	18
2.16	Principe de conversion de l'énergie cinétique du vent.	19
2.17	Les composants principaux d'une éolienne à axe horizontal.	19
2.18	Vue d'une fondation en béton armé.	20
2.19	Tour d'une éolienne.	20
2.20	Moyeu et pâles.	21
2.21	Classification des éoliennes.	23
2.22	Éolienne à axe horizontal.	24
2.23	Éolienne à axe horizontal en amont et en aval.	25
2.24	Éolienne à axe vertical.	26
2.25	Parc éolien terrestre en zone rurale et désertique.	27
2.26	Parc éolien maritime.	28
2.27	Principaux types de génératrices utilisées dans les SCEE.	28
2.28	Évolution de la taille (hauteur du mat et diamètre du rotor) et de la puissance nominale des éoliennes.	30
3.1	Cadre taxonomique pour la prédiction de la vitesse du vent.	36
4.1	Architecture d'un auto-encodeur.	50
4.2	Architecture de base d'un auto-encodeur.	51

4.3	Architecture du réseau ELM.	53
4.4	Architecture du réseau ENN.	55
4.5	Évolution temporelle des données du site Colorado.	56
4.6	Évolution temporelle des données du site Connecticut.	56
4.7	Courbes d'erreur de validation pour les sites Colorado et Connecticut.	58
5.1	Architecture du réseau neuronal MLP.	69
5.2	Architecture du réseau neuronal RBF.	70
5.3	Structure de base du modèle LSTM-RNN.	71
5.4	Architecture du modèle BiLSTM.	72
5.5	Architecture du modèle GRU.	74
5.6	Architecture du modèle BiGRU-NN.	76
5.7	Organigramme de la technique basée sur la classification.	79
5.8	Schéma général de l'approche hybride proposée.	82
5.9	Organigramme du processus de prédiction hybride.	83
5.10	Les enregistrements complets de la vitesse du vent pour les sept sites de test.	85
5.11	Vitesse du vent mesurée et prédite du site de test — Annaba — obtenue avec les modèles RNA uniquement et sans décomposition.	86
5.12	Vitesse du vent mesurée et prédite du site de test — Annaba — obtenue avec les modèles RNA combinés et sans décomposition.	86
5.13	Les formes d'onde des composantes EMD et le terme résiduel du site de test — Chlef —.	88
5.14	Vitesse du vent mesurée et prédite du site de test — Chlef — obtenue avec les modèles RNA après la décomposition EMD.	90
5.15	Vitesse du vent mesurée et prédite du site de test — Chlef — obtenue avec la combinaison des modèles RNA après la décomposition EMD.	91
5.16	Les formes d'onde des composantes VMD et le terme résiduel du site de test — Adrar —.	91
5.17	Vitesse du vent mesurée et prédite du site de test — Adrar — obtenue avec les modèles RNA après la décomposition VMD.	92
5.18	Vitesse du vent mesurée et prédite du site de test — Adrar — obtenue avec la combinaison des modèles RNA après la décomposition VMD.	92
5.19	Diagramme de Taylor de la vitesse du vent mesurée et prédite du site de test — Annaba — obtenue avec les modèles RNA combinés et sans décomposition.	93
5.20	Diagramme de Taylor de la vitesse du vent mesurée et prédite du site de test — Chlef — obtenue avec la combinaison des modèles RNA après la décomposition EMD.	93
5.21	Diagramme de Taylor de la vitesse du vent mesurée et prédite du site de test — Adrar — obtenue avec la combinaison des modèles RNA après la décomposition VMD.	94
5.22	Organigramme de l'approche ICEEMDAN-SE-DL proposée pour la prédiction de la vitesse du vent.	95
5.23	Une petite fenêtre des séries temporelles originales de la vitesse du vent des deux sites de test.	96
5.24	Une petite fenêtre des séries temporelles de la vitesse du vent provenant des deux sites de test après normalisation.	98
5.25	Vitesse du vent mesurée et prédite du site de test — Site #1 — sans décomposition, utilisant les modèles d'apprentissage profond combinés.	99

5.26	Vitesse du vent mesurée et prédite du site de test — Site #2 — sans décomposition, utilisant les modèles d'apprentissage profond combinés.	100
5.27	Formes d'onde des composantes ICEEMDAN de la série temporelle de la vitesse du vent du site de test — Site #1.	100
5.28	Formes d'onde des composantes ICEEMDAN de la série temporelle de la vitesse du vent du site de test — Site #2.	101
5.29	Vitesse du vent mesurée et prédite du site de test — Site #1 — avec décomposition, utilisant les modèles d'apprentissage profond combinés selon la méthode de classification (<i>Class</i>).	101
5.30	Vitesse du vent mesurée et prédite du site de test — Site #2 — avec décomposition, utilisant les modèles d'apprentissage profond combinés selon la méthode de classification (<i>Class</i>).	102
5.31	Histogramme des erreurs RMSE pour différentes approches pour le site de test — Site #1.	102
5.32	Histogramme des erreurs RMSE pour différentes approches pour le site de test — Site #2.	103

LISTE DES TABLEAUX

3.1	Classification des horizons de prédiction de la vitesse du vent.	36
4.1	Détails techniques des deux sites.	56
4.2	Résultats des quatre scénarios pour le site Colorado.	58
4.3	Résultats des quatre scénarios pour le site Connecticut.	59
4.4	Résultats obtenus sur le site Colorado avec l'approche AE-ELM.	60
4.5	Résultats obtenus sur le site Colorado avec l'approche AE-ENN.	60
4.6	Résultats obtenus sur le site Connecticut avec l'approche AE-ELM.	60
4.7	Résultats obtenus sur le site Connecticut avec l'approche AE-ENN.	60
5.1	Caractéristiques géographiques des sept sites étudiés.	80
5.2	Caractéristiques statistiques des sites étudiés.	80
5.3	Caractéristiques géographiques des sites de test #1 et #2.	80
5.4	Caractéristiques statistiques des deux sites #1 et #2.	81
5.5	Résultats de prédiction obtenus utilisant le premier groupe de modèles hybrides.	84
5.6	Résultats de prédiction obtenus en utilisant le deuxième groupe de modèles hybrides.	87
5.7	Résultats de prédiction obtenus en utilisant le troisième groupe de modèles hybrides.	89
5.8	Détails des métriques d'évaluation des performances des modèles sans décomposition.	97
5.9	Entropie d'échantillon des différentes composantes IMF pour les deux sites.	97
5.10	Détails des métriques d'évaluation des performances des modèles avec décomposition.	97
5.11	Comparaison avec certaines méthodes existantes dans la littérature.	103

LISTE DES ACRONYMES

INRA	Institut National de Recherche Agronomique
GWEC	Global Wind Energy Council
WECS	Wind Energy Conversion System
AC	Alternating Current
DC	Direct Current
HAWT	Horizontal Axis Wind Turbine
VAWT	Vertical Axis Wind Turbine
MS	Machines Synchrones
MAS	Machines Asynchrones
SCEE	Systèmes de Conversion d'Énergie Éolienne
MASCE	Machines Asynchrones à Cage d'Écureuil
MASDA	Machines Asynchrones à Double Alimentation
RVP	Rapport de Vitesse de Pointe
NWP	Numerical Weather Prediction
WRF	Weather Research and Forecasting
AR	Autoregressive
ARIMA	Autoregressive Integrated Moving Average
SARIMA	Seasonal Autoregressive Integrated Moving Average
IA	Intelligence Artificielle
AA	Apprentissage Automatique
ML	Machine Learning
AP	Apprentissage Profond
DL	Deep Learning
RF	Random Forests
SVM	Support Vector Machines
SVR	Support Vector Regression
RNA	Réseaux de Neurones Artificiels
BiLSTM	Bidirectional Long Short-Term Memory
CNN	Convolutional Neural Networks
GRU	Gated Recurrent Unit
GA	Genetic Algorithm
PSO	Particle Swarm Optimization
ACF	AutoCorrelation Function
CMI	Conditional Mutual Information

PCA	Principal Components Analysis
KPCA	Kernel Principal Components Analysis
DWT	Discrete Wavelet Transform
EWT	Empirical Wavelet Transform
EMD	Empirical Mode Decomposition
EEMD	Ensemble Empirical Mode Decomposition
FEEMD	Fast Ensemble EMD
CEEMDAN	Complete Ensemble EMD with Adaptive Noise
VMD	Variational Mode Decomposition
SSA	Singular Spectrum Analysis
WTD	Wavelet Thresholding Denoising
MAE	Mean Absolute Error
RMSE	Root Mean Square Error
NMSE	Normalized Mean Square Error
SMAPE	Symmetric Mean Absolute Percentage Error
NREL	National Renewable Energy Laboratory
AE	AutoEncoder
ELM	Extreme Learning Machine
SLFNN	Single-Layer Feedforward Neural Network
ENN	Elman Neural Network
RNN	Recurrent Neural Network
GNN	Graph Neural Network
LIDAR	Light Detection and Ranging
WT	Wavelet Transform
IMF	Intrinsic Mode Function
ADMM	Alternating Direction of Multipliers Method
ICEEMDAN	Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise
SE	Sample Entropy
MLPNN	Multilayer Perceptron Neural Network
ANN	Artificial Neural Network
RBFNN	Radial Basis Function Neural Network
LSTM	Long Short-Term Memory
BiGRU	Bidirectional Gated Recurrent Unit
SSE	Sum of Squared Errors
MABE	Mean Absolute Bias Error
MAEP	Mean Absolute Error in Percentage
R^2	Coefficient de Détermination
SA	Simple Average
OP	Outperformance
EB	Error-Based
LSR	Least-Squares Regression
DW	Differential Weighting
CB	Classification-based
CRMSE	Centered Root Mean Square Error
RMSD	Root Mean Square Deviation

LISTE DES SYMBOLES

E_c	Énergie cinétique du vent
m	Masse du volume d'air
v	Vitesse du vent
S	Surface balayée par les pales d'une éolienne
r	Rayon du rotor de l'éolienne
P	Puissance cinétique du vent
ρ	Masse volumique de l'air
ω	Vitesse angulaire du rotor
R	Rayon du rotor
C_P	Coefficient de puissance
$P_{\text{élec}}$	Puissance électrique générée par l'éolienne
C	Matrice de covariance
β	Vecteur propre
λ	Valeur propre de la matrice C
λ_n	$n^{\text{ième}}$ valeur propre de la matrice C
w_1	Matrice des poids (entrée \rightarrow cachée)
w_2	Matrice des poids (cachée \rightarrow sortie)
z	Sortie de l'auto-encodeur ou vecteur reconstruit
g	Fonction d'activation sigmoïde
$S(t)$	Série temporelle d'origine
$E_{\text{up}}(t)$	Enveloppe supérieure de la série
$E_{\text{down}}(t)$	Enveloppe inférieure de la série
$m_i(t)$	Enveloppe moyenne de la série
$H_i(t)$	Détails locaux
$C_i(t)$	IMF (Fonction de Mode Intrinsèque)
$R_i(t)$	Résidus
K	Nombre de modes
$u_k(t)$	Modes variationnels
$\omega_k(t)$	Fréquence centrale
$A_k(t)$	Amplitude instantanée de $u_k(t)$
$\phi_k(t)$	Phase instantanée croissante de $u_k(t)$
L_2	Norme L_2
∂_t	Dérivée partielle par rapport au temps
$\delta(t)$	Distribution de Dirac

α	Facteur de pénalité quadratique
$\lambda(t)$	Multiplicateur de Lagrange
$\langle \cdot, \cdot \rangle$	Produit scalaire
$\hat{S}(\omega)$	Transformée de Fourier de $S(t)$
$\hat{u}_i(\omega)$	Transformée de Fourier de $u_i(t)$
$\hat{\lambda}(\omega)$	Transformée de Fourier de $\lambda(t)$
$\hat{u}_k^{(n+1)}(\omega)$	Transformée de Fourier de $u_k^{(n+1)}(t)$
τ	Pas de mise à jour
n	Nombre d'itérations
ε	Tolérance de convergence
y	Signal original
$E_1[\omega^i]$	Bruit spécial
y^i	$i^{\text{ième}}$ bruit blanc ajouté
β_0	Rapport signal/bruit
R_1	Résidu de la première décomposition
$M[\cdot]$	Opérateur de moyenne locale
\tilde{r}_2	Deuxième IMF
X_i	Vecteur
$D_m(X_i, X_j)$	Distance entre les vecteurs X_i et X_j
$B^m(r)$	Moyenne des vecteurs
$SE(m, r, N)$	Entropie d'échantillon
m	Dimension d'immersion
r	Seuil de condition
N	Nombre total de points dans la série temporelle
S	Vecteur d'entrée
w	Poids entre couches cachée et sortie
b_0	Terme de biais
$h_j(S)$	Fonction gaussienne
C_j	Centres des fonctions gaussiennes
σ_j	Variances des fonctions gaussiennes
f_t	Porte d'oubli (LSTM)
δ	Fonction d'activation sigmoïde
X_f	Poids entre portes oubli et entrée
h_{t-1}	État caché précédent
I_t	Entrée actuelle du LSTM
β_f	Biais de la porte d'oubli
i_t	Porte d'entrée
\tilde{C}_t	État candidat de la cellule
C_t	État actuel de la cellule
C_{t-1}	État précédent de la cellule
X_i	Poids de la porte d'entrée
β_i	Biais de la porte d'entrée
X_C	Poids pour l'état candidat
β_C	Biais pour l'état candidat
h_t	État caché actuel
G	Fonction tanh (hyperbolique)
o_t	Porte de sortie

X_o	Poids de la porte de sortie
β_o	Biais de la porte de sortie
h_t^{\rightarrow}	État caché direction avant
h_t^{\leftarrow}	État caché direction arrière
x_t	Entrée au temps t
h_{t-1}^{\rightarrow}	État caché passé (avant)
h_{t+1}^{\leftarrow}	État caché futur (arrière)
W^{\rightarrow}	Poids direction avant
W^{\leftarrow}	Poids direction arrière
b^{\rightarrow}	Biais direction avant
b^{\leftarrow}	Biais direction arrière
h_t	État bidirectionnel à t
z_t	Porte de mise à jour
W_z	Poids de la porte de mise à jour
b_z	Biais de la porte de mise à jour
r_t	Porte de réinitialisation
W_r	Poids de la porte de réinitialisation
b_r	Biais de la porte de réinitialisation
\tilde{h}_t	État caché candidat
h_t^f	État caché avant (forward)
h_t^b	État caché arrière (backward)
\tilde{Y}	Valeur prédite
Y	Valeur observée
$\hat{P}(Z)$	Prédicteur optimal
$f_i(S_j)$	Prédiction du modèle i pour S_j
y_j	Valeur réelle
$\mathbf{var}(y_i)$	Variance des valeurs mesurées

Sommaire du chapitre

1.1 Contexte scientifique et technologique	1
1.2 Problématique de recherche	2
1.3 Objectifs généraux de la thèse	2
1.4 Apports et contributions scientifiques	3
1.5 Organisation de la thèse	3

1.1 Contexte scientifique et technologique

L'énergie éolienne, utilisée sous diverses formes depuis l'Antiquité, a connu une évolution technologique majeure au cours des dernières décennies, s'imposant aujourd'hui comme une solution parmi les plus prometteuses pour répondre aux défis énergétiques mondiaux. Dans un contexte de transition énergétique, face aux crises environnementales et à l'épuisement des ressources fossiles, les énergies renouvelables, dont l'éolien, jouent un rôle central en permettant de réduire de manière significative les émissions de gaz à effet de serre. Cette source d'énergie exploite le vent, un phénomène naturel omniprésent et constamment renouvelé, pour produire de l'électricité de manière propre et durable. Le vent, généré par la chaleur solaire et les mouvements d'air dans l'atmosphère, est influencé par divers facteurs géographiques, éléments essentiels pour évaluer le potentiel de l'énergie éolienne [1].

Au cours du XXe siècle, l'essor de l'énergie éolienne a été marqué par des progrès technologiques significatifs, notamment dans les matériaux de construction des éoliennes et la conception aérodynamique des turbines. L'optimisation des composants clés tels que les rotors, les nacelles et les systèmes de contrôle a permis d'améliorer continuellement l'efficacité des processus de conversion énergétique [2]. Les éoliennes modernes, qu'elles soient terrestres ou offshore, ont vu leurs coûts de production diminuer substantiellement grâce à des innovations constantes en matière de conception et de fabrication. En conséquence, la capacité de production éolienne a atteint des niveaux records, avec des prévisions indiquant que l'énergie éolienne pourrait jouer un rôle crucial dans la satisfaction de la demande énergétique mondiale au cours des prochaines décennies [3].

1.2 Problématique de recherche

La gestion efficace de l'énergie éolienne constitue aujourd'hui un enjeu majeur dans le contexte de la transition énergétique. Cette source d'énergie, bien que renouvelable et propre, demeure intrinsèquement variable, en raison de la nature fluctuante du vent. Cette variabilité complique l'équilibrage entre production et demande, rendant indispensable une anticipation fiable des ressources disponibles. L'un des défis fondamentaux réside ainsi dans la prédiction précise de la vitesse du vent, paramètre déterminant pour l'optimisation de la production, la planification des opérations de maintenance, la réduction des pertes d'énergie, ainsi que l'intégration harmonieuse de l'éolien au réseau électrique [4]. Par ailleurs, l'évaluation préalable du potentiel éolien d'un site est une étape critique dans tout projet de déploiement, puisqu'elle conditionne la faisabilité, la rentabilité et les performances attendues des installations. Une caractérisation fine et localisée du gisement éolien est donc indispensable pour garantir un dimensionnement optimal des infrastructures et une exploitation efficiente des ressources disponibles.

C'est dans cette perspective que s'inscrit la présente thèse, qui vise à améliorer les techniques de prédiction de la vitesse du vent. En s'appuyant sur des approches avancées, cette recherche ambitionne de renforcer la fiabilité des prévisions et, par conséquent, d'optimiser le fonctionnement global des systèmes de production d'énergie éolienne [5].

1.3 Objectifs généraux de la thèse

L'objectif principal de cette thèse est de proposer et de développer des méthodologies avancées dédiées à la prédiction de la vitesse du vent. Ce travail de recherche s'articule autour des objectifs spécifiques suivants :

- Amélioration de la précision des modèles de prédiction par une analyse approfondie et comparative de diverses techniques existantes de la littérature, incluant des approches d'apprentissage automatique et profond, visant à identifier les méthodes les plus efficaces pour accroître la fiabilité et la justesse des prédictions de la vitesse du vent ;
- Étude de l'impact de la réduction de la dimensionnalité des données, en mettant l'accent sur son rôle dans l'élimination des redondances, la mise en évidence des variables les plus influentes et l'amélioration de la performance globale des modèles prédictifs ;
- Proposition de plusieurs techniques avancées de décomposition des séries temporelles, essentielles pour isoler les composantes significatives du signal de la vitesse du vent. Cette approche permet une meilleure compréhension des dynamiques sous-jacentes et renforce la précision des modèles, condition clé pour une prédiction fiable des variations de la vitesse du vent ;
- Proposition de plusieurs techniques d'agrégation visant à combiner de manière optimale les différentes sorties issues de chaque composante spectrale obtenue par décomposition, afin d'améliorer la robustesse et la précision du modèle de prédiction ;
- Proposition de modèles hybrides de prédiction visant à combiner différentes techniques afin de surmonter les limitations des approches traditionnelles et d'améliorer la robustesse et la précision des prévisions.

1.4 Apports et contributions scientifiques

Cette thèse apporte des contributions scientifiques majeures à la recherche, en particulier dans le domaine de la prédiction de la vitesse du vent, avec pour objectif d'améliorer la fiabilité des prévisions et d'optimiser la production d'énergie éolienne. Ces contributions se déclinent comme suit :

1. Le développement de modèles hybrides innovants combinant des techniques d'apprentissage automatique et d'apprentissage profond, associés à des méthodes avancées de réduction de la dimensionnalité, d'agrégation et de décomposition des séries temporelles ;
2. L'amélioration des performances des systèmes de prédiction de la vitesse du vent, démontrée empiriquement à partir de données réelles collectées en Algérie ;
3. Une analyse approfondie des techniques de prétraitement des données, visant à renforcer la qualité des jeux de données et à garantir la fiabilité des prédictions sur différentes échelles temporelles.

Les résultats obtenus dans le cadre de cette thèse devraient contribuer de manière substantielle à accroître la compétitivité et l'efficacité de l'énergie éolienne, un secteur stratégique dans le contexte de la transition énergétique mondiale. En optimisant la précision des modèles de prédiction de la vitesse du vent, cette recherche permettrait non seulement de maximiser la production d'énergie éolienne, mais également de réduire les coûts liés à l'intégration de l'éolien dans les réseaux électriques. En outre, une gestion plus précise des ressources éoliennes et une meilleure anticipation des conditions climatiques permettront d'améliorer la fiabilité des systèmes de production d'énergie, facilitant ainsi leur intégration avec d'autres sources d'énergie renouvelables. Ces avancées pourraient accélérer l'adoption à grande échelle de l'énergie éolienne, rendant cette technologie plus rentable et durable à long terme, tout en soutenant les objectifs mondiaux de décarbonation et de réduction des émissions de gaz à effet de serre.

1.5 Organisation de la thèse

Cette thèse se compose de plusieurs chapitres, chacun abordant un aspect spécifique de l'énergie éolienne et de la prédiction de la vitesse du vent. Le chapitre 2 offre un aperçu général de l'énergie éolienne, retraçant son évolution historique, son développement mondial, les principes de conversion de l'énergie du vent en électricité, ainsi qu'une classification des éoliennes et des vents. Le chapitre 3 offre une synthèse de l'état de l'art des principales méthodes de prédiction de la vitesse du vent, incluant les modèles physiques, statistiques et les techniques d'intelligence artificielle. Le chapitre 4 explore les méthodes de réduction de dimensionnalité appliquées à cette prédiction. Le chapitre 5 présente des modèles hybrides combinant décomposition des séries temporelles et apprentissage profond, analysant et discutant leurs résultats. Enfin, La conclusion générale 6 propose une synthèse rigoureuse des principaux résultats, souligne les contributions scientifiques essentielles de cette thèse et esquisse des perspectives de recherche prometteuses dans les divers champs étudiés.

CHAPITRE 2

ÉNERGIE ÉOLIENNE : CONTEXTE ET FONDAMENTAUX

Sommaire du chapitre

2.1	Introduction	5
2.2	Historique de l'énergie éolienne	5
2.3	Développement de l'énergie éolienne dans le monde	9
2.4	L'énergie éolienne mondiale en chiffres	10
2.5	L'énergie éolienne en Algérie	12
2.6	Principes fondamentaux de l'énergie éolienne	13
2.6.1	Origine du vent	13
2.6.2	Classification des vents	13
2.6.3	Types des vents	14
2.6.4	Caractéristiques du vent	16
2.6.5	Mesure et caractérisation du vent	16
2.6.6	Définition de l'énergie éolienne	18
2.6.7	Définition d'une éolienne	18
2.6.8	Les composants principaux d'une éolienne	19
2.6.9	Principe de fonctionnement d'une éolienne	22
2.6.10	Classification des éoliennes	23
2.7	Quelques équations fondamentales de l'énergie éolienne	29
2.8	Avantages et inconvénients de l'énergie éolienne	31
2.8.1	Avantages	32
2.8.2	Inconvénients	32
2.9	Conclusion	33

2.1 Introduction

L'énergie éolienne, également appelée énergie du vent, constitue l'une des plus anciennes formes d'énergie renouvelable exploitées par l'humanité. Elle occupe désormais une position centrale dans les stratégies énergétiques mondiales et joue un rôle significatif dans la transition vers une économie durable et faiblement émettrice de gaz à effet de serre. Depuis les premières utilisations des moulins à vent jusqu'à l'émergence des parcs éoliens modernes, cette source d'énergie a connu une évolution remarquable, tirant parti des progrès technologiques et d'une sensibilisation accrue aux enjeux environnementaux. Dans un contexte caractérisé par la lutte contre le réchauffement climatique et la quête de solutions énergétiques durables, l'énergie éolienne se présente comme une alternative incontournable aux combustibles fossiles.

Ce chapitre est dédié à la présentation des principes généraux et fondamentaux associés à l'énergie éolienne. Il commence par un aperçu historique de cette forme d'énergie, retraçant son évolution depuis les premiers moulins à vent jusqu'aux turbines éoliennes modernes. Nous aborderons dans un premier temps le développement de cette énergie à l'échelle mondiale, suivi d'une présentation des statistiques clés illustrant l'impact et la croissance de l'énergie éolienne à l'échelle mondiale. Il est également essentiel d'examiner les principes fondamentaux de cette source d'énergie, notamment l'origine du vent, ses différentes classifications et les types de vents ainsi que leurs caractéristiques spécifiques. Ensuite, nous détaillerons les instruments utilisés pour mesurer la vitesse du vent et ses caractéristiques, ainsi que la définition précise de l'énergie éolienne et des technologies associées, incluant les composants principaux des éoliennes, leur structure et leur principe de fonctionnement. Ce chapitre se conclura par une présentation des avantages et des inconvénients de l'énergie éolienne.

2.2 Historique de l'énergie éolienne

Depuis des millénaires, le vent, aux côtés de l'eau, représente l'une des premières sources d'énergie exploitées par l'homme. L'énergie éolienne possède une histoire longue et riche. Dès l'antiquité, l'homme l'a utilisée comme source d'énergie, d'abord pour la propulsion des navires et des bateaux à voile, une pratique datant d'environ 3000 ans avant la naissance du prophète Aïssa, que la paix soit sur lui. Cependant, l'homme ne s'est pas limité à ces utilisations, il a également cherché à inventer et à développer d'autres machines et outils permettant de tirer parti de l'énergie éolienne pour faciliter la vie quotidienne et le travail. L'invention des moulins à vent constitue l'un des exemples les plus significatifs de cette évolution. Ces moulins, de conception simple, avec des ailes verticales et un mécanisme de rotation rudimentaire, ont été utilisés par les Perses, les Pharaons égyptiens et les Chinois pour des applications mécaniques, telles que le pompage de l'eau, principalement pour l'irrigation des terres agricoles, la mouture des grains et la presse à huile. La figure 2.1 présente quelques exemples de designs construits en Iran et en Chine [5–7].

Quelques siècles plus tard, en Europe, des informations émergèrent indiquant que les Chinois avaient également recours à des éoliennes, notamment pour le drainage des rizières [8]. De leur côté, les Perses apportèrent des améliorations substantielles à leurs machines en installant des voiles en roseau tissé montées sur un axe vertical, fonctionnant de manière similaire aux systèmes de portes tournantes.



(a) Éolienne perse pour moudre les grains.



(b) Éolienne chinoise pour pompage d'eau.

FIGURE 2.1 – Anciens moulins à vent.

Cette innovation leur permit d'exploiter plus efficacement l'énergie éolienne, améliorant ainsi le rendement de cette technologie, aujourd'hui connue sous le nom de « moulin ». Grâce à cette avancée majeure, le monde occidental put tirer parti de l'efficacité des moulins, qui constituaient des systèmes relativement simples, généralement installés sur des poteaux et munis de quatre pales. La figure 2.2 illustre un exemple de moulin à poteau construit en France [9].



FIGURE 2.2 – Moulin à poteau construit au XVIIIe siècle en France.

Entre les XI^e et XIII^e siècles, les moulins à vent, introduits en Europe depuis le Moyen-Orient par les marchands et croisés [10], se diffusèrent rapidement, tandis que le moulin à axe horizontal fut développé indépendamment en Europe [11]. Principalement utilisés pour le pompage de l'eau, le broyage du grain et le sciage du bois [5], les moulins à vent devinrent essentiels à la vie quotidienne au XV^e siècle pour l'irrigation, la production de farine et des tâches industrielles [9]. Entre les XVI^e et XVII^e siècles, les Néerlandais innovèrent dans l'utilisation des moulins pour drainer les terres et créer des polders [5, 9]. Ces avancées technologiques firent des moulins à vent un outil indispensable à travers l'Europe (voir figure 2.3).



(a) Russie



(b) Hollande



(c) Danemark

FIGURE 2.3 – Exemples de moulins à vent en bois en Europe.

Au XVIII^e siècle, le vent perd son rôle majeur en Europe avec l'essor des énergies fossiles et de la machine à vapeur durant la révolution industrielle. Au XIX^e siècle, les colons européens introduisent les moulins à vent en Amérique du Nord, améliorés pour l'agriculture, et atteignent une forme perfectionnée, notamment avec les modèles hollandais. En 1854, Daniel Halladay crée le premier moulin à vent orientable et fonde l'US Wind Engine & Pump Company, popularisant des éoliennes fabriquées en série. L'utilisation de matériaux en acier améliore leur robustesse, culminant avec le moulin de Thomas Osborn Perry en 1883 [10]. En 1888, Charles Brush développe la première éolienne générant de l'électricité, marquant un tournant vers la conversion du vent en énergie électrique (voir figure 2.4).

En 1891, au Danemark, Poul La Cour conçoit la première éolienne à quatre ailes asymétriques, illustrée à la figure 2.5. Ces éoliennes, largement utilisées dans les zones rurales pour l'énergie électrique, furent produites en milliers de modèles variés [10]. Cependant, au début du XX^e siècle, leur usage déclina face à la concurrence des machines à vapeur et des moteurs à combustion interne, ainsi qu'à l'électrification progressive des régions. Entre 1930 et 1940, elles restèrent employées dans les zones rurales, et pendant la Seconde Guerre mondiale, les Néerlandais utilisèrent des voiles d'éoliennes comme systèmes d'alerte contre les attaques ennemies [10].

En Algérie, en 1953, le Service de la Colonisation et de l'Hydraulique installa la plus grande éolienne de pompage à Adrar, dotée d'un mât de 25 mètres et de trois pales d'un diamètre de 15 mètres. Cette éolienne fonctionna pendant près de dix ans. Il convient de




FIGURE 2.4 – Eolienne de Charles Brush en 1888.




FIGURE 2.5 – Prototype de l'éolienne de Poul La Cour.

noter que ce modèle était une innovation à l'époque, avec seulement trois exemplaires dans le monde : l'un en Allemagne, l'un en Argentine et le troisième à Adrar. Deux autres éoliennes furent implantées à Mecheria et Naama, respectivement dédiées à l'alimentation en eau potable de la ville et au pompage de l'eau. À l'Institut National de Recherche Agrono-

mique (INRA) d'Adrar, cette éolienne est illustrée à la figure 2.6 témoignant de l'innovation dans l'utilisation de l'énergie éolienne dans le sud de l'Algérie, et ce, plus de 70 ans après son installation [12].



FIGURE 2.6 – Éolienne d'Adrar, Algérie.

Malgré les services considérables rendus à la société par l'énergie éolienne, l'industrialisation a conduit à son remplacement progressif par de grandes centrales thermiques utilisant des combustibles fossiles, considérés comme économiques et facilement accessibles. Ce n'est qu'à partir des années 1970, avec les avancées techniques et technologiques majeures que le monde a connues, notamment le développement rapide des énergies fossiles — particulièrement du pétrole et du gaz naturel — que l'exploitation de l'énergie éolienne a perdu de son attrait. Ces sources d'énergie, abondantes et peu coûteuses, ont contribué à rendre l'éolien moins compétitif. L'avenir de cette forme d'énergie semblait incertain jusqu'à la crise pétrolière de 1973.

2.3 Développement de l'énergie éolienne dans le monde

Les chocs pétroliers de 1973 et 1979 ont provoqué une crise mondiale, accentuant la dépendance aux hydrocarbures et incitant à diversifier les sources d'énergie face à la diminution des réserves fossiles et aux enjeux environnementaux croissants. Cette transition a favorisé l'essor des énergies renouvelables, notamment l'énergie éolienne, qui s'est imposée comme une solution clé pour produire de l'électricité propre. Sa croissance rapide, soutenue par la demande mondiale, en fait une alternative stratégique et complémentaire aux énergies fossiles et nucléaires, exploitant le potentiel considérable des masses d'air en mouvement. Un des atlas mondiaux, illustrant les moyennes annuelles de vitesses de vent à une hauteur de 100 mètres (en m/s), est présenté dans la figure 2.7 [13].




FIGURE 2.7 – Atlas mondial des moyennes annuelles de vitesses de vent (en m/s, à 100 m).

L'énergie éolienne a bénéficié d'importants progrès technologiques, avec le développement de prototypes dépassant 14 MW, visant une production optimale d'électricité propre. Ces avancées ont permis l'installation de parcs éoliens majeurs, tels que London Array au Royaume-Uni (630 MW), Jiuquan en Chine (prévu à 20 GW en 2025), Jaisalmer en Inde (1064 MW), Altamont Pass en Californie (576 MW après rénovation en 2016), et Horns Rev au Danemark, avec plusieurs phases atteignant 8,3 MW par turbine. Ces développements renforcent la compétitivité économique et environnementale de l'énergie éolienne, grâce à des turbines plus performantes, des matériaux améliorés et des systèmes intelligents optimisant la gestion de l'énergie produite.

2.4 L'énergie éolienne mondiale en chiffres

Malgré les crises économiques majeures (crise de 2008, COVID-19, guerre en Ukraine), le secteur de l'énergie éolienne a maintenu une forte dynamique de croissance, soutenue par des politiques gouvernementales ambitieuses pour la transition énergétique et la lutte contre le changement climatique. Entre 2017 et 2022, la capacité éolienne mondiale a connu une hausse constante, passant de 546,388 GW à 934 GW [14]. L'Europe domine le secteur avec environ 70% de la capacité mondiale, grâce à des politiques favorables, des investissements et des conditions géographiques avantageuses. En 2022, la capacité nouvellement installée atteignait 15 GW, dont 963 MW offshore, avec une production de 419,5 TWh (+8,4% par rapport à 2021) [15]. En Europe, l'Allemagne (66,2 GW), l'Espagne (28,4 GW), la France (20,7 GW), la Suède (14,6 GW) et l'Italie (12,9 GW) ont renforcé leur leadership, soutenus par des objectifs ambitieux de neutralité carbone d'ici 2050, une baisse des coûts et des innovations technologiques [16–19]. Le Royaume-Uni a atteint 20,7 GW en 2022, avec un objectif de 50 GW en 2030, appuyé par des politiques comme le programme "Renewable Obligation". En Asie, la Chine (près de 300 GW) et l'Inde (40 GW) dominent, avec une croissance rapide grâce à des politiques incitatives [20].

En 2022, l'Asie représentait 45% de la capacité mondiale avec plus de 750 GW installés. En Amérique du Nord, les États-Unis et le Canada ont ajouté 25,6 GW en 2022, atteignant 192,5 GW au total. Une croissance annuelle moyenne de 28 GW est attendue entre 2023 et 2025 [16]. En Amérique latine, la capacité installée était de 28,5 GW en 2022, dominée par le Brésil (25,6 GW), avec des contributions notables du Chili, du Mexique et de l'Argentine. L'Afrique et le Moyen-Orient ont triplé leurs installations en 2023 (1 GW), avec des perspectives de croissance significative d'ici 2028, notamment en Afrique du Sud, Égypte et Arabie Saoudite. Enfin, l'Australie a vu sa capacité croître de 94% entre 2018 (5,4 GW) et 2022 (10,5 GW), et prévoit une augmentation annuelle moyenne de 2 à 3 GW entre 2023 et 2025, consolidant sa place parmi les leaders de la région Asie-Pacifique [17]. La capacité éolienne cumulée installée dans le monde pour la période 2013 à 2022 (en GW) est présentée sur la figure 2.8 [21].




FIGURE 2.8 – Capacité éolienne cumulée installée dans le monde de 2013 à 2022.

Selon Global Wind Energy Council (GWEC), à la fin de l'année 2022, les cinq premières nations – à savoir la Chine, les États-Unis, l'Allemagne, l'Inde et l'Espagne – représentaient collectivement 72 % de la capacité éolienne installée totale à l'échelle mondiale [20]. La figure 2.9 présente la capacité installée des dix principaux pays producteurs d'énergie éolienne (exprimée en MW), ainsi que la part du reste du monde [22].

L'Afrique dispose d'un fort potentiel pour l'énergie éolienne grâce à ses vastes zones avec des vents puissants et constants [20]. En 2022, la capacité installée a atteint 28,5 GW, soit une hausse de 14% par rapport à 2018, favorisée par la baisse des coûts de production, des politiques publiques et la demande croissante d'électricité propre. Le Maroc (7,2 GW), l'Égypte (5,3 GW), l'Afrique du Sud (3,6 GW) et le Kenya (3,2 GW) sont les leaders du continent. L'éolien, sans émissions de gaz à effet de serre, représente une solution durable pour le développement énergétique de l'Afrique. Le GWEC prévoit une croissance annuelle de 6 GW entre 2023 et 2025 [20].




FIGURE 2.9 – Capacité installée cumulée d'énergie éolienne en MW des dix principaux pays producteurs en 2022.

2.5 L'énergie éolienne en Algérie

En Algérie, bien que le pays dispose d'un potentiel éolien considérable, le développement de l'énergie éolienne reste limité et n'a pas encore atteint l'ampleur nécessaire, malgré la présence de zones bénéficiant de vents forts et réguliers sur une grande partie de son territoire [23]. À ce jour, les infrastructures et technologies nécessaires à l'exploitation optimale de cette ressource n'ont pas été suffisamment développées. En conséquence, l'énergie éolienne demeure une ressource sous-utilisée dans le pays.

En décembre 2010, la première ferme éolienne d'Algérie a été mise en place à Adrar, grâce à un projet mené par Cegelec, une filiale de Vinci Energies, et initié par Sonelgaz. Cette ferme, située dans la région de Kabertène, dans la commune de Tissabit, à environ 72 kilomètres au nord de la Wilaya d'Adrar, couvre une superficie de 30 hectares. Le choix de Kabertène a été le fruit d'une étude cartographique approfondie des régions à fort potentiel éolien en Algérie, une étude qui pourrait contribuer à l'essor de l'énergie éolienne dans le pays. Le parc éolien est constitué de 12 éoliennes Gamesa de type G52/850/50-60Hz, d'une capacité de 0,850 MW chacune. Mis en service en 2014, il produit environ 10 MW d'électricité, soit l'équivalent de la consommation annuelle de 3 000 foyers algériens [12, 24]. La figure 2.10 illustre la ferme éolienne de Kabertène dans la Wilaya d'Adrar, Algérie.

Le gouvernement algérien ambitionne de devenir un acteur majeur dans la production d'électricité à partir de sources renouvelables, y compris l'énergie éolienne. Le programme national d'énergies renouvelables prévoit une augmentation substantielle de la capacité installée de ces sources, avec un objectif de 37 % d'énergie renouvelable dans le mix énergétique d'ici 2030, ainsi que 27 % de la production d'électricité destinée à la consommation



FIGURE 2.10 – Ferme éolienne Kabertène (Adrar-Algérie).

nationale provenant de sources renouvelables. Bien que le potentiel national en énergies renouvelables soit largement dominé par le solaire, l'Algérie poursuit également le développement de fermes éoliennes.

La première phase du programme (2015-2020) visait une production de 1010 MW d'énergie éolienne. La deuxième phase (2021-2030) se concentrera sur le développement de l'interconnexion électrique et l'installation de grandes centrales d'énergies renouvelables dans diverses régions, afin d'atteindre une production de 4000 MW d'énergie éolienne. Le programme prévoit, sur cette période, une capacité totale de 5010 MW issue de l'énergie éolienne [25].

2.6 Principes fondamentaux de l'énergie éolienne

2.6.1 Origine du vent

Le vent est un phénomène à la fois complexe et captivant, présent partout sur notre planète. Il peut être défini comme le déplacement horizontal de l'air au niveau de la surface terrestre. Omniprésent, il constitue l'un des éléments fondamentaux de notre environnement physique et joue un rôle central dans l'exploitation de l'énergie éolienne. Les flux de vent à l'échelle mondiale trouvent leur origine dans le rayonnement solaire et la rotation de la terre, qui génèrent des différences de pression à la surface terrestre en raison du chauffage inégal de la planète par le soleil. Ces variations de température et de pression dans l'atmosphère créent une force, la force de Coriolis, responsable de la génération et du déplacement de l'air des zones de haute pression vers les zones de basse pression. Ainsi, le vent se caractérise par sa direction et sa vitesse [5].

2.6.2 Classification des vents

Les vents terrestres sont généralement classés en trois catégories principales : les vents *primaires*, les vents *secondaires* et les vents *tertiaires*. Cette classification repose sur des critères tels que la périodicité, l'origine géographique, la vitesse, ainsi que les phénomènes météorologiques qui les génèrent [5].

2.6.2.1 Vent primaire ou vent planétaire

Les vents primaires soufflent de manière constante tout au long de l'année dans une direction particulière. Également appelés vents dominants ou vents planétaires, ces vents comprennent les Alizés, les vents d'Ouest et les vents d'Est.

2.6.2.2 Vent secondaire ou vent périodique

Les vents secondaires sont des vents qui changent de direction en fonction des saisons. On les désigne également sous les termes de vents saisonniers ou vents périodiques. Ces vents sont présents dans de nombreuses régions du globe et leur direction est régie par des forces physiques spécifiques à chaque emplacement géographique. Un exemple typique de vent secondaire est le vent de Mousson.

2.6.2.3 Vent tertiaire ou vent local

Les vents tertiaires soufflent seulement à des moments particuliers de la journée ou de l'année et se concentrent sur des zones géographiques restreintes. Ces vents résultent des différences de température et de pression atmosphérique au sein d'un lieu donné. Ils peuvent être chauds, froids, chargés de glace ou riches en poussière, en fonction des caractéristiques locales. Parmi les vents locaux notables, on trouve le Mistral, le Foehn, et la Bora.

2.6.3 Types des vents

À travers le monde, il existe différents types de vents, chacun possédant des caractéristiques et des origines spécifiques. Les vents les plus fréquemment rencontrés incluent :

2.6.3.1 Les Alizés

Les alizés, également appelés Est-Alizés tropicaux, soufflent dans des directions opposées dans chaque hémisphère en raison de l'effet Coriolis et de la loi de Ferrel. Dans l'hémisphère nord, ces vents soufflent du nord-est, tandis que dans l'hémisphère sud, ils soufflent du sud-est. Les alizés se forment dans les zones de haute pression subtropicale et se dirigent vers la zone de basse pression équatoriale.

2.6.3.2 Les vents d'ouest

Les vents d'ouest sont associés aux zones de latitude dans l'hémisphère sud. Ces vents soufflent des zones de haute pression subtropicale vers celles de basse pression subpolaire. En général, les vents d'ouest dans l'hémisphère sud sont plus forts et plus réguliers que dans l'hémisphère nord.

2.6.3.3 Vents d'est polaires

Les vents d'est polaires sont des vents permanents, froids et secs, soufflant du nord-est au sud-ouest dans l'hémisphère nord, et du sud-est au nord-ouest dans l'hémisphère sud. Ces vents partent des zones de haute pression polaire pour atteindre les basses pressions subpolaires.

2.6.3.4 Les vents de Mousson

La mousson est un vent caractéristique des climats de basse latitude qui inverse sa direction entre l'été et l'hiver. En hiver, les vents soufflent depuis la terre, tandis qu'en été, ils soufflent de l'océan vers la terre, entraînant des changements notables dans les températures et les modèles de précipitations. Ce phénomène affecte particulièrement l'Asie du Sud et l'Afrique de l'Est, avec des périodes de sécheresse alternées avec des saisons de pluies intenses.

2.6.3.5 Brise de terre et brise de mer

La brise de terre est un vent local soufflant de la terre vers la mer, généralement sec et chaud, tandis que la brise de mer souffle de la mer vers la terre, apportant une certaine humidité.

2.6.3.6 Brise de montagne et brise de vallée

Durant la journée, les pentes des régions montagneuses se réchauffent, ce qui entraîne l'ascension de l'air le long des pentes pour combler le vide. Ce phénomène est appelé brise de vallée. La nuit, les pentes se refroidissent, et l'air dense descend dans la vallée sous forme de brise de montagne.

2.6.3.7 Vents locaux

Les différences locales de température et de pression génèrent des vents locaux, qui sont confinés aux niveaux les plus bas de la troposphère. Parmi les exemples de vents locaux, on trouve le Loo en Inde, la Bora en Italie, le Chinook en Amérique du Nord, et le Zonda en Argentine.

La figure 2.11, tirée de [26], illustre la configuration globale des vents, en indiquant l'emplacement des vents polaires d'est, des vents d'ouest et des alizés.




FIGURE 2.11 – Configuration globale des vents : vents polaires d'est, vents d'ouest et alizés.

2.6.4 Caractéristiques du vent

Les caractéristiques du vent sont multiples et dépendent de nombreux facteurs. Parmi ces caractéristiques, on peut citer la turbulence du vent, la densité de l'air, et la saisonnalité, entre autres. Toutefois, les deux caractéristiques majeures du vent sont la vitesse et la direction, qui déterminent respectivement le sens de l'écoulement de l'air et sa vitesse.

2.6.4.1 Vitesse du vent

La vitesse du vent est l'une des caractéristiques les plus importantes pour l'énergie éolienne. Elle est généralement mesurée à une hauteur de 10 mètres au-dessus du sol. Cette vitesse est exprimée en kilomètres par heure (km/h), en mètres par seconde (m/s) ou en nœuds (1 nœud = 1,852 km/h).

2.6.4.2 Direction du vent

La direction du vent, généralement exprimée en degrés par rapport au nord (0° représentant le nord, 90° l'est, 180° le sud, et 270° l'ouest), est également essentielle pour l'orientation des éoliennes, qui sont généralement placées de manière à faire face au vent dominant. La direction du vent peut varier considérablement en fonction de la localisation géographique et des saisons.

2.6.5 Mesure et caractérisation du vent

La mesure du vent est une activité essentielle dans plusieurs domaines tels que la météorologie, l'aviation, l'énergie éolienne, et d'autres applications. Différents instruments et méthodes sont utilisés pour mesurer la vitesse, la pression et la direction du vent. Parmi les dispositifs les plus couramment utilisés, on trouve :

2.6.5.1 Anémomètres

Les anémomètres sont des instruments utilisés pour mesurer la vitesse ou la pression du vent. Parmi les types les plus répandus, on trouve les anémomètres à coupelles, à hélice, à fil chaud et à ultrasons. La figure 2.12 illustre quelques-uns de ces types d'anémomètres.




FIGURE 2.12 – Quelques modèles d'anémomètre.

2.6.5.2 Girouettes

Ces instruments permettent de mesurer la direction du vent. Ils sont fréquemment associés aux anémomètres afin d'offrir des données complètes sur la vitesse et la direction du vent. Deux types de girouettes, l'un classique et l'autre moderne, sont illustrés dans la figure 2.13.




FIGURE 2.13 – Modèles de girouettes.

2.6.5.3 Manche à air

C'est un instrument utilisé pour estimer approximativement la vitesse et la direction du vent. La figure 2.14 illustre ces valeurs approximatives.





FIGURE 2.14 – Manche à air et valeurs approximatives de la vitesse du vent.

2.6.5.4 Lidar

Le lidar (Light Detection and Ranging) est un instrument qui utilise des faisceaux laser pour mesurer la vitesse et la direction du vent à différentes altitudes (voir figure 2.15).



(a) Lidar WINDCUBE.

(b) Lidar sur site éolien.

FIGURE 2.15 – Lidar.

Il existe également d'autres dispositifs utilisés pour mesurer la vitesse, la direction et la pression du vent, tels que les sondes atmosphériques, les stations météorologiques au sol, les ballons captifs et les mâts de mesure, ...etc [27].

2.6.6 Définition de l'énergie éolienne

L'énergie éolienne désigne la conversion de l'énergie cinétique du vent en énergie mécanique ou électrique à l'aide de dispositifs appelés éoliennes. Cette forme d'énergie est renouvelable, inépuisable et ne produit ni émissions polluantes ni déchets radioactifs. Elle est principalement exploitée pour la production d'électricité, mais peut également être utilisée dans d'autres applications telles que le pompage d'eau ou la production d'énergie mécanique. La performance de la conversion énergétique dépend des conditions météorologiques, notamment de la vitesse et de la direction du vent, ce qui introduit une variabilité dans la production d'énergie. L'énergie éolienne joue un rôle central dans la transition énergétique mondiale en tant que solution propre et durable, contribuant à la réduction des émissions de gaz à effet de serre et à la préservation de l'environnement [20, 28].

2.6.7 Définition d'une éolienne

Une éolienne, également désignée sous le terme d'aérogénérateur ou, plus communément, éolienne, est un dispositif de conversion de l'énergie cinétique du vent en énergie mécanique, qui est ensuite transformée en énergie électrique grâce à une génératrice. Ce système, appelé en anglais Wind Energy Conversion System (WECS), se compose de plusieurs éléments techniques destinés à optimiser cette conversion. Lorsqu'elles sont installées en nombre, les éoliennes forment ce que l'on appelle un « parc éolien » ou une « ferme éolienne », un ensemble d'unités de production. Ces parcs peuvent être situés à terre (installations " Onshore " ou en mer " Offshore "). La fabrication des différents composants des éoliennes repose sur l'intégration de technologies de pointe, visant à améliorer leur efficacité, leur durabilité et leur adaptabilité. Ces avancées permettent aux éoliennes de jouer un rôle de plus en plus central dans la production d'énergie propre et renouvelable. La figure 2.16 illustre le principe de la conversion de l'énergie cinétique du vent en énergie électrique [28].

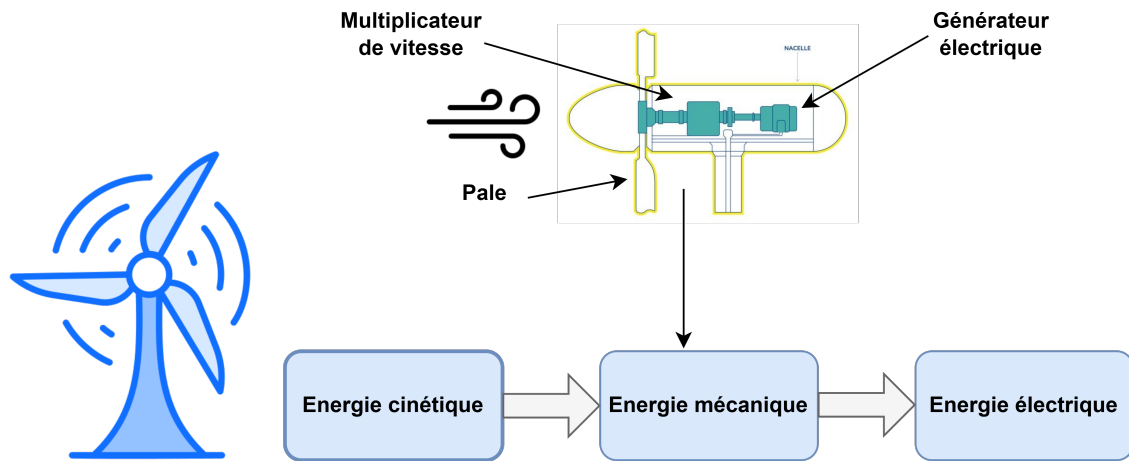


FIGURE 2.16 – Principe de conversion de l'énergie cinétique du vent.

2.6.8 Les composants principaux d'une éolienne

Une éolienne est généralement constituée de quatre composants principaux, auxquels s'ajoutent plusieurs éléments mineurs interconnectés, qui fonctionnent ensemble pour convertir l'énergie cinétique du vent en énergie électrique. Les composants essentiels sont : la fondation, la tour, le rotor et le moyeu (comportant généralement trois pales), ainsi que la nacelle. La figure 2.17 présente une illustration des composants principaux d'une éolienne.




FIGURE 2.17 – Les composants principaux d'une éolienne à axe horizontal.

2.6.8.1 La fondation

La fondation, également appelée base, est habituellement réalisée en béton armé. Elle doit être suffisamment robuste pour supporter l'ensemble de la structure de l'éolienne et assurer la fixation de la tour au sol. Ce composant joue un rôle fondamental dans la stabilité de l'éolienne, en particulier face à des conditions météorologiques extrêmes. Le diamètre de la fondation est généralement supérieur à 20 mètres, avec une profondeur excédant les 3 mètres. Le choix du type de fondation dépend des caractéristiques du sol et de la présence de la nappe phréatique sur le site d'installation de l'éolienne. La figure 2.18 montre un exemple de fondation adaptée à ces critères.




FIGURE 2.18 – Vue d'une fondation en béton armé.

2.6.8.2 La tour

La tour, souvent désignée sous le terme de mât, est construite en béton ou, plus couramment, en acier. De forme conique, elle doit posséder une structure particulièrement robuste pour supporter les principaux éléments de l'éolienne, tels que la nacelle, le rotor et le moyeu des pales. Fixée solidement à la fondation, la tour garantit la stabilité et la sécurité de l'éolienne. Sa hauteur est un paramètre crucial, car elle permet d'atteindre des vents plus puissants et réguliers. La hauteur de la tour varie généralement entre 50 et 130 mètres, et elle est constituée de plusieurs sections. Le diamètre de la tour est compris entre 4 et 7 mètres. À l'intérieur de la tour se trouvent les câbles électriques assurant le raccordement au réseau de distribution, ainsi que l'échelle d'accès à la nacelle. La figure 2.19 illustre l'image d'un tour d'une éolienne en métal.



FIGURE 2.19 – Tour d'une éolienne.

2.6.8.3 Le rotor et le moyeu

Le rotor, également désigné sous le terme d'hélice, constitue la partie tournante de l'éolienne. Il est responsable de la conversion de l'énergie éolienne en énergie mécanique. Pour les éoliennes dédiées à la production d'électricité, le rotor est généralement composé de deux ou trois pales, chacune mesurant entre 10 et 30 mètres de longueur. Ces pales sont fixées de manière sécurisée au moyeu, qui est ensuite relié à la nacelle par l'intermédiaire de l'arbre principal. Le moyeu joue un rôle essentiel dans la transmission de l'énergie cinétique du vent, du rotor vers le générateur situé dans la nacelle. Les pales possèdent un profil aérodynamique similaire à celui des ailes d'un avion, et sont fabriquées à partir de matériaux composites, afin de garantir légèreté et résistance. Le moyeu, quant à lui, est généralement réalisé en acier allié et fabriqué par des techniques d'usinage de haute précision. La figure 2.20 illustre le moyeu et la pale d'une éolienne.



(a) Moyeu d'une éolienne à trois pâles.



(b) Pâle d'une éolienne.

FIGURE 2.20 – Moyeu et pâles.

2.6.8.4 La nacelle

La nacelle constitue le cœur opérationnel de l'éolienne. Installée au sommet de la tour, elle abrite et protège l'ensemble des systèmes mécaniques, électriques et de commande nécessaires à la conversion de l'énergie mécanique, générée par la rotation des pales, en énergie électrique. Elle intègre notamment le générateur, la boîte de vitesses, le système de freinage, les dispositifs de conversion électrique, ainsi que le mécanisme d'orientation. Plusieurs systèmes coopèrent de manière complémentaire pour optimiser la production d'énergie, chacun remplissant une fonction précise dans la chaîne de conversion. Parmi ces systèmes, on distingue notamment :

- **Système de conversion électrique**

Le système de conversion électrique d'une éolienne est un ensemble de composants et de processus essentiels permettant de convertir l'énergie mécanique générée par la rotation des pales en énergie électrique. Ce système joue un rôle clé dans la chaîne de production d'énergie éolienne et permet une gestion flexible de l'éolienne, afin de s'adapter aux variations de la vitesse du vent et aux besoins fluctuants du réseau électrique.

- **La génératrice**

La génératrice, élément central du système de conversion électrique d'une éolienne, peut être de type continu ou alternatif, synchrone ou asynchrone, et fonctionner à l'aide d'aimants permanents ou d'une excitation externe. Le choix du générateur dépend de plusieurs critères techniques et économiques. Tous reposent sur le principe de l'induction électromagnétique formulé par Faraday.

- **Convertisseur de puissance**

Le convertisseur de puissance est un élément clé de la chaîne de conversion énergétique des éoliennes. Il permet de stabiliser le courant alternatif produit par le générateur, en le rendant compatible avec les exigences du réseau électrique. Deux types sont généralement utilisés : le convertisseur côté générateur (AC/DC ou DC/DC) et le convertisseur côté réseau (souvent un onduleur). Les progrès technologiques dans ce domaine jouent un rôle déterminant dans l'amélioration de la performance des systèmes éoliens.

- **La boîte de vitesse**

La boîte de vitesses, ou multiplicateur, joue un rôle crucial dans une éolienne en convertissant la rotation lente de l'arbre principal, induite par les pales, en une rotation rapide adaptée au fonctionnement du générateur. Différents types de multiplicateurs sont utilisés, tels que les engrenages planétaires, droits, coniques, hélicoïdaux ou à vis sans fin, chacun présentant des caractéristiques spécifiques en matière de performance, de coût et de maintenance.

- **Le système de freinage**

Le système de freinage assure la sécurité de l'éolienne en régulant ou en arrêtant la rotation des pales lors de la maintenance ou en conditions extrêmes. Deux types principaux sont utilisés : mécanique et électrique, chacun contribuant à la protection de l'installation contre les surtensions dues aux vents violents.

- **Le système de contrôle**

Le système de contrôle gère l'orientation, l'angle des pales et la vitesse de rotation, assurant ainsi une production optimale d'électricité tout en protégeant l'éolienne contre les conditions extrêmes.

- **Le système d'orientation**

Le système d'orientation ajuste la nacelle selon la direction du vent, à l'aide des données de la girouette et de l'anémomètre, afin d'optimiser la captation d'énergie et stabiliser la production.

2.6.9 Principe de fonctionnement d'une éolienne

Le fonctionnement d'une éolienne repose sur la conversion de l'énergie cinétique du vent en énergie mécanique, puis en énergie électrique. Lorsque le vent souffle, il fait tourner les pales de l'éolienne, orientées face au vent grâce à un système de régulation. Ce mouvement entraîne le rotor, relié à un arbre principal, dont la vitesse est amplifiée par une boîte de vitesses. Le générateur transforme ensuite l'énergie mécanique en courant alternatif à basse tension, transporté jusqu'à un transformateur qui ajuste la tension pour l'intégration au réseau ou le stockage.

2.6.10 Classification des éoliennes

Les éoliennes modernes se présentent sous différents modèles, chacun offrant des caractéristiques spécifiques. Elles peuvent être classées selon plusieurs critères, notamment l'orientation de l'axe de rotation, le type de générateur, le lieu d'installation, ainsi que les systèmes de gestion ou les techniques de contrôle de la puissance. D'autres aspects, comme leur taille ou leur capacité de production, peuvent également servir de base de classification. La figure 2.21 illustre cette classification selon ces différents critères.

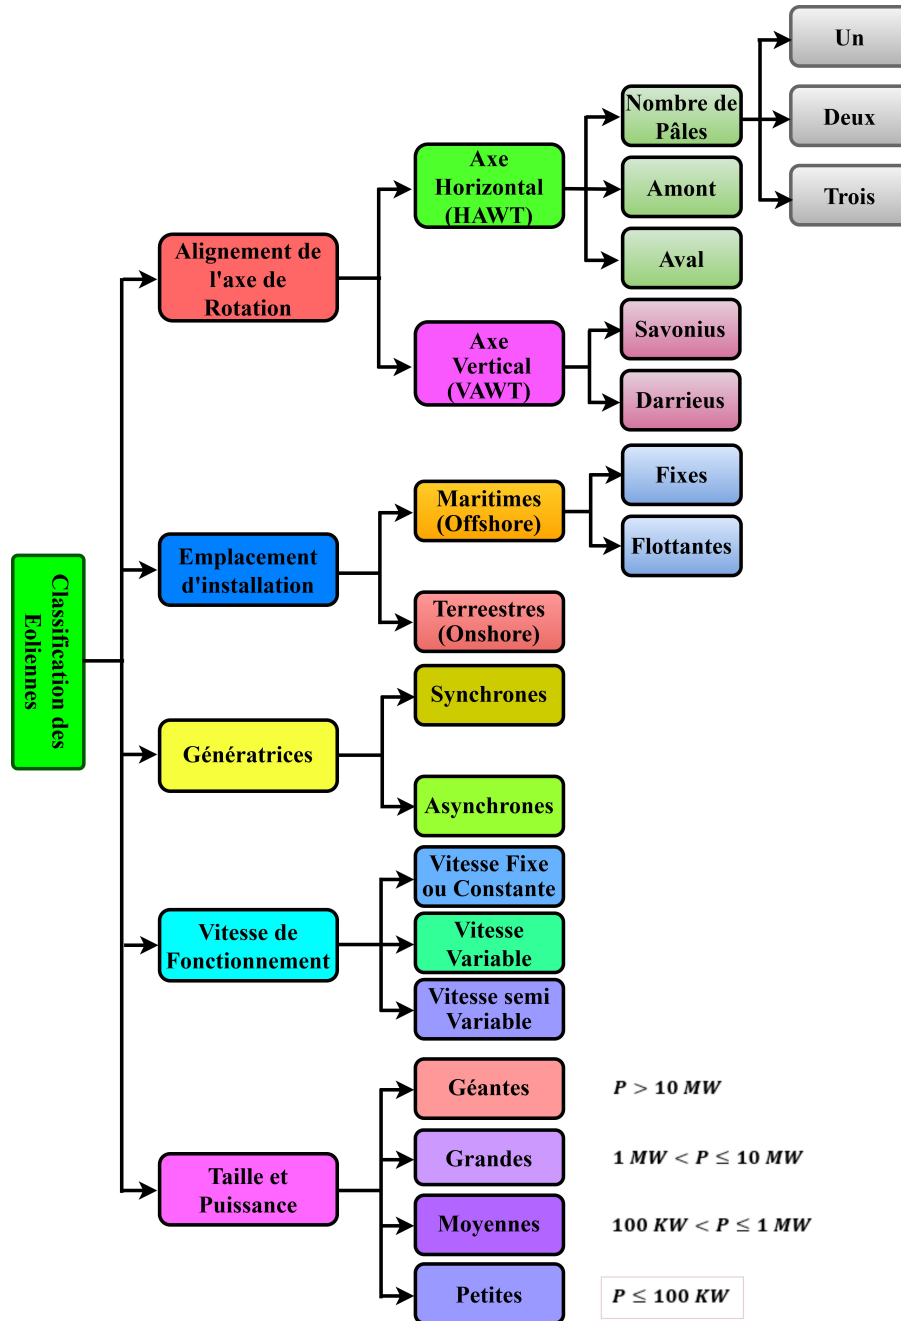


FIGURE 2.21 – Classification des éoliennes.

Ci-dessous, une présentation générale fondée sur ces aspects :

2.6.10.1 Alignement de l'axe de rotation

La classification des éoliennes en fonction de l'alignement de leur axe de rotation se divise principalement en deux types : les éoliennes à axe horizontal et les éoliennes à axe vertical.

• Éoliennes à axe horizontal (HAWT)

Souvent désignées sous le terme d'« éoliennes à hélices », ce type d'éolienne est actuellement le plus couramment utilisé. Elles se caractérisent par un axe de rotation horizontal, parallèle au sol, avec l'arbre du rotor orienté dans la direction du vent. Les modèles les plus répandus sont ceux à trois pales (tripales), dont la conception aérodynamique permet de les faire tourner grâce à la portance générée par la force du vent. Ces éoliennes sont généralement orientées face au vent et nécessitent un système de suivi de la direction du vent pour maximiser leur efficacité [29]. La figure 2.22 illustre les trois types d'éoliennes à axe horizontal, différenciées par le nombre de pales.




FIGURE 2.22 – Éolienne à axe horizontal.

Selon la direction du vent par rapport aux pales de l'éolienne, deux types distincts d'éoliennes à axe horizontal peuvent être identifiés : l'éolienne à axe horizontal en amont, où le vent souffle de l'avant des pales, et l'éolienne à axe horizontal en aval, où le vent souffle sur l'arrière des pales. La figure 2.23 illustre ces deux configurations.

Les éoliennes à axe horizontal (HAWT) présentent plusieurs avantages, tels que :

- La puissance de sortie est élevée comparée aux éoliennes à axe vertical ;
- L'efficacité d'une HAWT est élevée ;
- Elle est moins coûteuse qu'une éolienne à axe vertical ;
- Elle est plus constante et sa vitesse de rotation est élevée ;
- Avec les variations de cisaillement du vent, la grande tour capte plus de vent ;
- La fiabilité est élevée ;
- Les pales de l'éolienne peuvent être inclinées à l'aide d'un engrenage pour obtenir le meilleur angle d'attaque du vent, ce qui entraîne une meilleure performance en cas de tempête ;
- Le rotor peut être incliné par les pales pendant les tempêtes.



(a) Éolienne face au vent (Amont).

(b) Éolienne sous le vent (Aval).

FIGURE 2.23 – Éolienne à axe horizontal en amont et en aval.

et des inconvénients dont :

- Les HAWTs sont disponibles seulement en grandes tailles et sont difficiles à utiliser dans la génération distribuée ;
- Comme elles sont de grande taille et lourdes, leur transport d'un lieu à un autre est difficile ;
- Le montage d'un générateur lourd et d'une boîte de vitesses en haut de la tour nécessite une structure plus robuste, ce qui augmente la complexité et le coût de la structure ;
- L'installation et la maintenance d'une HAWT sont des processus difficiles en raison de la grande tour et des turbines lourdes ;
- Le bruit provenant de la HAWT est élevé comparé aux autres éoliennes ;
- Pour concevoir et fabriquer une HAWT, des machines lourdes sont nécessaires.

• Éoliennes à axe vertical (VAWT)

Les éoliennes à axe vertical se caractérisent par un axe de rotation perpendiculaire au sol, ce qui les rend indépendantes de la direction du vent. Par conséquent, aucune conception aérodynamique spécifique n'est requise pour les pales. En comparaison avec les éoliennes à axe horizontal (HAWT), les VAWT sont de taille plus modeste et, bien qu'elles soient généralement moins efficaces, elles peuvent présenter des avantages dans certaines situations, notamment dans des environnements urbains où les conditions de vent sont plus turbulentes. Il existe principalement deux types de conceptions pour les VAWT : le modèle Savonius, illustré dans la figure 2.24(a), et le modèle Darrieus, représenté dans la figure 2.24(b) [29].

Les éoliennes à axe vertical (VAWT) présentent plusieurs avantages, notamment :

- Une production de vibrations réduite et un fonctionnement plus silencieux par rapport aux éoliennes à axe horizontal (HAWT) ;
- L'absence de besoin d'une orientation spécifique, car la direction des pales est perpendiculaire à la vitesse du vent, ce qui élimine la nécessité d'un mécanisme de contrôle de lacet ;
- La capacité à générer de l'électricité à des vitesses de vent plus faibles ;



(a) Type Savonius.



(b) Type Darrieus.

FIGURE 2.24 – Éolienne à axe vertical.

- Une installation et une maintenance faciles, car le générateur et la boîte de vitesses sont situés près du sol ;
- Une préférence pour la génération distribuée, en raison de leur taille généralement plus modeste et de leur faible niveau sonore ;
- Un aspect visuel attrayant, ce qui peut constituer un avantage esthétique dans certains contextes.

Cependant, les VAWT présentent également certains inconvénients, parmi lesquels :

- Une efficacité inférieure à celle des HAWT ;
- Une production d'énergie moins élevée que celle d'une HAWT de taille équivalente, en raison de la position du rotor près du sol, où l'air est moins disponible en raison de la traînée de surface ;
- La maintenance et le remplacement des pièces peuvent être complexes si la structure est mal conçue, car les pales, montées au-dessus du générateur et de la boîte de vitesses, exercent tout leur poids sur cette dernière, nécessitant l'ajout d'un hauban pour les stabiliser.

2.6.10.2 Emplacement d'installation

Le choix de l'emplacement d'installation des éoliennes est un facteur déterminant, influencé par plusieurs critères tels que la vitesse, la direction et la constance des vents, ainsi que la proximité des zones habitées, l'accessibilité pour la construction et la maintenance, sans oublier les conditions météorologiques spécifiques à la région. Ce choix conditionne non seulement l'efficacité de la production d'énergie, mais aussi les coûts et la faisabilité des travaux d'installation et d'entretien. La classification des éoliennes en fonction de leur emplacement se divise principalement en deux catégories : les éoliennes terrestres et les éoliennes maritimes.

- **Éoliennes terrestres**

Également appelées éoliennes « onshore », elles sont les plus courantes. Ces éoliennes sont installées sur terre, généralement dans des zones rurales, sur des collines ou dans des régions désertiques. Leur implantation sur terre ferme présente l'avantage de la proximité des infrastructures de transport et de maintenance, mais elle peut être limitée par la disponibilité d'espaces et par l'impact visuel (voir figure 2.25).



(a) Zone rurale.



(b) Zone désertique.

FIGURE 2.25 – Parc éolien terrestre en zone rurale et désertique.

- **Éoliennes maritimes**

Appelées également éoliennes « offshore », elles sont installées en mer, généralement au large des côtes. Il existe deux principaux types d'éoliennes offshore :

- **Éoliennes offshore fixes**

Ces éoliennes sont solidement ancrées au fond marin, que ce soit dans des eaux peu profondes ou dans des zones maritimes plus profondes.

- **Éoliennes offshore flottantes**

Ces éoliennes, flottant à la surface de l'eau, sont stabilisées par des câbles ancrés au fond marin. Elles exploitent les vents marins, généralement plus puissants et constants que ceux terrestres, ce qui les rend idéales pour une production d'énergie à grande échelle.

La figure 2.26 montre les deux types d'éoliennes maritimes (offshore).

2.6.10.3 Type de génératrice électrique

La classification des éoliennes par type de génératrice est un facteur technique clé qui impacte leur conception, fonctionnement et applications. Les génératrices électriques, responsables de la conversion de l'énergie mécanique en énergie électrique, peuvent être directement connectées au réseau ou couplées via un convertisseur de puissance. Elles se divisent en deux catégories : les machines synchrones (MS) et les machines asynchrones (MAS), fonctionnant à vitesse fixe ou variable. La figure 2.27 illustre les différents types de génératrices dans les systèmes de conversion d'énergie éolienne (SCEE).



(a) Éolienne maritime fixe.



(b) Éolienne maritime flottante.

FIGURE 2.26 – Parc éolien maritime.

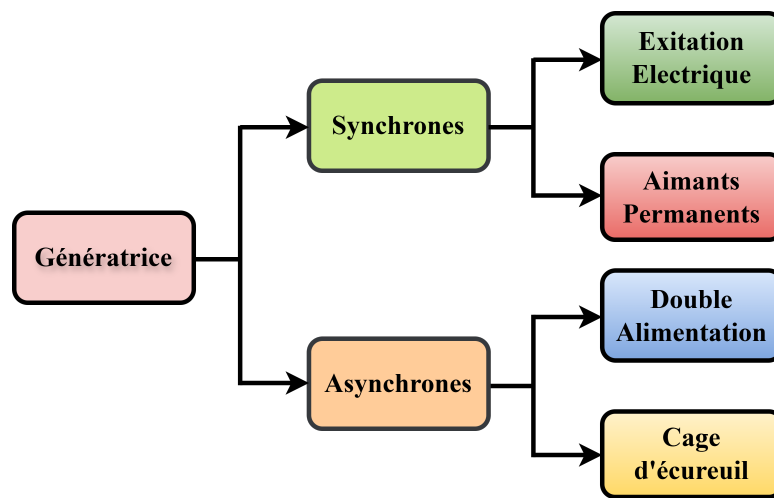


FIGURE 2.27 – Principaux types de génératrices utilisées dans les SCEE.

- **Génératrices synchrones**

Ces génératrices peuvent être conçues avec ou sans aimants permanents (à excitation). Elles sont privilégiées pour leur capacité à produire une fréquence stable et à fonctionner à une vitesse constante. En raison de ces caractéristiques, elles sont particulièrement adaptées aux installations d'éoliennes connectées directement au réseau électrique [30].

- **Génératrices asynchrones**

Ce type de génératrice se décline principalement en deux variantes : les machines asynchrones à cage d'écureuil (MASCE), également appelées machines à induction, et les machines asynchrones à double alimentation (MASDA). Elles sont choisies pour leur flexibilité, leur capacité à supporter des variations de charge et leur aptitude à fonctionner à une vitesse variable [30]. Ces génératrices sont généralement connectées au réseau électrique via des systèmes de conversion, tels que des convertisseurs de fréquence et de puissance bidirectionnels.

2.6.10.4 Vitesse de fonctionnement

La classification des éoliennes en fonction de la vitesse de fonctionnement se divise principalement en trois catégories : les éoliennes à vitesse fixe, les éoliennes à vitesse variable, et les éoliennes à vitesse semi-variable.

- **Éoliennes à vitesse fixe ou constante**

Les éoliennes à vitesse fixe, principalement utilisées dans les anciens modèles, fonctionnent à vitesse constante, indépendamment des variations de vent. Elles utilisent une génératrice à induction directement connectée au réseau, à condition que le vent permette de dépasser la vitesse synchrone. Elles se distinguent par leur conception simple, leur robustesse et leur coût réduit [30, 31].

- **Éoliennes à vitesse variable**

Les éoliennes à vitesse variable, dominantes aujourd'hui, optimisent l'efficacité aérodynamique et la production énergétique en ajustant leur vitesse de rotation selon les variations du vent. Elles utilisent un convertisseur de puissance pour réguler la vitesse de la génératrice et gérer les fluctuations du vent [30, 31]. Cette technologie améliore la capture d'énergie, la qualité de l'électricité, et la durabilité du système, malgré un coût plus élevé.

- **Éoliennes à vitesse semi-variable**

Ce type d'éoliennes représente un compromis entre les modèles à vitesse fixe et variable, optimisant le rendement sur deux plages de vitesses de vent distinctes. Elles utilisent une génératrice asynchrone à rotor bobiné avec excitation électronique pour une variation partielle de la vitesse, ou une génératrice asynchrone à double stator, dont les enroulements sont adaptés aux vitesses élevées et faibles. Bien que capable de s'ajuster à deux points de fonctionnement, leur adaptation reste limitée, avec un coût intermédiaire.

2.6.10.5 Taille et puissance

Les éoliennes se classent aussi selon leur taille et la puissance produite, qui dépendent de la vitesse du vent ainsi que de la longueur et de la forme des pales. La figure 2.28 montre l'évolution des dimensions des éoliennes terrestres de 1980 à 2020, révélant une augmentation constante de leur taille. Elles se répartissent par ailleurs en quatre catégories principales selon leur puissance nominale.

- **Éoliennes de petite puissance** : Inférieures à 100 kW ;
- **Éoliennes de moyenne puissance** : Supérieures à 100 kW et inférieures à 1 MW ;
- **Éoliennes de forte puissance** : Supérieures à 1 MW et inférieures à 10 MW ;
- **Éoliennes de très forte puissance** : Supérieures à 10 MW.

2.7 Quelques équations fondamentales de l'énergie éolienne

L'exploitation de l'énergie éolienne s'appuie sur un ensemble d'équations fondamentales, indispensables à la conception, l'analyse, le dimensionnement et l'optimisation des systèmes éoliens. Ces équations permettent de comprendre le fonctionnement des éoliennes, de modéliser les processus impliqués, et d'évaluer ou prédire leurs performances énergétiques. Parmi les principales équations utilisées dans ce domaine, on retrouve notamment :




FIGURE 2.28 – Évolution de la taille (hauteur du mat et diamètre du rotor) et de la puissance nominale des éoliennes.

• **Équation de l'énergie cinétique du vent**

L'énergie cinétique du vent dépend de sa masse du volume d'air et de la vitesse du vent, elle est exprimée par la formule suivante :

$$E_c = \frac{1}{2}mv^2 \tag{2.1}$$

où :

- E_c : l'énergie cinétique du vent (en joules, J),
- m : la masse du volume d'air (en kilogrammes, kg),
- v : la vitesse du vent (en mètres par seconde, m/s).

• **Surface balayée de l'éolienne**

La surface balayée S par les pales d'une éolienne est circulaire peut être exprimée par l'équation suivante :

$$S = \pi r^2 \tag{2.2}$$

où :

r : est le rayon du rotor de l'éolienne.

• **Équation de la Puissance du vent**

La puissance cinétique P du vent est la quantité d'énergie que le vent transporte par unité de temps qui frappe une éolienne avec une surface balayée S peut être donnée par l'équation suivante :

$$P = \frac{1}{2}\rho Sv^3 \tag{2.3}$$

où :

- P : la puissance cinétique du vent (en watts).
- ρ : est la masse volumique de l'air (kg/m^3),
- v : la vitesse du vent (m/s),
- S : la surface balayée par les pales de l'éolienne (m^2).

- **Rapport de vitesse de pointe (RVP)**

Le rapport de vitesse de pointe μ est un facteur important dans la conception des éoliennes, il peut être calculé comme suit :

$$\mu = \frac{\omega}{v} R \quad (2.4)$$

où :

ω : la vitesse angulaire du rotor (rad/s),

R : le rayon du rotor (m),

v : la vitesse du vent (m/s).

- **Coefficient de puissance (C_p)**

Le coefficient de puissance est un indicateur important de la performance d'une éolienne, il représente l'efficacité de l'éolienne à convertir la puissance du vent en puissance mécanique. Il est défini par la formule suivante :

$$C_p = \frac{P_{\text{éolienne}}}{P_{\text{disponible}}} \quad (2.5)$$

Il dépend de la conception de l'éolienne et de la vitesse du vent. Le coefficient de puissance maximal est atteint pour une vitesse du vent particulière appelée vitesse de Betz. Il est compris entre 0 et 0.5926. Chaque type d'éolienne a son propre coefficient de puissance.

- **Production de puissance de l'éolienne**

La puissance électrique réelle $P_{\text{élect}}$ produite par une éolienne peut être estimée par :

$$P_{\text{élect}} = \frac{1}{2} \rho S v^3 C_p \quad (2.6)$$

où :

$P_{\text{élect}}$: est la puissance électrique générée par l'éolienne (Watts),

ρ : la densité de l'air (kg/m^3),

S : la surface balayée par les pales de l'éolienne (m^2),

v : la vitesse du vent (m/s),

C_p : le coefficient de performance de l'éolienne.

2.8 Avantages et inconvénients de l'énergie éolienne

L'énergie éolienne est l'une des formes d'énergie renouvelable les plus répandues à travers le monde et représente l'une des sources d'électricité à la croissance la plus rapide. Bien qu'elle offre de nombreux avantages environnementaux, elle s'accompagne également de certains inconvénients significatifs. Voici une synthèse des principaux atouts et limites de l'énergie éolienne :

2.8.1 Avantages

- **Énergie propre** : Contrairement aux sources d'énergie fossile telles que le charbon, le gaz naturel ou le pétrole, la production d'électricité à partir de l'énergie éolienne ne génère aucune émission de gaz à effet de serre. De plus, l'énergie éolienne est entièrement renouvelable et inépuisable, car le vent est un phénomène naturel permanent dans l'atmosphère, à l'opposé des ressources fossiles, qui se régénèrent très lentement.

- **Création d'emplois** : L'industrie de l'énergie éolienne génère des milliers d'emplois dans divers secteurs, notamment la fabrication des éoliennes, le développement de projets, ainsi que l'installation et la maintenance des infrastructures nécessaires.

- **Coûts d'exploitation réduits** : Bien que les coûts initiaux d'installation des parcs éoliens ou des éoliennes individuelles puissent être élevés, les coûts d'exploitation associés à ces systèmes sont relativement faibles à long terme, ce qui rend l'énergie éolienne économiquement avantageuse.

- **Optimisation de l'utilisation de l'espace** : Malgré la nécessité de vastes espaces terrestres pour installer des parcs éoliens, les turbines et les équipements eux-mêmes ne requièrent pas une grande surface. De ce fait, les terrains utilisés pour l'installation des éoliennes peuvent souvent être exploités à d'autres fins, telles que l'agriculture, ce qui permet une utilisation optimale des terres.

2.8.2 Inconvénients

- **Intermittence de la production** : L'énergie éolienne est intermittente, car elle dépend des conditions météorologiques. Lorsque le vent est insuffisant, les éoliennes ne produisent pas d'électricité, ce qui limite leur disponibilité, notamment lors des périodes de forte demande. Pour assurer une utilisation continue, il est essentiel de les associer à des technologies de stockage d'énergie.

- **Nuisances sonore et visuelle** : L'un des inconvénients majeurs de l'énergie éolienne réside dans la nuisance sonore et visuelle qu'elle engendre. Les éoliennes génèrent du bruit en raison de leurs mécanismes internes et du mouvement de l'air autour des pales. Par ailleurs, étant donné leur taille imposante, elles peuvent perturber des paysages naturels autrement attrayants, tels que les chaînes de montagnes, les lacs ou les zones côtières.

- **Impacts environnementaux** : Les éoliennes peuvent impacter la faune, notamment les oiseaux et chauves-souris, et perturber les habitats naturels. Cependant, ces effets peuvent être réduits grâce aux avancées technologiques et à une implantation adaptée.

- **Transport et infrastructure** : L'un des défis associés à l'énergie éolienne réside dans la nécessité de transporter l'électricité produite depuis des sites éloignés des zones urbaines où la demande est concentrée. Cela nécessite la mise en place de lignes de transmission supplémentaires, ce qui constitue un coût et un investissement infrastructurel considérable pour la réussite de cette forme de production énergétique.

2.9 Conclusion

Dans ce chapitre, nous avons présenté une synthèse des fondements de l'énergie éolienne, en retraçant son évolution historique et en exposant ses principes fondamentaux. Nous avons examiné les caractéristiques essentielles du vent, qui constituent la base de cette source d'énergie, et analysé les différentes technologies d'éoliennes disponibles, tout en évaluant leur contribution et leur impact dans le paysage énergétique mondial. Cette exploration met en lumière le rôle crucial de l'énergie éolienne dans la transition énergétique globale, où elle s'impose comme une solution clé face aux défis environnementaux et à la nécessité de diversifier les sources d'énergie. En offrant des perspectives sur ses avantages et ses limites, nous avons établi une base pour comprendre son importance stratégique.

Le chapitre suivant portera sur les méthodes modernes de prédiction de la vitesse du vent. Une modélisation et une estimation précises de cette vitesse sont essentielles non seulement pour optimiser les performances des parcs éoliens, mais également pour maximiser leur rentabilité économique. Dans un contexte où la demande d'énergie renouvelable ne cesse de croître, ces avancées jouent un rôle déterminant pour garantir une production énergétique stable et durable.

CHAPITRE 3

ÉTAT DE L'ART SUR LA PRÉDICTION DE LA VITESSE DU VENT

Sommaire du chapitre

3.1 Introduction	34
3.2 Classification des méthodes de prédiction de la vitesse du vent	35
3.2.1 Échelle temporelle	35
3.2.2 Objectif de prédiction	36
3.2.3 Nature ou type du modèle	37
3.2.4 Théorie de modélisation	37
3.3 Sources et techniques de prétraitement des données	39
3.3.1 Sources de données	40
3.3.2 Techniques de prétraitement de données	40
3.4 Évaluation des performances des modèles de prédiction	42
3.5 Approches de prédiction de la vitesse du vent	42
3.5.1 Prédiction à très court terme	42
3.5.2 Prédiction à court terme	43
3.5.3 Prédiction à moyen terme	43
3.5.4 Prédiction à long terme	44
3.6 Conclusion	45

3.1 Introduction

La prédiction précise de la vitesse du vent représente un enjeu stratégique pour le développement durable des énergies renouvelables, en particulier dans le domaine de la production éolienne. Elle joue un rôle essentiel non seulement dans l'optimisation de la production énergétique, mais aussi dans l'intégration efficace de cette source intermittente aux réseaux électriques intelligents, contribuant ainsi à leur stabilité et à la rentabilité économique des installations. Dans le contexte actuel de transition énergétique mondiale, la fiabilité des prévisions de vent est devenue une nécessité pour répondre à la demande croissante en électricité propre et stable. Toutefois, cet objectif se heurte à la nature instable et imprévisible du vent, résultant de l'interaction de nombreux facteurs géographiques, météorologiques et

temporels. La complexité inhérente à ces phénomènes impose le recours à des techniques de modélisation sophistiquées. Face à ces défis, une grande variété d'approches a émergé au fil des années. Celles-ci peuvent être classées selon plusieurs dimensions : l'horizon temporel de prédiction, l'objectif visé par la prévision, la nature du modèle adopté (déterministe ou probabiliste), ainsi que la théorie de modélisation sous-jacente, qu'elle soit physique, statistique, issue de l'intelligence artificielle, ou encore hybride.

Parallèlement, la qualité des prédictions repose largement sur les données disponibles et les techniques de prétraitement mises en œuvre. Ces dernières incluent la réduction de la dimensionnalité, la décomposition des séries temporelles, ainsi que le débruitage des signaux, toutes indispensables pour capter les dynamiques complexes du vent.

Ce chapitre propose ainsi une revue de littérature détaillée des méthodes existantes, en suivant une structuration claire selon les critères précités. Il aborde également les principaux indicateurs d'évaluation des performances des modèles et présente un panorama des travaux récents classés selon les différents horizons de prédiction (très court, court, moyen et long terme), offrant une vue d'ensemble critique et actualisée de l'état de l'art.

3.2 Classification des méthodes de prédiction de la vitesse du vent

Au fil du temps, un large éventail d'approches de prédiction de la vitesse du vent a été développé, mis en œuvre et perfectionné afin de relever les défis croissants liés à l'intégration de l'énergie éolienne dans les réseaux électriques. Ces méthodes se différencient selon plusieurs critères essentiels, notamment l'échelle temporelle de la prévision, l'objectif spécifique de la prédiction, la nature du modèle employé (déterministe ou probabiliste), ainsi que la théorie de modélisation sous-jacente. Parmi les approches de modélisation, on distingue les modèles physiques, fondés sur la dynamique atmosphérique, les modèles statistiques classiques, les modèles reposant sur l'intelligence artificielle, ainsi que des modèles hybrides combinant plusieurs techniques pour tirer parti de leurs complémentarités. Cette diversité méthodologique contribue à améliorer la précision des prévisions, favorisant ainsi une gestion optimisée des réseaux électriques et une maximisation de l'efficacité de la production éolienne. La figure 3.1 présente une classification détaillée des principales méthodes de prédiction de la vitesse du vent, en tenant compte de plusieurs aspects fondamentaux : l'échelle temporelle, l'objectif de la prédiction, la nature ou le type du modèle, ainsi que la théorie de modélisation sous-jacente.

3.2.1 Échelle temporelle

L'échelle temporelle, également désignée sous le terme d'« horizon de prédiction », constitue un critère fondamental dans la prévision de la vitesse du vent. Cette échelle s'étend généralement de quelques secondes à plusieurs jours dans le futur. Elle est classiquement subdivisée en quatre catégories en fonction de la durée de la prédiction : très court terme, court terme, moyen terme et long terme. Le choix de la méthode de prédiction est étroitement lié à cet horizon temporel ainsi qu'à l'application envisagée [32, 33]. Le tableau 3.1 présente une synthèse des horizons de prédiction, en détaillant leurs caractéristiques ainsi que leurs domaines d'application respectifs.

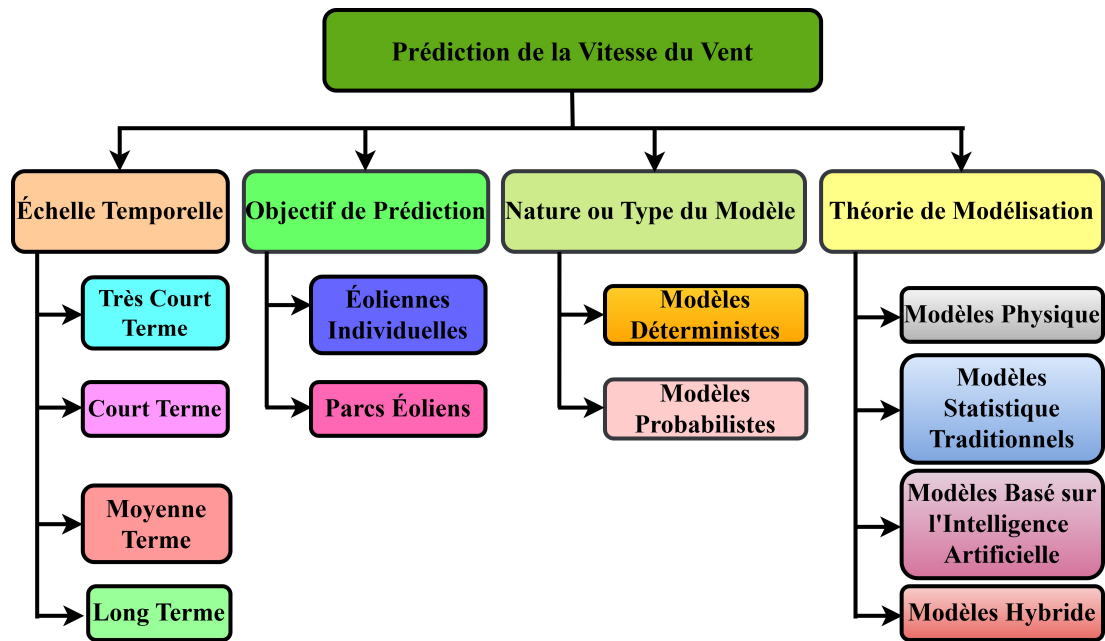


FIGURE 3.1 – Cadre taxonomique pour la prédiction de la vitesse du vent.

TABLE 3.1 – Classification des horizons de prédiction de la vitesse du vent.

Horizon de prédiction	Description	Application
Très court terme	Prédictions de la vitesse du vent pour des périodes allant de quelques secondes à 30 minutes à l'avance.	Régulation des turbines éoliennes et ajustements immédiats.
Court terme	Prédictions de la vitesse du vent pour des périodes comprises entre 30 minutes et 6 heures à l'avance.	Partage de la charge dans le réseau électrique.
Moyen terme	Prédictions de la vitesse du vent pour des périodes allant de 6 heures à 1 jour à l'avance.	Gestion des systèmes énergétiques et prédiction de la production d'énergie.
Long terme	Prédictions de la vitesse du vent pour des périodes supérieures à un jour.	Planification de la maintenance et gestion des réserves énergétiques.

Cette segmentation des échelles temporelles permet d'adapter les prévisions aux besoins opérationnels spécifiques et d'optimiser les modèles en fonction de l'horizon temporel considéré.

3.2.2 Objectif de prédiction

En fonction des objectifs, les modèles de prédiction de la vitesse du vent se répartissent en deux grandes catégories : ceux appliqués aux éoliennes individuelles et ceux destinés aux parcs éoliens. Les premiers cherchent à optimiser les performances des turbines en ajustant, par exemple, l'angle de tangage des pales à partir de prévisions à court terme [34]. Les seconds utilisent des données météorologiques et historiques pour modéliser l'incertitude et estimer la production globale, facilitant ainsi la planification des ressources et l'intégration de l'énergie éolienne dans le réseau [35].

3.2.3 Nature ou type du modèle

Selon leur nature, les modèles de prédiction de la vitesse du vent se répartissent en deux grandes catégories : les modèles déterministes et les modèles probabilistes.

3.2.3.1 Modèles déterministes

Les modèles déterministes de prédiction de la vitesse du vent visent à fournir une estimation unique de la valeur future de la vitesse du vent à un instant et en un lieu précis, relevant ainsi d'une approche de prédiction ponctuelle. Fondés majoritairement sur des équations physiques décrivant la dynamique atmosphérique, ces modèles sont particulièrement pertinents pour les prévisions à court terme nécessitant une haute résolution spatiale. Toutefois, la complexité intrinsèque des phénomènes météorologiques peut limiter leur efficacité, entraînant des erreurs notables dans les résultats de prédiction [36, 37].

3.2.3.2 Modèles probabilistes

Les modèles probabilistes de prédiction de la vitesse du vent sont essentiels pour gérer les incertitudes inhérentes à la production d'énergie éolienne. Contrairement aux modèles déterministes qui fournissent une seule estimation, les approches probabilistes quantifient cette incertitude en générant des intervalles de confiance [36]. La prédiction de l'incertitude se divise en deux grandes catégories : les méthodes paramétriques, qui reposent sur une hypothèse de distribution de probabilité spécifique, et les méthodes non paramétriques, qui permettent de construire des intervalles de prédiction fiables sans faire d'hypothèses strictes sur la distribution des erreurs [37]. Ces approches améliorent la gestion des risques et renforcent la stabilité des prévisions dans des environnements caractérisés par une forte variabilité et incertitude.

3.2.4 Théorie de modélisation

Selon les fondements théoriques de modélisation, les modèles de prédiction de la vitesse du vent se subdivisent en quatre catégories distinctes : les modèles physiques, les modèles statistiques classiques, les modèles fondés sur l'intelligence artificielle (IA) ainsi que les modèles hybrides combinant plusieurs approches [38].

3.2.4.1 Modèles physiques

Les modèles physiques destinés à la prédiction de la vitesse du vent s'appuient sur des équations complexes décrivant la dynamique atmosphérique. Ces méthodes reposent principalement sur des modèles tels que la prévision numérique du temps (NWP) [39] et le modèle météorologique de recherche (WRF) [40]. Ces derniers intègrent divers paramètres météorologiques, notamment la pression atmosphérique, l'humidité et la température, afin de fournir des estimations précises de la vitesse du vent [41]. Par ailleurs, les modèles physiques tiennent compte des conditions spécifiques du site éolien, ce qui permet d'affiner les prédictions à une échelle locale [38, 42]. Ces approches se révèlent particulièrement efficaces pour les prévisions à moyen et long terme, jouant un rôle essentiel dans l'intégration des énergies renouvelables au sein des réseaux électriques.

3.2.4.2 Modèles statistiques traditionnels

Les modèles statistiques traditionnels exploitent les données historiques pour établir des relations entre variables d'entrée et de sortie. Parmi eux figurent les modèles AR, ARMA, ARIMA et SARIMA, largement utilisés pour les prévisions à court terme, allant de quelques heures à plusieurs jours [41, 43]. Ces méthodes sont appréciées pour leur simplicité et leur rapidité de calcul, mais leur précision diminue avec l'allongement de l'horizon de prédiction. Elles restent toutefois limitées face aux variations atmosphériques imprévisibles, pouvant engendrer des erreurs significatives [38, 42]. Contrairement aux modèles physiques, ces approches, basées sur l'analyse des séries temporelles, modélisent principalement les fluctuations linéaires de la vitesse du vent et sont souvent combinées aux modèles physiques pour améliorer la précision des prévisions à court terme [41].

3.2.4.3 Modèles basés sur l'intelligence artificielle

Récemment, avec l'essor rapide des technologies informatiques et des techniques d'IA, de nombreuses méthodes et modèles de prédiction de la vitesse du vent ont été développés dans le but d'améliorer la précision des prévisions. Ces techniques d'IA englobent notamment les algorithmes d'apprentissage automatique (AA) ainsi que les méthodes d'apprentissage profond (AP) [44].

•Algorithmes d'apprentissage automatique

Les algorithmes d'apprentissage automatique (Machine Learning) ont largement contribué à la prédiction de la vitesse du vent. Parmi les méthodes les plus efficaces et couramment utilisées figurent les forêts aléatoires (Random Forests, RF) [45], les machines à vecteurs de support (Support Vector Machines, SVM) [46] et la régression par vecteur de support (Support Vector Regression, SVR). Plusieurs études ont démontré que ces techniques améliorent la précision des prévisions en exploitant de vastes ensembles de données historiques météorologiques [47, 48]. Ces résultats confirment l'importance de l'apprentissage automatique pour les prédictions à court et moyen terme, voire parfois à long terme, notamment dans des contextes où une haute précision est nécessaire pour optimiser la gestion des parcs éoliens.

Les réseaux de neurones artificiels (RNA), inspirés du fonctionnement des neurones biologiques, constituent une des approches d'apprentissage automatique les plus répandues. Leur succès en IA s'explique par leur capacité à modéliser des phénomènes complexes. Au cours de la dernière décennie, les RNA ont été largement appliqués à divers problèmes, tels que le contrôle automatique, la classification, l'optimisation, l'approximation de fonctions, la régression et la prédiction [49]. De nombreuses études ont montré que les RNA surpassent souvent les modèles statistiques traditionnels dans la prédiction de la vitesse du vent, en intégrant plusieurs variables météorologiques telles que la température, la pression atmosphérique et l'humidité [49–51]. Ces caractéristiques rendent les RNA particulièrement adaptés à la gestion des parcs éoliens et à la planification de la production énergétique.

•Techniques d'apprentissage profond (Deep Learning)

Le développement récent des techniques d'apprentissage profond, en particulier des réseaux de neurones récurrents à mémoire longue à court terme (Long Short-Term Memory, LSTM) [52] et des réseaux de neurones convolutifs (Convolutional Neural Networks, CNN) [53], a conduit à des avancées significatives dans l'amélioration de la précision des prévisions de la vitesse du vent. Ces modèles se distinguent par leur capacité à traiter des

phénomènes non linéaires complexes, surpassant ainsi les performances des modèles classiques de prédiction [54, 55]. Les réseaux LSTM, en particulier, sont capables de capturer des dépendances à long terme au sein des séries temporelles, permettant des prévisions plus fiables même dans des conditions de vent variables et imprévisibles [56]. Par ailleurs, les réseaux CNN extraient efficacement des caractéristiques spatiales et temporelles, ce qui leur permet de modéliser les corrélations spatiales présentes dans les données [55]. Parmi les variantes notables, le LSTM bidirectionnel (BiLSTM) [57], qui traite les séquences temporelles dans les deux directions, ainsi que l'unité récurrente à portes (Gated Recurrent Unit, GRU) [58], offrant une architecture plus légère tout en maintenant des performances élevées, ont contribué à améliorer sensiblement la précision des prévisions de la vitesse du vent [59, 60]. L'utilisation de ces réseaux profonds fournit ainsi des modèles robustes pour la prédiction de la vitesse du vent, contribuant à une gestion optimisée des ressources éoliennes, à l'amélioration de la production énergétique, et à l'assurance de la stabilité des réseaux électriques.

3.2.4.4 Modèles hybrides

Les modèles hybrides sont conçus en combinant différents types de modèles afin de capturer la diversité des fluctuations de la vitesse du vent. Ces approches intègrent les avantages complémentaires de plusieurs modèles de prédiction et peuvent être classées en deux grandes catégories selon leur stratégie d'hybridation : les modèles basés sur l'optimisation métaheuristique et ceux fondés sur l'apprentissage par ensemble [61]. Les modèles reposant sur l'optimisation métaheuristique combinent une diversité de prédicteurs afin de saisir différentes dimensions de la variabilité du vent [62]. Dans ce cadre, les coefficients de combinaison sont optimisés à l'aide d'algorithmes intelligents tels que les algorithmes génétiques (GA) [63] ou l'optimisation par essaims particulaires (Particle Swarm Optimization, PSO) [64]. Ces techniques permettent d'identifier les combinaisons optimales de prédicteurs et de paramètres pour minimiser les erreurs tout en maximisant la précision des prévisions [65, 66]. Par ailleurs, les modèles fondés sur l'apprentissage par ensemble reposent sur des méthodes telles que le bagging, le boosting ou l'empilement (stacking), qui agrègent les prédictions issues de multiples modèles de base afin d'améliorer la robustesse globale du système prédictif [67, 68]. Ces deux stratégies complémentaires contribuent ainsi à une amélioration significative de la précision et de la fiabilité des prévisions de la vitesse du vent, en tirant parti des forces respectives de chaque modèle au sein d'une architecture hybride.

3.3 Sources et techniques de prétraitement des données

La précision des modèles de prédiction de la vitesse du vent dépend étroitement de la qualité des données ainsi que des techniques de traitement appliquées. Les données exploitées proviennent de sources variées, incluant des mesures météorologiques, des archives historiques et des informations géographiques, fournissant une compréhension fine des variations temporelles et spatiales du vent [69, 70]. Toutefois, ces données sont souvent affectées par du bruit et une complexité intrinsèque, ce qui impose l'utilisation de méthodes de prétraitement sophistiquées afin d'extraire les caractéristiques pertinentes et d'améliorer la précision des prévisions [70]. La combinaison judicieuse de diverses sources de données avec des techniques de traitement adaptées permet ainsi d'optimiser les performances des modèles de prédiction de la vitesse du vent.

3.3.1 Sources de données

La prédiction de la vitesse du vent s'appuie sur l'exploitation de diverses sources de données, généralement classées selon leur origine : données géographiques, données issues des prévisions météorologiques numériques (NWP), données historiques ainsi que données de surveillance en temps réel. Chacune de ces sources contribue de manière significative à l'amélioration de la précision des modèles de prédiction [69, 70]. Ces données sont recueillies à l'aide d'instruments variés, tels que les stations météorologiques terrestres, les satellites, ou encore d'autres dispositifs, dans des environnements atmosphériques et géographiques diversifiés. En raison de cette diversité et des éventuelles imperfections inhérentes aux mesures, un prétraitement des données s'avère indispensable pour optimiser la précision des prévisions de la vitesse du vent.

3.3.2 Techniques de prétraitement de données

Les techniques de prétraitement des données jouent un rôle crucial dans l'amélioration de la qualité et de la précision des prédictions de la vitesse du vent. Elles consistent à préparer les données brutes avant leur exploitation par les modèles prédictifs, afin de minimiser les erreurs et d'optimiser la performance des modèles. Parmi les méthodes couramment employées figurent les approches basées sur la réduction de la dimensionnalité, les techniques de décomposition des séries temporelles ainsi que les méthodes de débruitage des données.

3.3.2.1 Techniques basées sur la réduction de la dimensionnalité

Les approches de réduction de la dimensionnalité jouent un rôle crucial dans la gestion de la complexité croissante des données météorologiques utilisées pour la prédiction de la vitesse du vent. En présence de vastes ensembles de données, ces techniques permettent non seulement d'améliorer la précision des modèles prédictifs, mais également de réduire la charge computationnelle en éliminant les redondances et les variables non informatives [71–73]. Deux grandes catégories sont généralement distinguées : la sélection de caractéristiques et l'extraction de caractéristiques. La première consiste à identifier un sous-ensemble optimal de variables d'entrée à partir de l'ensemble initial, tandis que la seconde crée de nouvelles variables (ou composantes) à partir de transformations des données originales. Parmi les techniques de sélection de caractéristiques, on retrouve des approches basées sur le clustering, telles que le clustering spectral, le k-means, le fuzzy c-means (FCM) ou encore les cartes auto-organisatrices (Self-Organizing Maps, SOM) [74–77]. D'autres méthodes s'appuient sur l'analyse des corrélations, en utilisant des outils statistiques comme la fonction d'autocorrélation (ACF) et la fonction de corrélation partielle (PACF) [78], ou sur des critères informationnels tels que l'information mutuelle (MI) et l'information mutuelle conditionnelle (CMI) [79, 80]. Du côté de l'extraction de caractéristiques, des techniques bien établies comme l'analyse en composantes principales (PCA) et sa version non linéaire, l'analyse en composantes principales par noyau (Kernel PCA, KPCA), sont largement utilisées pour réduire la dimensionnalité tout en préservant l'essentiel de la variance contenue dans les données d'origine [81, 82]. L'intégration de ces méthodes dans les pipelines de prédiction permet d'améliorer significativement les performances des modèles, notamment dans les contextes marqués par une forte hétérogénéité des données.

3.3.2.2 Techniques basées sur la décomposition des séries temporelles

Les techniques basées sur la décomposition des séries temporelles jouent un rôle déterminant dans l'amélioration de la précision des prévisions de la vitesse du vent. Leur principe repose sur la division d'une série complexe et non stationnaire en sous-séries plus simples et relativement stationnaires, facilitant ainsi l'application de modèles prédictifs plus performants. Chaque composante est prédite séparément, puis les résultats sont recombinaés pour fournir une estimation globale. Parmi ces approches, les méthodes basées sur la décomposition en ondelettes occupent une place centrale. Celles-ci incluent la transformation en ondelettes discrètes (Discrete Wavelet Transform, DWT) [83], la décomposition en paquets d'ondelettes (Wavelet Packet Decomposition, WPD) [84], ainsi que la décomposition par ondelettes empiriques (Empirical Wavelet Transform, EWT) [85]. D'autres techniques notables reposent sur la décomposition en modes intrinsèques (Empirical Mode Decomposition, EMD) [86] et ses variantes, telles que l'Ensemble Empirical Mode Decomposition (EEMD) [87], la Fast Ensemble EMD (FEEMD) [88], la Complementary Ensemble EMD (CEEMD) [89], et la Complete Ensemble EMD with Adaptive Noise (CEEMDAN) [90, 91]. Ces méthodes permettent d'extraire des composantes oscillatoires représentatives des dynamiques sous-jacentes du vent. Plus récemment, la Variational Mode Decomposition (VMD) a émergé comme une alternative puissante. Elle consiste à décomposer le signal en modes ayant des bandes fréquentielles spécifiques, offrant une plus grande robustesse face aux fluctuations irrégulières du vent [92, 93]. Lorsqu'elles sont intégrées à des techniques d'apprentissage automatique, ces méthodes de décomposition permettent de construire des modèles hybrides particulièrement performants, adaptés aux environnements caractérisés par une forte variabilité météorologique.

3.3.2.3 Techniques basées sur le débruitage de données

Les approches de débruitage des données jouent un rôle fondamental dans l'amélioration de la qualité des données utilisées pour la prédiction de la vitesse du vent. Le bruit, qu'il soit d'origine instrumentale ou environnementale, peut fortement altérer la précision des modèles prédictifs. Ces méthodes visent à supprimer les composantes parasites tout en préservant les structures significatives des séries temporelles [94]. Parmi les techniques les plus couramment employées, on retrouve des méthodes de décomposition qui consistent à fragmenter la série temporelle en sous-séries plus simples pour mieux localiser et isoler les composantes bruitées. L'analyse en spectre singulier (Singular Spectrum Analysis, SSA) est particulièrement prisée pour sa capacité à extraire les tendances et les cycles dominants tout en filtrant le bruit [95]. De même, le débruitage par seuillage des ondelettes (Wavelet Thresholding Denoising, WTD) constitue une autre approche efficace. Elle repose sur la transformation en ondelettes et l'application de seuils aux coefficients obtenus, permettant ainsi de supprimer les fluctuations de haute fréquence tout en conservant les composantes essentielles du signal [96]. Aucune de ces techniques n'étant universellement supérieure, leur combinaison est souvent adoptée pour renforcer la robustesse du processus de prétraitement. L'intégration conjointe de plusieurs méthodes permet généralement de produire des données d'entrée de meilleure qualité, ce qui se traduit par une amélioration significative de la performance des modèles prédictifs.

3.4 Évaluation des performances des modèles de prédiction

L'évaluation rigoureuse des performances des modèles de prédiction de la vitesse du vent est essentielle pour garantir leur précision et leur fiabilité dans des applications opérationnelles, telles que la gestion des parcs éoliens et l'intégration de l'énergie éolienne aux réseaux électriques [36,37]. Plusieurs indicateurs statistiques sont couramment utilisés pour quantifier l'efficacité des prévisions. Parmi eux, l'erreur absolue moyenne (Mean Absolute Error, MAE), l'erreur quadratique moyenne (Root Mean Square Error, RMSE), l'erreur absolue symétrique en pourcentage (Symmetric Mean Absolute Percentage Error, SMAPE) et le coefficient de détermination (R^2) sont les plus répandus [38, 47]. Ces métriques permettent de mesurer l'écart entre les valeurs observées et prédites, offrant ainsi une évaluation complète de la précision globale du modèle ainsi que de sa robustesse face aux variations des conditions météorologiques.

3.5 Approches de prédiction de la vitesse du vent

La prédiction de la vitesse du vent s'appuie sur une diversité de techniques adaptées aux différentes échelles temporelles et aux objectifs spécifiques de la prévision. Parmi les méthodes couramment utilisées figurent les approches déterministes, probabilistes, celles fondées sur l'intelligence artificielle ainsi que les modèles hybrides. Cette section propose une revue de quelques approches récentes rapportées dans la littérature, accompagnée d'une brève description de chacune d'entre elles.

3.5.1 Prédiction à très court terme

Ces dernières années, de nombreux modèles ont été développés pour la prédiction très court terme de la vitesse du vent, avec des performances améliorées en précision et stabilité. Par exemple, un modèle hybride combinant un réseau de neurones récurrents à mémoire longue et courte (LSTM) et un réseau convolutif (CNN), nommé CLSTM, a été appliqué à des données semi-horaires sur 27 mois, incluant vitesse du vent, température et humidité [97]. Ce modèle prévoit la vitesse jusqu'à six pas de temps (chaque pas = 30 min), avec des RMSE entre 0,581 et 1,198, et des MAPE variant de 2% à 6,4%, la meilleure corrélation (93%) étant observée au premier pas. Une autre étude [98] a comparé plusieurs modèles de machine learning pour une prédiction jusqu'à cinq minutes, utilisant des données d'une minute à 80 m de hauteur (NREL). Le régresseur à couches multiples (MLPR) a montré la meilleure performance avec un RMSE de 0,819 et un MAPE de 1,43% à un pas (1 min), bien que la précision diminue avec l'horizon de prédiction. Un modèle combiné ARIMA-ANN a été proposé pour capturer les composantes linéaires et non linéaires des séries temporelles, avec un prétraitement par ICEEMDAN pour éliminer le bruit [99], appliqué à des données toutes les 10 minutes issues de quatre fermes éoliennes en Chine, ce modèle a obtenu un RMSE de 0,20 et un MAE de 0,16 pour une prédiction à un pas, surpassant d'autres approches. Pour améliorer la précision à court terme, une autre approche hybride utilise la décomposition en modes intrinsèques (EMD) associée à des modèles ANN et SVM [100]. Appliquée à des données horaires sur un mois, cette méthode a réduit le RMSE à 0,79–0,80 m/s, contre 1,25 m/s pour les modèles ANN seuls. Enfin, un modèle combinant EMD et modèle vectoriel autorégressif (VAR) a été développé pour la prédiction ultra-court terme, intégrant la corrélation spatiale entre points de mesure [101], testé sur des données toutes

les 10 minutes sur plusieurs points en Chine, il a réduit significativement les erreurs (RMSE moyen de 0,3621, MAPE de 4,87%) par rapport à VAR classique, forêts aléatoires et ANN.

3.5.2 Prédiction à court terme

Ces dernières années, plusieurs approches innovantes ont été développées pour la prédiction à court terme de la vitesse du vent. Dans [102], un modèle hybride combinant un réseau de neurones artificiels optimisé par un algorithme génétique et la décomposition en mode variationnel (VMD) est proposé. Ce modèle utilise un clustering hiérarchique pour sélectionner les données historiques pertinentes, décompose la série en sous-séquences via VMD, et prédit chaque sous-séquence indépendamment avant recombinaison. Testé sur un horizon de 10 minutes, il obtient une MAPE de 1,58% et un RMSE de 0,127 m/s, surpassant des méthodes traditionnelles comme le BP ou le GA-BP. Une autre méthode [103] repose sur la décomposition ICEEMDAN combinée à l'optimisation Grey Wolf Optimizer (GWO), intégrant plusieurs réseaux neuronaux (BPNN, ENN, WNN, GRNN). Validée sur des données de fermes éoliennes chinoises avec un pas de 10 minutes, cette approche atteint une MAE de 0,2201, un RMSE de 0,2994 et une MAPE de 3,02% à un pas, et maintient des performances supérieures pour des prédictions multi-pas. Dans [104], un modèle VMD-SSA-STACK combine décomposition en mode variationnel, analyse en spectre singulier (SSA) et apprentissage ensembliste par empilement (stacking) pour améliorer la précision, appliqué à des données brésiliennes avec horizons jusqu'à 60 minutes, ce modèle réduit la MAPE à 2,871% à 10 minutes, contre 3,789% pour un modèle VMD-SSA-LSTM, confirmant la supériorité de l'approche. L'étude [105] présente une méthode Jaya-SVM, optimisant la sélection des caractéristiques et les hyperparamètres via l'algorithme Jaya. Comparé à sept autres modèles, Jaya-SVM obtient les meilleures performances sur des données chinoises pour des horizons de 10 à 30 minutes, avec une MAPE de 11,87% à 10 minutes, et une supériorité confirmée sur les erreurs quadratiques moyennes et le coefficient de détermination. Enfin, [106] propose un modèle dynamique spatio-temporel basé sur un réseau d'attention dirigé par graphes (DSTDGAT), capable de capturer les corrélations dynamiques et asymétriques entre turbines. Testé sur des horizons de 1 à 12 heures, il atteint une MAE de 2,569 et un RMSE de 3,293 à 6 heures, surpassant des modèles de référence comme STGCN et GCDLA, démontrant ainsi son efficacité pour les prévisions à court terme.

3.5.3 Prédiction à moyen terme

Récemment, plusieurs méthodes performantes ont été proposées pour la prédiction à moyen terme de la vitesse du vent. Dans [107], un modèle fractionné ARIMA (f-ARIMA) a été appliqué à des données du Dakota du Nord (USA) sur un horizon de 24 à 48 heures, réduisant le RMSE de 42 % par rapport à la persistance, avec une robustesse conservée jusqu'à 48 heures malgré une légère dégradation au-delà de 24 heures. L'approche hybride EMD-WT-LSSVM décrite dans [108] combine décomposition modale empirique, transformation par ondelettes et machines à vecteurs de support pour atténuer la non-stationnarité des données sur un horizon d'une heure. Ce modèle atteint un MAPE de 4,53%, bien inférieur aux 16,38% du LS-SVM classique, illustrant l'efficacité de cette méthode pour la prédiction à court terme. Dans [104], une stratégie multi-étapes fondée sur VMD, SSA et apprentissage par empilement (stacking) est utilisée pour des horizons de 10, 30 et 60 minutes. Cette méthode améliore significativement la précision des prévisions, avec une réduction moyenne

de 56,61% des erreurs MAE et RMSE par rapport à des modèles sans décomposition. Le modèle CM-GMNN présenté dans [109] intègre un réseau convolutif à mémoire de porte minimale (ConvMGM) et un réseau neuronal graphique convolutionnel (GCN) pour la prédiction conjointe de la vitesse et de la direction du vent sur 1 à 5 heures. Il dépasse 90% des métriques évaluées par rapport aux approches existantes, bien que la précision décline avec l'allongement de l'horizon, la vitesse restant mieux prédite que la direction. Enfin, [110] propose un modèle hybride combinant VMD, BP, CNN et LSTM, où la décomposition VMD sépare les composantes fréquentielles, chacune traitée par un réseau spécifique. Sur un horizon de trois heures, ce modèle atteint un MAE de 0,681 et un RMSE de 0,899, surpassant les modèles CNN-LSTM et VMD-CNN-LSTM précédents.

3.5.4 Prédiction à long terme

Au cours des dernières années, plusieurs techniques avancées ont été développées pour la prédiction à long terme de la vitesse du vent, améliorant significativement la gestion des parcs éoliens et la planification énergétique sur des horizons de plusieurs jours à plusieurs semaines. L'approche combinée SDA-SVR-UKF, présentée dans [111], intègre la régression par vecteurs de support (SVR) pour les horizons courts (1–6 h), un auto-encodeur empilé de réduction de bruit (SDA) pour affiner les sorties des modèles numériques de prévision du temps (NWP) sur un horizon de 6 à 24 heures, ainsi qu'un filtre de Kalman Unscented (UKF). Cette méthode permet de réduire l'erreur quadratique moyenne (RMSE) à 1,28 m/s sur le court terme et à 2,53 m/s à 24 h, surpassant les modèles AR-KF et PCR-KF. Dans [112], un modèle hybride combinant l'optimisation par essaim de particules (PSO) et un réseau de neurones artificiels (ANN) est proposé pour la prédiction mensuelle de la vitesse du vent dans 67 villes indiennes. L'algorithme PSO optimise les poids initiaux de l'ANN, évitant ainsi les minima locaux. Le modèle atteint un MSE de 0,10 et un coefficient de détermination $R^2 = 0,98$, démontrant la supériorité de cette approche hybride par rapport à l'ANN traditionnel. Un autre modèle ANN, basé sur des données issues de la NASA couvrant 26 villes indiennes, est présenté dans [113]. Entraîné sur diverses variables climatiques et géographiques, ce modèle obtient un MSE de 0,0933 et un MAPE de 6,75 % en phase d'entraînement. Lors de la validation sur 39 localités du Maharashtra, les résultats sont de 0,48 pour le MSE et de 22,8 % pour le MAPE, attestant de la capacité du modèle à fournir des prédictions mensuelles fiables à long terme. L'étude comparative menée dans [114] évalue trois modèles de régression — Forêt Aléatoire (Random Forest), réseaux de neurones multicouches (MLP) et Gradient Boosting — sur des données météorologiques provenant de trois parcs éoliens situés dans le nord-est du Brésil. La Forêt Aléatoire s'illustre comme la plus performante avec un MAPE de 6,11 % pour le parc de Morro do Chapéu Sul, tandis que le MLP atteint 9,72 % à Praia Mansa. À Mangue Seco, la Forêt Aléatoire présente également les meilleurs résultats avec un MAPE de 7,72 %. Ces observations indiquent que la performance dépend du site, mais que la Forêt Aléatoire est globalement la méthode la plus efficace. Enfin, [115] propose un modèle basé sur plusieurs architectures de réseaux de neurones artificiels — réseau à rétro-propagation améliorée (IBPN), perceptron multicouche (MLPN), réseau à base radiale récursive (RBFN) et réseau Elman (ENN). Cinq variables d'entrée sont utilisées : direction du vent, température, humidité, précipitation et vitesse du vent. Le réseau RBFN, avec 31 neurones dans la couche cachée, montre les meilleures performances avec un MSE de $1,2781 \times 10^{-11}$, un RMSE de $3,5751 \times 10^{-6}$ et un MAE de $2,4435 \times 10^{-6}$. Ce modèle surpasse les autres en précision et fiabilité pour la prédiction à long terme de la vitesse du vent.

3.6 Conclusion

Ce chapitre a présenté une synthèse approfondie et structurée des approches existantes pour la prédiction de la vitesse du vent, en les classifiant selon plusieurs axes pertinents, tels que l'échelle temporelle (court, moyen et long terme), les objectifs visés (gestion en temps réel, planification énergétique, optimisation des ressources) ainsi que la nature des modèles utilisés (physiques, statistiques, fondés sur l'intelligence artificielle ou hybrides).

Chaque catégorie de méthode présente des atouts spécifiques, dépendant étroitement du contexte d'application et des exigences opérationnelles. Les modèles physiques offrent une interprétabilité forte mais nécessitent des données d'entrée exhaustives, tandis que les approches statistiques et l'apprentissage automatique, notamment celles basées sur les réseaux de neurones ou les algorithmes d'ensemble, ont démontré une capacité remarquable à capturer les non-linéarités inhérentes aux phénomènes éoliens. Les modèles hybrides, quant à eux, tirent parti des complémentarités entre différentes approches pour améliorer la robustesse et la précision des prédictions.

Une attention particulière a également été portée sur l'étape cruciale du prétraitement des données. Des techniques telles que la réduction de dimensionnalité, la décomposition des séries temporelles (comme EMD ou wavelets) et le débruitage se sont révélées déterminantes pour améliorer la qualité des signaux d'entrée et, par conséquent, les performances prédictives des modèles.

L'analyse comparative conduite à travers différentes échelles temporelles met en évidence que chaque horizon de prévision (quelques minutes, heures, jours ou mois) implique des défis distincts en termes de précision, de complexité algorithmique et de disponibilité des données. Il en découle que le choix de la méthode doit être soigneusement adapté aux besoins spécifiques de l'application considérée.

En somme, la revue présentée dans ce chapitre constitue une base méthodologique solide pour orienter les futures recherches sur la prévision de la vitesse du vent. Elle s'inscrit dans une dynamique scientifique visant à accompagner l'intégration croissante des énergies renouvelables dans les réseaux électriques intelligents, en réponse aux enjeux énergétiques et environnementaux modernes.

CHAPITRE 4

RÉDUCTION DE DIMENSIONNALITÉ POUR LA PRÉDICTION DE LA VITESSE DU VENT

Sommaire du chapitre

4.1 Introduction	46
4.2 Techniques de réduction de la dimensionnalité	47
4.2.1 Analyse en composantes principales	47
4.2.2 Analyse en composantes principales à noyau	49
4.2.3 Auto-encodeurs	50
4.3 Réseaux de neurones artificiels pour la prédiction de la vitesse du vent	52
4.3.1 Machines à apprentissage extrême	52
4.3.2 Réseaux neuronaux récurrents : l'approche Elman	54
4.4 Études de cas et résultats expérimentaux	54
4.4.1 Séries temporelles	55
4.4.2 Ensembles de données utilisés	55
4.4.3 Résultats expérimentaux	57
4.5 Conclusion	61

4.1 Introduction

L'énergie éolienne, en tant que source renouvelable, s'impose aujourd'hui comme une ressource stratégique à l'échelle mondiale. Historiquement exploitée pour la navigation maritime, le broyage des grains et le pompage de l'eau [116], elle occupe désormais une position centrale dans les politiques énergétiques visant à répondre à la demande croissante tout en limitant l'empreinte environnementale. Toutefois, son intégration optimale dans les réseaux électriques demeure un défi majeur [117]. En effet, ces réseaux, structurés autour des exigences de puissance, de capacité et de fiabilité, nécessitent une planification rigoureuse et une gestion dynamique pour faire face aux fluctuations inhérentes à la nature intermittente du vent [118].

Dans ce contexte, la prévision de la vitesse du vent constitue une priorité stratégique pour les gestionnaires de réseaux électriques, dans la mesure où elle contribue à atténuer

les risques associés à une alimentation instable ou intermittente [38]. Diverses approches de prédiction ont été proposées, allant des réseaux de neurones artificiels basés sur l'algorithme de rétropropagation et des modèles fondés sur la logique floue [32, 119], jusqu'aux filtres de Kalman [120] et aux méthodes à noyaux, reconnues pour leur robustesse et leur capacité de généralisation [121].

Au cours des dernières décennies, l'essor des techniques d'IA a considérablement élargi les perspectives en matière de prévision de la vitesse du vent et de la puissance éolienne. Des approches innovantes, telles que le data mining [122], les réseaux neuronaux profonds [123], ainsi que des techniques hybrides combinant ces réseaux avec des architectures de type réseaux de neurones artificiels (ANN), ont été proposées. Ces avancées soulignent l'importance d'une méthodologie robuste et intégrée, alliant outils statistiques et modèles d'apprentissage profond, pour relever les défis liés à la variabilité du vent et à son intégration optimale dans les réseaux électriques modernes.

Dans ce cadre, la réduction de dimensionnalité apparaît comme une étape cruciale. Elle permet d'optimiser les performances des algorithmes prédictifs en limitant la complexité computationnelle, en atténuant le risque de surapprentissage, tout en préservant les caractéristiques essentielles des données, ce qui améliore à la fois l'interprétabilité et la précision des modèles.

4.2 Techniques de réduction de la dimensionnalité

Ces techniques visent à simplifier la représentation des données tout en conservant leur contenu informationnel essentiel. Dans ce qui suit, un aperçu succinct est présenté des principales approches de réduction de dimensionnalité exploitées dans les travaux de cette thèse.

L'analyse en composantes principales (PCA) [124] permet de transformer les données initiales en un ensemble de variables indépendantes (composantes principales), facilitant ainsi la réduction de leur complexité. Le Kernel PCA (KPCA) [125], extension non linéaire de la PCA, exploite des fonctions noyaux pour capturer des relations complexes au sein des données. Quant aux autoencodeurs, ils reposent sur des réseaux de neurones artificiels capables d'apprendre une représentation compacte des données à travers un processus d'encodage et de décodage, tout en préservant les caractéristiques essentielles. Ces méthodes sont largement utilisées pour accroître l'efficacité des modèles d'apprentissage automatique, en particulier dans le traitement de données de grande dimension et à forte complexité.

4.2.1 Analyse en composantes principales

Dans le domaine de l'apprentissage automatique, la réduction de dimension constitue une étape cruciale dans la conception d'algorithmes efficaces, en particulier pour l'analyse de grands ensembles de données. Parmi les techniques les plus largement utilisées figure la PCA, qui vise à projeter les données d'un espace de dimension élevée vers un sous-espace de dimension inférieure tout en préservant l'essentiel de l'information.

La PCA identifie les directions principales, appelées composantes principales (PC), le long desquelles la variance des données est maximale. Cette approche permet ainsi de compresser les données tout en conservant leur structure fondamentale. Dans le cadre de l'analyse des séries temporelles, la PCA se révèle particulièrement utile pour réduire la taille des données historiques, en représentant chaque vecteur temporel par un nombre restreint de composantes significatives, au lieu de milliers de points initiaux. Cette réduction permet non seulement d'améliorer les performances des modèles prédictifs, mais également de limiter le risque de sur-apprentissage [124]. Le processus initial de notre système consiste à extraire les PCs à partir des séries temporelles observées. Ces composantes remplacent les variables d'origine et sont obtenues sous forme de combinaisons linéaires des séries initiales X . L'objectif est d'identifier les *vecteurs propres* de la matrice de covariance des données, lesquels définissent les directions des axes principaux le long desquelles la variance est maximale.

Chaque vecteur propre associé à une *valeur propre* représente une direction principale de la distribution des données, la valeur propre indiquant l'importance (ou la variance capturée) par cette direction. Ainsi, les composantes principales permettent une transformation des données vers un espace de plus faible dimension tout en préservant l'essentiel de l'information.

Ce processus s'articule selon les étapes suivantes dans le cadre de l'application de la PCA au sein de notre système de prédiction de la vitesse du vent :

1. **Centrage des données** : Pour chaque vecteur de série temporelle, on soustrait la moyenne de chaque variable individuelle. Cette opération permet de centrer les données autour de zéro, assurant ainsi que les variables transformées ont une moyenne nulle.
2. **Calcul de la matrice de covariance** : La matrice de covariance C est calculée comme suit :

$$C = \frac{1}{N} X \cdot X^T \quad (4.1)$$

où X représente la matrice des données centrées, et N le nombre d'observations.

3. **Détermination des valeurs propres et des vecteurs propres** : Étant donné que C est une matrice symétrique réelle, il est possible de déterminer ses vecteurs propres β et ses valeurs propres associées λ en résolvant :

$$C\beta = \lambda\beta \quad (4.2)$$

où λ est une valeur propre et β le vecteur propre correspondant. Ces valeurs sont obtenues en résolvant l'équation caractéristique :

$$\det(C - \lambda I) = 0 \quad (4.3)$$

avec I la matrice identité.

4. **Tri des valeurs propres** : Les valeurs propres sont classées par ordre décroissant :

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n \quad (4.4)$$

Les vecteurs propres correspondants sont réorganisés en conséquence.

5. **Sélection des composantes principales** : On sélectionne les $a \leq n$ premières composantes principales associées aux plus grandes valeurs propres. Ces vecteurs propres forment une nouvelle base de l'espace réduit, et permettent de représenter les données initiales dans un espace de dimension réduite.
6. **Projection des données** : Les données d'entrée sont projetées sur ce nouvel espace, et les scores (valeurs des a premières composantes principales) sont utilisés comme entrées dans le modèle de prédiction.

4.2.2 Analyse en composantes principales à noyau

Le Kernel PCA (KPCA) constitue une extension non linéaire de la PCA traditionnelle. Contrairement à la PCA classique, qui opère dans l'espace d'origine des données, le Kernel PCA reformule cette méthode dans un espace de dimension élevée, appelé espace de caractéristiques (feature space), construit à l'aide d'une fonction noyau. Plutôt que de calculer les vecteurs propres de la matrice de covariance des données, le Kernel PCA opère sur la matrice noyau (ou matrice de Gram), laquelle encode les produits scalaires entre toutes les paires de données projetées dans cet espace transformé. Cette reformulation permet de capturer des structures non linéaires complexes présentes dans les données d'origine.

La simplicité de cette approche réside dans le fait que la matrice noyau \mathbf{K} remplit un rôle équivalent au produit scalaire dans l'espace de caractéristiques, sans nécessiter une transformation explicite des données vers cet espace de haute dimension. Ainsi, en utilisant des fonctions noyaux telles que le noyau gaussien (RBF), polynomial ou sigmoïdal, le KPCA permet d'extraire des composantes principales reflétant des relations non linéaires entre les observations [125–127].

Le KPCA s'effectue dans l'espace original selon les étapes suivantes :
Soit C la matrice de dispersion de l'application centrée $\varphi(x)$, définie par :

$$C = \sum_{i=1}^N \varphi(x_i)\varphi(x_i)^T \quad (4.5)$$

Soit v un vecteur propre de C , qui peut s'exprimer comme une combinaison linéaire des images $\varphi(x_k)$:

$$v = \sum_{k=1}^N \alpha_k \varphi(x_k) \quad (4.6)$$

Le vecteur propre v satisfait l'équation aux valeurs propres :

$$Cv = \lambda v \quad (4.7)$$

En injectant l'expression de v dans l'équation ci-dessus, on obtient :

$$\left(\sum_{i=1}^N \varphi(x_i)\varphi(x_i)^T \right) \left(\sum_{k=1}^N \alpha_k \varphi(x_k) \right) = \lambda \sum_{k=1}^N \alpha_k \varphi(x_k) \quad (4.8)$$

Après simplification et utilisation de la matrice noyau K , cette relation se réduit à :

$$K^2 \alpha = \lambda K \alpha \implies K \alpha = \lambda \alpha \quad (4.9)$$

La matrice noyau K est ensuite diagonalisée, et les vecteurs propres sont normalisés selon la condition :

$$\lambda_k (\alpha^k)^T \alpha^k = 1 \quad (4.10)$$

Enfin, les k premières composantes principales dans l'espace noyau sont données par :

$$\varphi(x)_{\text{kPCA}}^k = \sum_{i=1}^M \alpha_i^k k(x_i, x) \quad (4.11)$$

où $k(x_i, x) = \langle \varphi(x_i), \varphi(x) \rangle$ est la fonction noyau associée.

4.2.3 Auto-encodeurs

Un auto-encodeur est un réseau de neurones artificiels à propagation avant largement utilisé en apprentissage automatique. Il se compose de trois parties principales : l'encodeur, qui comprime les données d'entrée en une représentation de dimension réduite appelée « code » ; ce code, qui constitue une représentation compacte et informative des données ; et le décodeur, qui reconstruit les données originales à partir de ce code. Cette architecture est illustrée à la figure 4.1.



FIGURE 4.1 – Architecture d'un auto-encodeur.

La tâche principale d'un auto-encodeur consiste à compresser les données d'entrée en une représentation de dimension réduite, appelée code, puis à reconstruire les données originales à partir de cette représentation. Le code est généré par l'encodeur et constitue une version condensée de l'entrée ; il est ensuite transmis au décodeur, chargé de reconstruire les données d'origine. L'apprentissage de l'auto-encodeur vise à minimiser l'erreur de reconstruction entre l'entrée et la sortie du réseau.

L'architecture de base d'un auto-encodeur comprend généralement une seule couche cachée, contenant un nombre de neurones inférieur à celui des neurones en entrée, ce qui force le réseau à apprendre une représentation compacte et informative. Cette configuration est illustrée dans la figure 4.2. Dans certaines variantes, la couche cachée peut être remplacée ou enrichie par plusieurs couches empilées, formant ainsi des auto-encodeurs profonds (deep autoencoders). Grâce à leur capacité à extraire des représentations significatives sans supervision, les auto-encodeurs sont particulièrement bien adaptés aux tâches de réduction de dimension non supervisée [128].

Un auto-encodeur transforme une entrée $\mathbf{x} \in [0, 1]^d$ en une représentation intermédiaire (cachée) $\mathbf{y} \in [0, 1]^{d'}$, avec $d' < d$, selon la relation suivante :

$$\mathbf{y} = f(W_1 \mathbf{x} + \mathbf{b}) \quad (4.12)$$

où :

W_1 : est la matrice des poids reliant la couche d'entrée à la couche cachée,

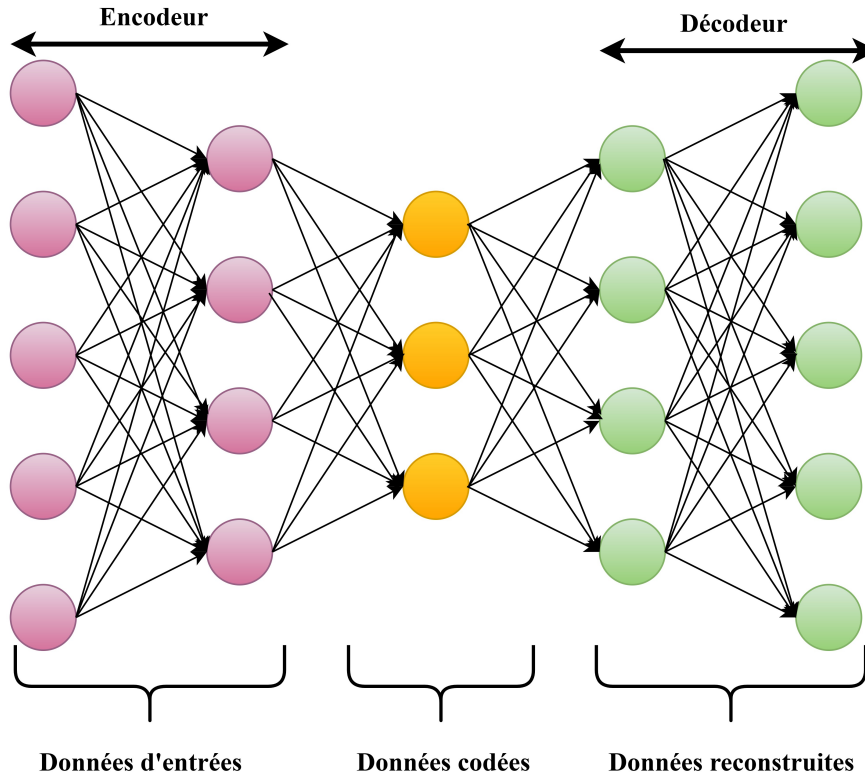


FIGURE 4.2 – Architecture de base d’un auto-encodeur.

\mathbf{b} : est le vecteur de biais associé à la transformation entrée–cachée,
 f : est la fonction d’activation, généralement une sigmoïde définie par :

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4.13)$$

La sortie \mathbf{z} de l’auto-encodeur, qui représente la reconstruction de l’entrée \mathbf{x} , est obtenue à partir de la couche cachée selon l’équation :

$$\mathbf{z} = g(W_2\mathbf{y} + \mathbf{b}) \quad (4.14)$$

où :

W_2 : est la matrice des poids reliant la couche cachée à la couche de sortie, généralement prise comme la transposée de W_1 :

$$W_2 = W_1^T \quad (4.15)$$

g est une autre fonction d’activation, souvent identique à f :

$$g(y) = \frac{1}{1 + e^{-y}} \quad (4.16)$$

Ainsi, pour chaque échantillon d’apprentissage $\mathbf{x}^{(i)}$, l’auto-encodeur apprend une représentation $\mathbf{y}^{(i)}$ à partir de laquelle il reconstruit une approximation $\mathbf{z}^{(i)}$ de l’entrée, telle que :

$$\mathbf{z}^{(i)} \approx \mathbf{x}^{(i)} \quad (4.17)$$

4.3 Réseaux de neurones artificiels pour la prédiction de la vitesse du vent

Les ANNs à propagation avant sont considérés comme les architectures les plus simples et les plus largement utilisées pour la prédiction de la vitesse du vent, en raison de leur capacité à modéliser des relations complexes et non linéaires entre les données. Leur fonctionnement s’inspire du cerveau humain. Ils sont composés d’une couche d’entrée recevant les données, d’une ou plusieurs couches cachées, ainsi que d’une couche de sortie transmettant les résultats. Grâce à leur aptitude à approximer des modèles non linéaires, ces réseaux sont employés pour résoudre des problèmes complexes, difficilement modélisables par des techniques classiques [129].

Dans le cadre de la prédiction de la vitesse du vent, les ANNs exploitent des séries temporelles historiques pour construire des modèles prédictifs précis. Certaines architectures spécifiques, telles que les Machines à Apprentissage Extrême (ELM) [130] et les réseaux d’Elman (ENN) [131], sont particulièrement adaptées à cette tâche. L’ELM se distingue par sa rapidité d’apprentissage, grâce à l’initialisation aléatoire des poids dans sa couche cachée, tandis que le réseau d’Elman, qui est un réseau récurrent, capture les dépendances temporelles à l’aide de ses connexions internes récurrentes.

Ces modèles permettent d’anticiper efficacement les variations de la vitesse du vent, contribuant ainsi à une meilleure gestion des ressources éoliennes et à leur intégration dans les réseaux électriques.

4.3.1 Machines à apprentissage extrême

L’*Extreme Learning Machine* (ELM) est un type de réseau de neurones à propagation avant, appartenant à la classe des réseaux monocouches à anticipation (*Single-Layer Feed-forward Neural Networks* — SLFNs). Ce modèle est spécifiquement conçu pour résoudre rapidement les problèmes d’apprentissage supervisé. Son architecture repose sur une unique couche cachée, dont les poids d’entrée et les biais sont initialisés aléatoirement et restent fixes tout au long de l’entraînement. Cette particularité permet de simplifier considérablement le processus d’apprentissage, car seuls les poids de sortie sont ajustés. Ces derniers sont déterminés analytiquement à l’aide de l’inversion pseudo-généralisée de la matrice des sorties de la couche cachée [130, 132].

Grâce à sa rapidité d’exécution et à sa capacité de généralisation, l’ELM est devenu une méthode populaire dans divers domaines, notamment dans la prédiction des séries temporelles, comme la vitesse du vent [117, 132].

Avec K neurones cachés et une fonction d’activation $g(x)$, l’ELM est capable de traiter N échantillons (x_i, t_i) , où x_i représente les caractéristiques d’entrée et t_i la sortie désirée. Cette méthode permet de transformer un problème non linéaire en un système linéaire à travers les étapes suivantes :

Étape 1 : Calcul de la sortie de la couche cachée : La sortie de la couche cachée est calculée pour chaque échantillon x_j en appliquant une transformation linéaire suivie d’une fonction d’activation non linéaire $g(x)$:

$$h_{ij} = g(w_i \cdot x_j + b_i) \quad (4.18)$$

où : w_i et b_i sont respectivement les poids d'entrée et les biais attribués aléatoirement, et h_{ij} représente un élément de la matrice de sortie de la couche cachée H .

Étape 2 : Résolution analytique des poids de sortie : Les poids de sortie β sont déterminés en résolvant le système linéaire suivant :

$$H\beta = T \quad (4.19)$$

où : T est la matrice des sorties désirées. La solution est obtenue à l'aide de l'inverse pseudo-généralisée de H [133] :

$$\beta = H^+ T \quad (4.20)$$

Étape 3 : Prédiction des nouvelles données : Une fois le modèle entraîné, pour une nouvelle donnée x , la prédiction est obtenue comme suit :

$$y = H\beta \quad (4.21)$$

où : H correspond aux sorties de la couche cachée associées à x , et β est le vecteur des poids calculés précédemment.

La structure d'un ELM est illustrée à la Figure 4.3.

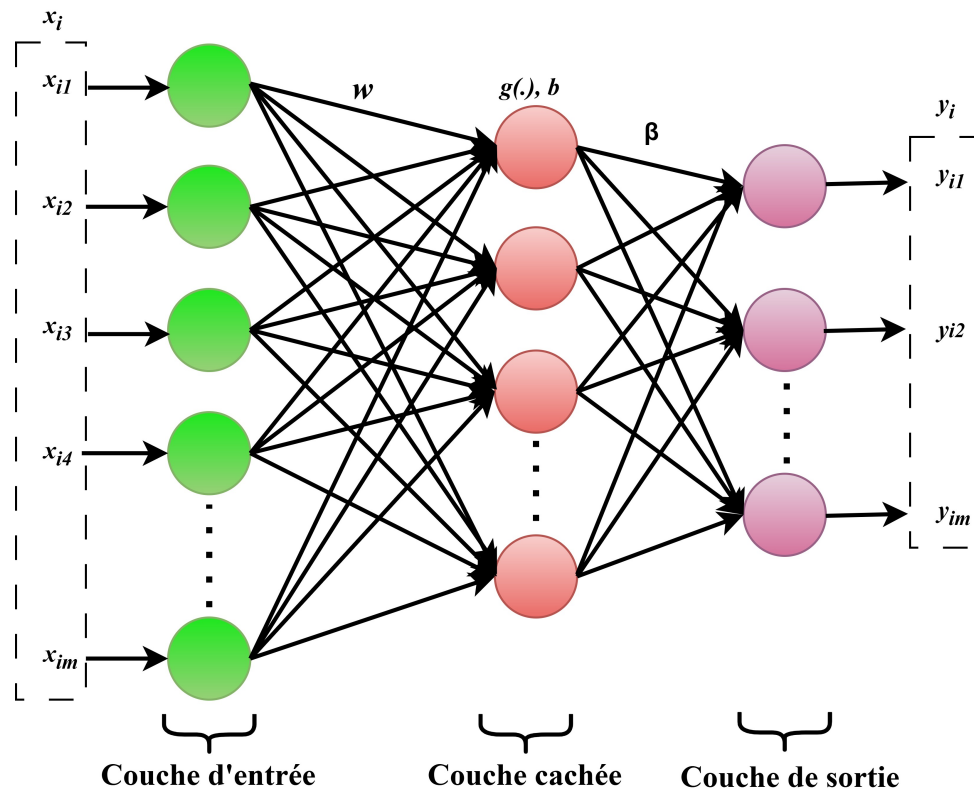


FIGURE 4.3 – Architecture du réseau ELM.

4.3.2 Réseaux neuronaux récurrents : l'approche Elman

Les ENNs constituent un type particulier de réseaux neuronaux artificiels à topologie récurrente. Bien qu'ils soient similaires aux réseaux à propagation directe (feedforward), leur principale caractéristique réside dans l'introduction de boucles internes qui permettent à l'information de circuler à travers le réseau avec un nombre illimité de cycles. Cette récurrence confère au réseau un état interne, lui permettant ainsi de modéliser des comportements dynamiques dans le temps [131]. Au cours des dernières années, plusieurs variantes de RNN ont été proposées, dont les réseaux d'Elman [131], particulièrement efficaces pour les tâches impliquant des données séquentielles. Ces réseaux intègrent un mécanisme de mémoire de court terme, leur permettant de tenir compte du contexte temporel dans leurs prédictions. Cela les rend particulièrement adaptés à l'apprentissage de séquences et à la prédiction de séries temporelles. Le réseau d'Elman partage de nombreuses similitudes avec le réseau de Jordan. Dans l'architecture Elman, les neurones de la couche cachée sont connectés à une *couche de contexte*, dans laquelle leurs activations sont copiées avec un poids unitaire. L'état de cette couche de contexte à l'instant t est donc égal à celui de la couche cachée à l'instant $t - 1$. Cette mémoire interne permet au réseau de garder une trace des événements passés.

Lors de l'étape suivante ($t + 1$), les activations de la couche de contexte sont combinées avec les nouvelles entrées, puis transmises à la couche cachée. Ce mécanisme permet d'intégrer l'historique dans le processus de décision du réseau, renforçant ainsi ses capacités de modélisation des dépendances temporelles [134].

Par conséquent, les entrées provenant de l'environnement externe sont combinées avec les sorties calculées lors des étapes précédentes, fournissant ainsi à la couche cachée une combinaison récursive des informations transformées. Sur la voie de rétroaction, les poids reliant la couche de contexte à la couche cachée sont fixés et généralement égaux à un. Les fonctions d'activation employées dans la couche cachée sont typiquement non linéaires, tandis que la fonction d'activation de la couche de sortie est souvent linéaire. L'entraînement du réseau s'effectue via l'algorithme de rétropropagation classique, mais seuls les poids de propagation avant sont mis à jour, les poids entre la couche de contexte et la couche cachée restant constants. L'architecture de base du réseau ENN est illustrée à la figure 4.4.

4.4 Études de cas et résultats expérimentaux

Dans cette étude, deux approches basées sur des techniques avancées d'intelligence artificielle ont été développées pour la prédiction de la vitesse du vent à partir de séries temporelles. Ces méthodes visent à réduire la dimensionnalité des données tout en améliorant la précision des prédictions grâce à des architectures adaptées.

- La première approche repose sur la combinaison de l'Analyse en Composantes Principales à Noyau (KPCA) pour la réduction dimensionnelle, associée à l'ELM pour la phase de prédiction.
- La seconde approche utilise une architecture d'auto-encodeur pour la réduction de la dimensionnalité des séries temporelles, couplée à des ENN, particulièrement adaptés à la modélisation des dynamiques temporelles complexes.

Les résultats obtenus sont présentés et analysés dans les sections suivantes, accompagnés d'une comparaison entre les approches proposées.

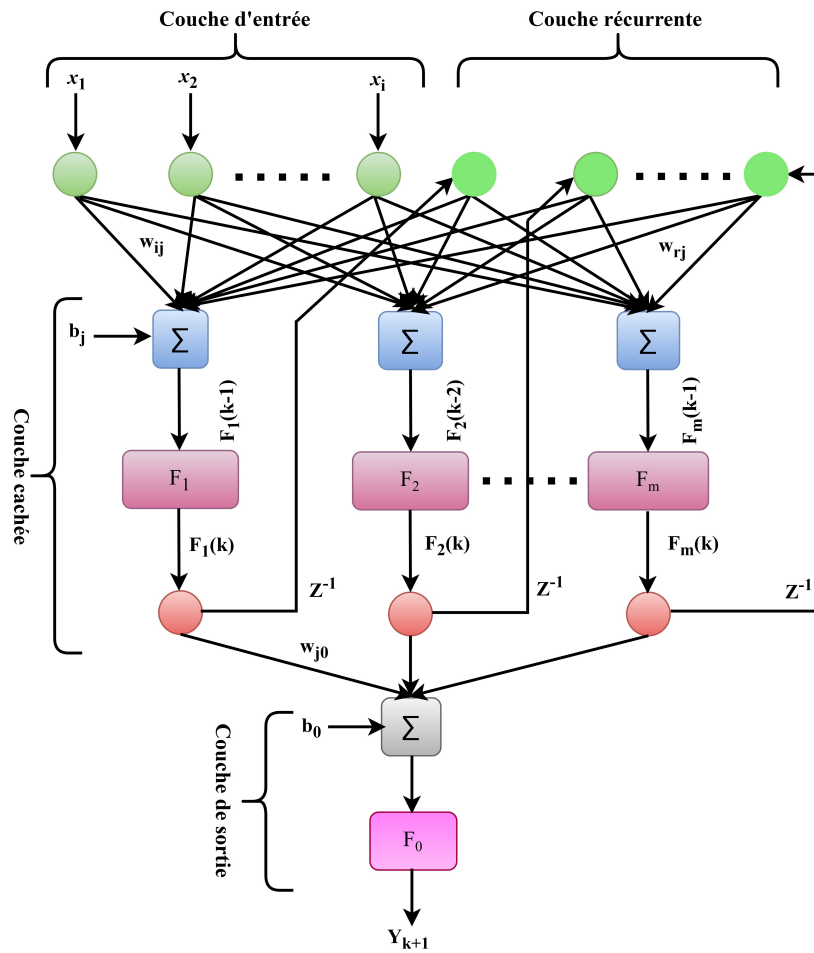


FIGURE 4.4 – Architecture du réseau ENN.

4.4.1 Séries temporelles

L'une des tâches les plus importantes dans l'analyse des séries temporelles est la capacité de prédire les observations futures, notamment lorsqu'il s'agit de grandes quantités de données. L'objectif de la prédiction des séries temporelles est d'estimer les valeurs futures à partir des observations passées (points historiques) [116, 135–137], ce qui peut être formulé par l'équation générale suivante :

$$\hat{y}_{t+T} = h(y_t, y_{t-1}, \dots, y_{t-M+1}) \quad (4.22)$$

Pour obtenir des prédictions précises et fiables, plusieurs aspects doivent être pris en compte, tels que le choix de l'algorithme de prédiction, la sélection des entrées appropriées, ainsi que la méthode de sélection du modèle. Cependant, une mauvaise décision sur l'un de ces aspects peut influencer considérablement les autres, rendant le processus imprécis et conduisant à des prédictions peu fiables.

4.4.2 Ensembles de données utilisés

Les deux approches proposées ont été évaluées sur deux ensembles de données réels provenant de sites situés au Colorado et au Connecticut aux États-Unis, comprenant chacun 52 000 points de mesure collectés toutes les 10 minutes. Les données ont été réparties en trois ensembles : 50 % pour l'apprentissage, 30 % pour la validation, et 20 % pour les tests.

Les détails techniques des deux sites sont présentés dans le tableau 4.1.

TABLE 4.1 – Détails techniques des deux sites.

Site	Latitude	Longitude	Altitude (m)	Nombre d'enregistrements	Année
Colorado	37.39	-102.52	1299	52 000	2006
Connecticut	42.03	-73.46	562	52 000	2006

Les variations temporelles de la vitesse du vent des deux sites sont illustrées dans les figures 4.5 et 4.6.

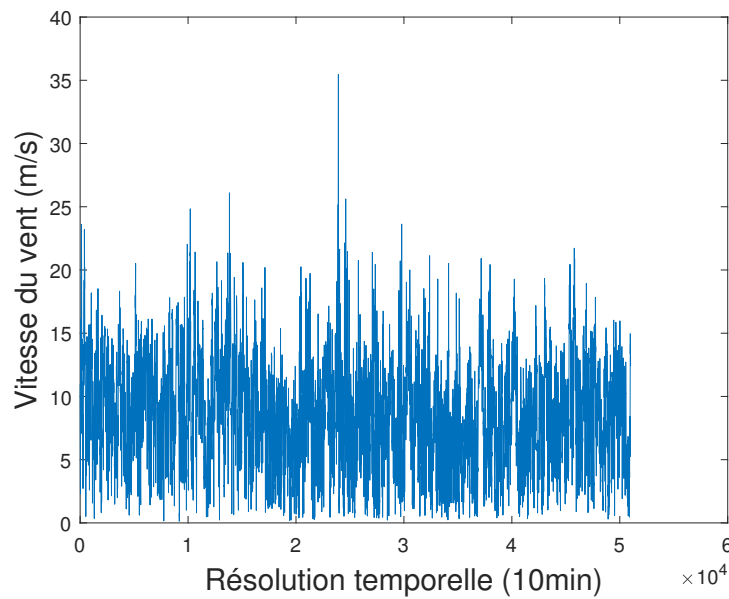


FIGURE 4.5 – Évolution temporelle des données du site Colorado.




FIGURE 4.6 – Évolution temporelle des données du site Connecticut.

Pour évaluer l'efficacité de la première approche proposée, les données originales ont été normalisées afin d'obtenir une moyenne nulle et un écart-type égal à 1. Ensuite, plusieurs expériences ont été réalisées sur chaque ensemble de données, testant différentes architectures avec divers paramètres.

Afin d'analyser les performances obtenues, nous avons retenu les critères d'erreur suivants : l'erreur quadratique moyenne (RMSE), l'erreur absolue moyenne (MAE) et l'erreur quadratique moyenne normalisée (NMSE). Les formules de ces critères sont définies ci-dessous :

$$\text{RMSE} = \sqrt{\frac{1}{N_T} \sum_{q=1}^{N_T} (\hat{f}(x_q) - y_q)^2} \quad (4.23)$$

$$\text{MAE} = \frac{1}{N_T} \sum_{q=1}^{N_T} |\hat{f}(x_q) - y_q| \quad (4.24)$$

$$\text{NMSE} = \frac{\frac{1}{N_T} \sum_{q=1}^{N_T} (\hat{f}(x_q) - y_q)^2}{\text{var}(y)} \quad (4.25)$$

où : y_q représente la valeur réelle, $\hat{f}(x_q)$ la valeur prédite, N_T le nombre total d'échantillons, et $\text{var}(y)$ la variance des valeurs mesurées.


4.4.3 Résultats expérimentaux

4.4.3.1 Présentation, analyse et discussion des résultats de la première approche

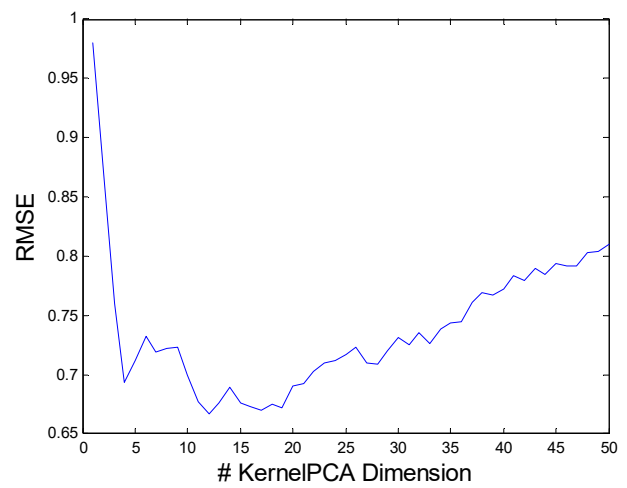
Dans la première approche, quatre scénarios de sélection des variables des séries temporelles historiques ont été adoptés. Dans le premier scénario, l'ensemble complet de 50 variables historiques est utilisé. Dans le deuxième scénario, seules les quatre dernières variables sont fournies à notre prédicteur ELM. Dans les troisième et quatrième scénarios, des transformations par PCA et KPCA sont appliquées aux 50 variables initiales, avant d'introduire les nouvelles PCs dans notre prédicteur ELM.

Pour cette approche combinant la réduction dimensionnelle via KPCA et la prédiction à l'aide d'un ELM, les expérimentations ont montré des résultats prometteurs. Les erreurs mesurées sur l'ensemble de validation sont minimisées dans chaque cas, ce qui a permis de déterminer les paramètres optimaux, notamment le nombre de nœuds cachés et le nombre de composantes principales retenues.

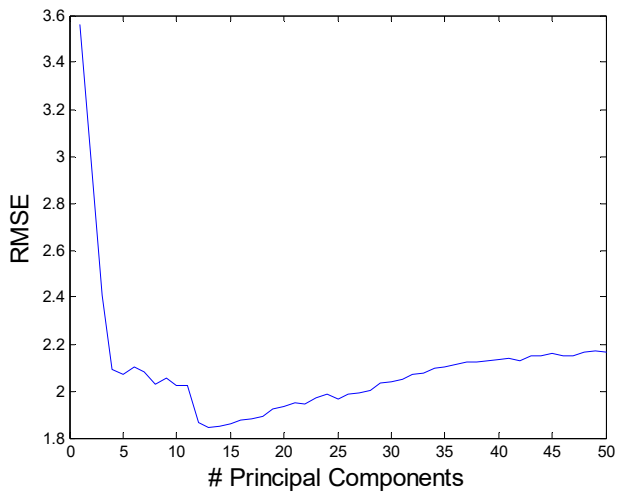
Ces paramètres optimaux sont illustrés sous forme de courbes d'erreur de validation dans les Figures 4.7a à 4.7d, pour les deux sites étudiés : Colorado et Connecticut. Les résultats présentés dans les tableaux 4.2 et 4.3 montrent que la KPCA permet une meilleure réduction tout en exploitant les relations non linéaires entre les variables, ce qui améliore significativement les performances de l'ELM. Ainsi, l'approche KPCA-ELM surpasse non seulement les autres techniques de réduction, mais elle offre également une méthode rapide et efficace. De plus, une analyse comparative des temps de calcul associés à chaque scénario est effectuée pour chaque site étudié.



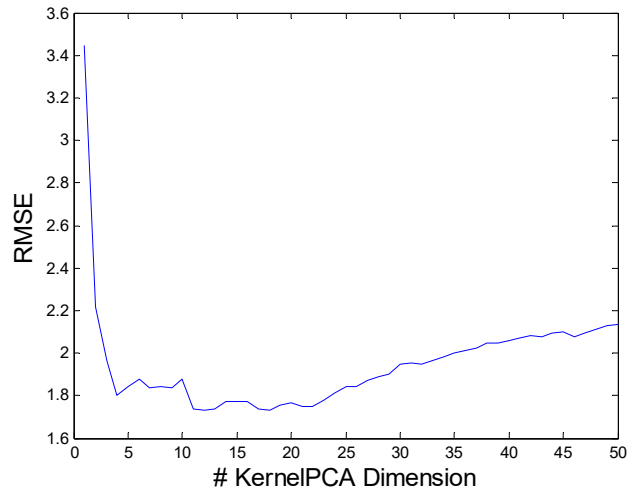
(a) Courbe d'erreur de validation PCA-ELM pour le site Colorado.



(b) Courbe d'erreur de validation KPCA-ELM pour le site Colorado.



(c) Courbe d'erreur de validation PCA-ELM pour le site Connecticut.



(d) Courbe d'erreur de validation KPCA-ELM pour le site Connecticut.

FIGURE 4.7 – Courbes d'erreur de validation pour les sites Colorado et Connecticut.

TABLE 4.2 – Résultats des quatre scénarios pour le site Colorado.

Technique de Réduction	Espace Complet	Partie de l'Espace	PCA	KPCA
Nombre de Variables	50	5	11	12
RMSE	4.32	15.03	3.77	3.00
NMSE	5.04	60.98	3.84	2.43
MAE	3.47	12.02	3.28	2.52
Temps (s)	0.93	0.39	15.31	49.92

4.4.3.2 Présentation, analyse et discussion des résultats de la deuxième approche

Lors de l'évaluation de la deuxième approche, deux techniques de prédiction ont été appliquées : l'auto-encodeur combiné au réseau ENN (AE-ENN) et l'auto-encodeur combiné à un ELM (AE-ELM). Les expériences ont été menées sur les mêmes ensembles de données de vitesse du vent, mesurées sur les sites du Colorado et du Connecticut.

TABLE 4.3 – Résultats des quatre scénarios pour le site Connecticut.

Technique de Réduction	Espace Complet	Partie de l'Espace	PCA	KPCA
Nombre de Variables	50	5	13	12
RMSE	10.95	15.34	6.99	6.36
NMSE	6.04	11.86	2.46	2.04
MAE	9.43	10.05	5.94	5.05
Temps (s)	0.46	0.39	15.45	53.75

Ces expérimentations avaient pour objectif d'évaluer l'efficacité des techniques proposées en testant diverses architectures et en variant les paramètres. Pour chaque site, la réduction de la dimensionnalité des séries temporelles a été d'abord réalisée à l'aide d'un auto-encodeur, afin de minimiser la redondance des données. Les représentations compressées obtenues ont ensuite été introduites respectivement dans le réseau ENN et ELM, chaque technique étant optimisée pour capturer les caractéristiques dynamiques et non linéaires des séries temporelles, ainsi que pour prédire la valeur future de la vitesse du vent.

Pour évaluer les performances de cette deuxième approche, les critères d'erreur suivants ont été retenus : l'erreur absolue moyenne (MABE), la racine carrée de l'erreur quadratique moyenne (RMSE), l'erreur absolue moyenne en pourcentage (MAPE) et le coefficient de détermination (R^2). Les formules mathématiques associées à ces indicateurs sont données ci-dessous :

$$MABE = \frac{1}{N} \sum_{t=1}^N |y_t - \hat{y}_t| \quad (4.26)$$

$$MAPE = \frac{100}{N} \sum_{t=1}^N \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (4.27)$$

$$R^2 = 1 - \frac{\sum_{t=1}^N (y_t - \hat{y}_t)^2}{\sum_{t=1}^N (y_t - \bar{y})^2} \quad (4.28)$$

$$\bar{y} = \frac{1}{N} \sum_{t=1}^N y_t \quad (4.29)$$

où : N désigne le nombre total de mesures, y_t la valeur réelle de la vitesse du vent au temps t , \hat{y}_t la valeur prédite au temps t , et \bar{y} la moyenne des valeurs réelles.

Les résultats obtenus pour la prédiction de la vitesse du vent sont présentés dans les tableaux 4.4, 4.5, 4.6 et 4.7. Ces tableaux mettent en évidence les performances comparées des approches AE-ELM et AE-ENN appliquées aux sites du Colorado et du Connecticut. L'analyse des indicateurs d'évaluation, notamment le RMSE, le MAPE, le MABE ainsi que le coefficient de détermination R^2 , permet d'apprécier de manière quantitative la qualité des prédictions fournies par les deux modèles.

Par ailleurs, les tableaux 4.4, 4.5, 4.6 et 4.7 permettent une analyse comparative approfondie des deux approches proposées. Il en ressort que la combinaison AE-ENN surpasse systématiquement l'approche AE-ELM en termes de précision de prédiction, quelle que soit la localisation géographique du site étudié. En particulier, pour le site du Colorado (tableaux 4.4 et 4.5), l'approche AE-ENN affiche des valeurs minimales pour les indicateurs

d'erreur tels que le RMSE, MABE et MAPE, tout en présentant un coefficient de détermination R^2 significativement plus élevé. Ces résultats traduisent une meilleure capacité du modèle AE-ENN à représenter fidèlement la dynamique temporelle et non linéaire des séries de vitesse du vent.

TABLE 4.4 – Résultats obtenus sur le site Colorado avec l'approche AE-ELM.

Nombre de Neurones	RMSE	MAPE (%)	MABE	R^2
20	29.78	8.27	21.26	0.981
30	26.98	7.11	18.28	0.984
50	33.85	10.04	25.81	0.976

TABLE 4.5 – Résultats obtenus sur le site Colorado avec l'approche AE-ENN.

Nombre de Couches Cachées	RMSE	MAPE (%)	MABE	R^2
1	14.02	4.78	9.06	0.989
2	13.70	4.65	8.81	0.990
3	13.78	4.59	8.71	0.990

De même, pour le site du Connecticut (Tableaux 4.6 et 4.7), l'approche AE-ENN démontre une supériorité significative, avec des erreurs nettement réduites et un meilleur coefficient de détermination.

TABLE 4.6 – Résultats obtenus sur le site Connecticut avec l'approche AE-ELM.

Nombre de Neurones	RMSE	MAPE (%)	MABE	R^2
20	4.19	12.24	2.69	0.960
30	4.06	11.83	2.60	0.963
50	3.88	11.22	2.47	0.966

TABLE 4.7 – Résultats obtenus sur le site Connecticut avec l'approche AE-ENN.

Nombre de Couches Cachées	RMSE	MAPE (%)	MABE	R^2
1	3.08	7.18	2.06	0.9843
2	3.05	7.09	2.03	0.9846
3	3.11	7.37	2.11	0.9845

Ces résultats confirment la robustesse et la pertinence de l'approche AE-ENN, qui parvient à exploiter efficacement la compression d'information opérée par l'auto-encodeur pour améliorer la qualité des prédictions à court terme de la vitesse du vent. L'architecture AE-ENN se distingue ainsi comme une solution fiable pour le traitement des séries temporelles non linéaires à haute dimension.

4.5 Conclusion

La synthèse des méthodes explorées dans cette étude met en évidence l'importance cruciale des techniques d'apprentissage automatique et des architectures avancées dans la prédiction de la vitesse du vent. Les approches basées sur la réduction de dimensionnalité, telles que la KPCA, et sur les réseaux de neurones profonds, notamment les auto-encodeurs et les ENN, ont démontré une capacité remarquable à améliorer la précision des prédictions tout en maîtrisant la complexité des modèles.

En particulier, l'utilisation de la KPCA combinée à un ELM s'est révélée particulièrement efficace pour capter les structures non linéaires des données, réduisant significativement les erreurs de prédiction, tout en maintenant un coût computationnel relativement faible. D'autre part, les réseaux neuronaux récurrents, grâce à leur mémoire interne et leur capacité à modéliser les dépendances temporelles, ont permis de capturer des variations complexes et fines dans les séries temporelles de vitesse du vent.

Les résultats obtenus confirment non seulement la pertinence des combinaisons hybrides (réduction de dimension + apprentissage supervisé), mais ouvrent également la voie à des systèmes prédictifs plus robustes, capables de fonctionner en temps réel. Ils laissent entrevoir des perspectives prometteuses pour l'optimisation des systèmes de gestion de l'énergie éolienne, en particulier dans des contextes fortement dynamiques et soumis à des incertitudes climatiques.

En conclusion, ces travaux renforcent l'idée que l'intégration cohérente et méthodique des techniques avancées d'apprentissage automatique représente une solution fiable et évolutive face aux défis croissants de prédiction dans le domaine des énergies renouvelables, notamment pour la planification intelligente, l'optimisation des réseaux électriques et la transition énergétique durable.

CHAPITRE 5

MÉTHODES DE DÉCOMPOSITION POUR LA PRÉDICTION DE LA VITESSE DU VENT

Sommaire du chapitre

5.1 Introduction	63
5.2 Méthodes de décomposition des séries temporelles pour la prédiction de la vitesse du vent	63
5.2.1 Décomposition modale empirique	63
5.2.2 Décomposition modale variationnelle	64
5.2.3 Décomposition en mode empirique d'ensemble complet améliorée avec bruit adaptatif	67
5.3 Sélection des caractéristiques des modes décomposés	68
5.3.1 Entropie d'échantillon pour la sélection des modes	68
5.4 Modèles de prédiction	68
5.4.1 Modèles d'apprentissage automatique	68
5.4.2 Modèles d'apprentissage profond	70
5.5 Stratégies de fusion des prédictions	76
5.5.1 Scénarios classiques	76
5.6 Expérimentation et évaluation des performances	79
5.6.1 Description des données utilisés	79
5.7 Mesures de performance	80
5.8 Résultats Expérimentaux	81
5.8.1 Modèles hybrides : EMD/VMD et RNA	81
5.8.2 Modèles basée sur la décomposition ICEEMDAN, entropie de l'échantillon et apprentissage profond	90
5.9 Conclusion	104

5.1 Introduction

Face à l'épuisement des ressources fossiles et à l'urgence climatique, les énergies renouvelables représentent une alternative stratégique incontournable. La transition énergétique devient d'autant plus prioritaire que la production pétrolière mondiale pourrait bientôt atteindre un pic [138]. Parmi les sources durables, l'énergie éolienne se démarque par sa croissance rapide : en 2019, elle a contribué à hauteur de 61 GW sur un total mondial record de 184 GW de capacité installée en énergies renouvelables [139]. Toutefois, sa variabilité naturelle rend la prédiction de la vitesse du vent essentielle pour garantir la stabilité des réseaux électriques et optimiser la production [140, 141]. Une prédiction précise contribue à réduire les coûts d'intégration et à améliorer la planification énergétique [142]. Les approches de prédiction se classent généralement en quatre catégories : physiques, statistiques, apprentissage automatique, et hybrides [86, 121, 143–150]. Ces dernières suscitent un intérêt croissant, notamment grâce à l'intégration de techniques de décomposition des séries temporelles, telles que l'EMD, la transformation en ondelettes (WT) ou la variation modale (VMD). En extrayant les composantes multi-échelles des signaux de vent, ces méthodes, combinées à des algorithmes d'apprentissage automatique ou profond, permettent d'améliorer la compréhension des dynamiques du vent et les performances prédictives.

Dans ce contexte, ce chapitre s'attache à explorer et à évaluer des stratégies avancées de prédiction de la vitesse du vent, en mettant particulièrement l'accent sur l'utilisation des techniques de décomposition comme étape préalable à la modélisation. Il présente de manière détaillée les méthodes de décomposition utilisées, les modèles prédictifs développés, ainsi que le protocole expérimental suivi. Une évaluation rigoureuse des performances est ensuite conduite sur des données réelles, avant de conclure par une synthèse des résultats obtenus et des perspectives de recherche.

5.2 Méthodes de décomposition des séries temporelles pour la prédiction de la vitesse du vent

5.2.1 Décomposition modale empirique

Proposée par Huang et ses collaborateurs [151], la Décomposition Modale Empirique (EMD) est une méthode auto-adaptative basée sur la transformée de Hilbert, conçue pour l'analyse des signaux non stationnaires et non linéaires. Elle permet de décomposer une série temporelle en un ensemble fini de fonctions de modes intrinsèques (IMF) représentant les oscillations périodiques, et un résidu correspondant à la tendance globale [152]. Les IMF doivent respecter deux conditions : (1) le nombre de zéros et d'extrêmes doit être égal ou différer d'une unité au plus, et (2) la moyenne des enveloppes supérieure $u(t)$ et inférieure $v(t)$ doit être nulle en tout point. L'algorithme EMD se déroule selon les étapes suivantes [153, 154] :

Étape 1 : Prendre la série temporelle d'origine $S(t)$. Identifier tous les minima et maxima locaux de $S(t)$.

Étape 2 : Interpoler tous les extrema locaux à l'aide d'une méthode d'interpolation, telle que le spline cubique, pour former une enveloppe supérieure $E_{up}(t)$ et utiliser la même

méthode d'interpolation pour les minima locaux afin de former une enveloppe inférieure $E_{down}(t)$. Les enveloppes supérieure et inférieure doivent entourer l'ensemble des données.

Étape 3 : Calculer la fonction enveloppe moyenne $\{m_k(t)\}$:

$$m_i(t) = \frac{E_{up}(t) - E_{down}(t)}{2}, \quad \text{avec } i = 1, 2, 3, \dots, N, \quad (4.1)$$

où : N est le nombre de fonctions IMF.

Étape 4 : Calculer les détails locaux ou les composantes $\{H_i(t)\}$ comme suit :

$$H_i(t) = S(t) - m_i(t) \quad (4.2)$$

Ce processus est appelé le processus de criblage (sifting process).

Étape 5 : Maintenant, $H_i(t)$ devient le nouveau signal de données. On doit vérifier si $H_i(t)$ satisfait les deux conditions mentionnées ci-dessous :

- Si $\{H_i(t)\}$ est une IMF, alors une IMF notée $C_i(t)$ est produite et le résidu devient $R_i(t) = S(t) - H_i(t)$, lequel remplace $S(t)$.
- Sinon, si $\{H_i(t)\}$ n'est pas une IMF, $S(t)$ est remplacé par $H_i(t)$ et on répète les étapes 1 à 5.

Étape 6 : Répéter les étapes 1 à 5 jusqu'à obtenir toutes les IMFs et le résidu. La décomposition est terminée lorsque $R_i(t)$ devient une fonction monotone ou que le nombre d'extrema est inférieur ou égal à 1.

Finalement, la EMD peut être représentée par l'expression suivante :

$$S(t) = \sum_{i=1}^N C_i(t) + R_N(t) \quad (4.3)$$

5.2.2 Décomposition modale variationnelle

Inspirée de l'EMD, la Décomposition Modale Variationnelle (VMD) est une méthode récente, totalement non récursive et particulièrement adaptée aux signaux non linéaires et non stationnaires, proposée par [155]. Elle repose sur trois concepts fondamentaux :

- 1- Un filtrage classique de Wiener pour débruiter le signal ;
- 2- La transformée de Hilbert pour créer un signal analytique à bande latérale unique ;
- 3- La résolution variationnelle d'un problème de séparation de fréquences mixtes [155, 156].

L'objectif principal de la méthode VMD est de décomposer le signal d'origine $S(t)$ (tel qu'une série temporelle) en K sous-composantes appelées modes variationnels $u_k(t)$, où K est le nombre de modes ($k = 1, \dots, K$) et chaque mode possède une bande passante limitée ainsi qu'une fréquence centrale correspondante $\omega_k(t)$. Contrairement à l'EMD, la VMD permet de définir chaque mode comme un signal modulé en amplitude et en fréquence (AM-FM), pouvant être exprimé comme suit :

$$u_k(t) = A_k(t) \cos(\phi_k(t)), \quad (5.1)$$

où : $u_k(t)$ désigne les modes variationnels ; $A_k(t)$ est l'amplitude instantanée de $u_k(t)$ avec $A_k(t) \geq 0$ et $\phi_k(t)$ est la phase instantanée croissante de $u_k(t)$. La fréquence instantanée est donnée par :

$$\omega_k(t) = \frac{d}{dt} \phi_k(t). \quad (5.2)$$

Pour obtenir la bande passante de chaque mode, trois étapes sont réalisées :

- 1- Calcul du spectre unilatéral associé à chaque mode par la transformée de Hilbert ;
- 2- Modulation du spectre unilatéral par la fréquence centrale et transformation en bande de base ;
- 3- Estimation de la bande passante de chaque mode via le calcul de la norme L^2 du gradient du signal modulé.

Le problème variationnel contraint peut être formulé comme suit [156] :

$$\min_{\{u_k\}, \{\omega_k\}} \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \quad (5.3)$$

sous la contrainte $S(t) = \sum_{k=1}^K u_k(t)$,

où : $\{u_k\} = \{u_1, u_2, \dots, u_K\}$ et $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_K\}$ représentent respectivement l'ensemble des modes et des fréquences centrales. t est le temps, ∂_t la dérivée partielle par rapport au temps, $\delta(t)$ la distribution de Dirac, j la racine carrée de -1 (i.e. $j^2 = -1$), $(*)$ le produit de convolution, et $\|\cdot\|_2^2$ le carré de la norme L^2 .

En introduisant le facteur de pénalité quadratique α et le multiplicateur de Lagrange $\lambda(t)$, le problème contraint est converti en un problème non contraint. L'expression du lagrangien augmenté devient alors :

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \\ & + \left\| S(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), S(t) - \sum_{k=1}^K u_k(t) \right\rangle, \end{aligned} \quad (5.4)$$

où : $\langle \cdot, \cdot \rangle$ désigne le produit scalaire.

La méthode d'optimisation appelée Méthode de Direction Alternée des Multiplicateurs (ADMM) [157] est appliquée pour résoudre ce problème variationnel non contraint. L'algorithme s'arrête dès que la précision de discrimination est atteinte et que le point-selle (point-col) est obtenu¹ de l'équation (5.4), ce qui correspond à la solution optimale du problème (5.3).

1. On dit que a est un point col, ou point selle si a est un point critique (ie $dfa = 0$) et si f ne présente pas d'extrémum local en a

Les formules de mise à jour itérative sont données par :

$$\hat{u}_k^{(n+1)}(\omega) = \frac{\hat{S}(\omega) - \sum_{i=1}^{k-1} \hat{u}_i^{(n+1)}(\omega) - \sum_{i=k+1}^K \hat{u}_i^{(n)}(\omega) + \frac{\hat{\lambda}^{(n)}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^{(n)})^2}, \quad (5.5)$$

$$\omega_k^{(n+1)} = \frac{\int_0^\infty \omega |\hat{u}_k^{(n+1)}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{(n+1)}(\omega)|^2 d\omega}, \quad (5.6)$$

$$\hat{\lambda}^{(n+1)}(\omega) = \hat{\lambda}^{(n)}(\omega) + \tau \left[\hat{S}(\omega) - \sum_k \hat{u}_k^{(n+1)}(\omega) \right], \quad (5.7)$$

où $\hat{S}(\omega)$, $\hat{u}_i(\omega)$, et $\hat{\lambda}(\omega)$ sont les transformées de Fourier respectives de $S(t)$, $u_i(t)$, et $\lambda(t)$. Le paramètre τ est le pas de mise à jour du multiplicateur de Lagrange, et n le numéro d'itération.

Le critère d'arrêt est défini par :

$$\sum_k \frac{\|\hat{u}_k^{(n+1)} - \hat{u}_k^{(n)}\|_2^2}{\|\hat{u}_k^{(n)}\|_2^2} < \epsilon, \quad (5.8)$$

où : ϵ est la tolérance de convergence.

L'algorithme VMD est résumé dans l'Algorithme 1 suivant :

Algorithm 1: Algorithme VMD

```

1 Initialise  $\hat{u}_k^1, \omega_k^1, \hat{\lambda}^1, n \leftarrow 0$ ;
2 repeat
3    $n \leftarrow n + 1$ ;
4   for  $k = 0$  to  $K$  do
5     Mettre à jour  $\hat{u}_k$  pour tout  $\omega \geq 0$  ;;
6     
$$\hat{u}_k^{(n+1)}(\omega) \leftarrow \frac{\hat{S}(\omega) - \sum_{i=1}^{k-1} \hat{u}_i^{(n+1)}(\omega) - \sum_{i=k+1}^K \hat{u}_i^{(n)}(\omega) + \frac{\hat{\lambda}^{(n)}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^{(n)})^2}$$

7     ;
8     Mettre à jour  $\omega_k$  ;;
9     
$$\omega_k^{(n+1)} \leftarrow \frac{\int_0^\infty \omega |\hat{u}_k^{(n+1)}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{(n+1)}(\omega)|^2 d\omega}$$

10    ;
11   Double ascension pour tout  $\omega \geq 0$  ;;
12   
$$\hat{\lambda}^{(n+1)}(\omega) \leftarrow \hat{\lambda}^{(n)}(\omega) + \tau \left[ \hat{S}(\omega) - \sum_k \hat{u}_k^{(n+1)}(\omega) \right]$$

13   ;
14 until jusqu'à la convergence;
15 Jusqu'à la convergence ;;

```

$$\sum_k \frac{\|\hat{u}_k^{(n+1)} - \hat{u}_k^{(n)}\|_2^2}{\|\hat{u}_k^{(n)}\|_2^2} < \epsilon$$

5.2.3 Décomposition en mode empirique d'ensemble complet améliorée avec bruit adaptatif

L'algorithme ICEEMDAN (Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise), proposé par Colominas et al. en 2014 [158], constitue une amélioration de la méthode EEMD, visant à surmonter ses principales limitations. Il décompose un signal en un ensemble fini de fonctions de modes intrinsèques (IMF) [159], tout en gérant le bruit de manière adaptative. Cette approche corrige les problèmes d'aliasing fréquentiel en intégrant progressivement un bruit blanc, améliorant ainsi la qualité des IMF et réduisant le bruit résiduel [160]. Les étapes de la méthode ICEEMDAN sont les suivantes :

Étape 1 : Afin d'obtenir un bruit spécifique, on ajoute la Décomposition en Modes Empiriques au signal original comme indiqué dans l'équation suivante :

$$y^i = y + \beta_0 E_1[\omega^i] \quad (4.11)$$

Cette équation représente le processus d'ajout d'un bruit spécial $E_1[\omega^i]$ au signal original y . La variable y^i représente le i -ième bruit blanc ajouté, avec i allant de 1 à N . Le rapport signal/bruit attendu du premier signal décomposé est représenté par β_0 .

Étape 2 : Pour calculer la première IMF, l'algorithme EMD est utilisé pour obtenir la moyenne locale du signal reconstruit, et le premier résidu est obtenu en prenant leur valeur moyenne :

$$R_1 = \frac{1}{N} \sum_{i=1}^N M[y^i] \quad (4.12)$$

$$\tilde{r}_1 = y - R_1 \quad (4.13)$$

Dans ces équations, R_1 est le résidu de la première décomposition, $M[\cdot]$ est l'opérateur calculant la moyenne locale, et \tilde{r}_1 représente la première IMF.

Étape 3 : Calculer la deuxième IMF en utilisant l'équation suivante :

$$R_2 = \frac{1}{N} \sum_{i=1}^N M[R_1 + \beta_1 E_2[\omega^i]] \quad (4.14)$$

$$\tilde{r}_2 = R_1 - R_2 \quad (4.15)$$

où : R_2 et \tilde{r}_2 représentent respectivement le résidu et la valeur de la deuxième IMF.

Étape 4 : Appliquer de manière itérative les étapes précédentes pour déterminer la k -ième IMF :

$$R_k = \frac{1}{N} \sum_{i=1}^N M[R_{k-1} + \beta_{k-1} E_k[\omega^i]] \quad (4.16)$$

$$\tilde{r}_k = R_{k-1} - R_k \quad (4.17)$$

où : $k = 1, 2, 3, \dots, N$. Le calcul itératif de cette équation permet de décomposer avec précision le signal.

5.3 Sélection des caractéristiques des modes décomposés

5.3.1 Entropie d'échantillon pour la sélection des modes

L'entropie échantillon (Sample Entropy, SE), introduite par Richman et Moorman comme amélioration de l'entropie approximative (ApEn), constitue une méthode fiable pour évaluer la complexité et la régularité des séries temporelles [161]. Contrairement à l'ApEn, la SE fournit des résultats plus stables, notamment pour les séries courtes ou bruitées. Elle mesure la similarité entre sous-séquences extraites de la série : une SE faible indique une structure régulière, tandis qu'une SE élevée reflète une complexité accrue. Son calcul dépend de trois paramètres principaux : la longueur de la série, la tolérance à la similarité (souvent une fraction de l'écart-type), et la dimension d'immersion, généralement fixée à 2. Les étapes de calcul sont détaillées dans plusieurs travaux [162, 163] :

Étape 1 : Les données d'origine composées de N points sont représentées comme suit :

$$X_i = [x_i, x_{i+1}, \dots, x_{i+m-1}] \quad (4.18)$$

Étape 2 : La distance entre les vecteurs X_i et X_j est définie comme :

$$D_m(X_i, X_j) = \max_{0 \leq k \leq m-1} |x_{i+k} - x_{j+k}| \quad (4.19)$$

Étape 3 : La moyenne des vecteurs est ensuite calculée comme suit :

$$B^m(r) = \frac{1}{N - M + 1} \sum_{i=1}^{N-M+1} B_i^m \quad (4.20)$$

Étape 4 : Les étapes 1 à 3 sont répétées pour calculer la valeur finale de l'entropie échantillon, exprimée par :

$$SE(m, r, N) = \lim_{N \rightarrow \infty} \left[-\ln \frac{B^{m+1}(r)}{B^m(r)} \right] \quad (4.21)$$

où : m désigne la dimension d'immersion et r représente le seuil de condition.

5.4 Modèles de prédiction

5.4.1 Modèles d'apprentissage automatique

5.4.1.1 Réseaux de neurones perceptron multicouches

Le perceptron multicouches (MLPNN), considéré comme l'architecture classique des réseaux de neurones artificiels (ANNs), constitue un type typique de réseau de neurones à propagation avant. Il se caractérise par des connexions entièrement unidirectionnelles entre les couches successives. Un MLPNN se compose de trois types de couches : une couche d'entrée, une ou plusieurs couches cachées, et une couche de sortie. Les neurones des couches cachées sont généralement associés à différentes fonctions de transfert, parmi lesquelles la fonction sigmoïde est la plus courante. Pour les problèmes de régression, tels que ceux liés à la prédiction, la couche de sortie comprend généralement un unique neurone doté d'une fonction d'activation linéaire.

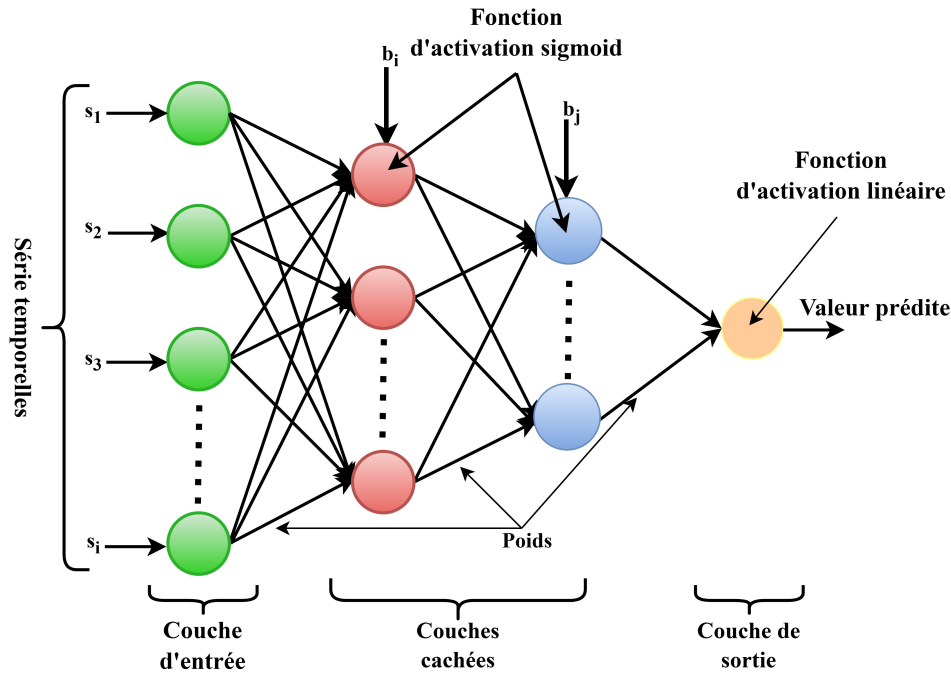


FIGURE 5.1 – Architecture du réseau neuronal MLP.

L'architecture typique d'un MLPNN est illustrée à la figure 5.1. Dans ce schéma, chaque couche transmet l'information à la couche suivante jusqu'à ce que le résultat final soit obtenu dans la couche de sortie. En pratique, les MLPNNs sont le plus souvent entraînés au moyen de l'algorithme de rétropropagation du gradient [129].

5.4.1.2 Réseaux de neurones à fonction de base radiale

Un autre type majeur de modèles de réseaux de neurones à propagation avant est le Réseau de Neurones à Fonction de Base Radiale (RBFNN). La structure typique d'un RBFNN est illustrée à la figure 5.2. Ce réseau se compose de trois couches :

- Une couche d'entrée;
- Une unique couche cachée, dans laquelle chaque neurone utilise une fonction de base radiale comme fonction de transfert, constituant ainsi une fonction d'activation non linéaire;
- Une couche de sortie qui applique une transformation linéaire à partir de l'espace des neurones cachés.

La sortie d'un RBFNN peut être formulée par l'expression suivante :

$$f(S) = b_0 + \sum_{j=1}^m w_j h_j(S) \quad (4.22)$$

où : $S = [s_1, s_2, \dots, s_n]^T$ représente le vecteur d'entrée, w_j désigne les poids de connexion entre la couche cachée et la couche de sortie, b_0 est un terme de biais, et h_j est une fonction gaussienne définie par :

$$h_j(S) = \exp\left(-\frac{\|S - C_j\|^2}{2\sigma_j^2}\right), \quad j = 1, 2, \dots, m \quad (4.23)$$

où : C_j et σ_j sont respectivement les centres et les variances des fonctions gaussiennes, et m est le nombre de neurones dans la couche cachée.

Dans l'algorithme d'apprentissage du RBFNN, trois paramètres doivent être déterminés : les centres des fonctions de base, les variances, ainsi que les poids de connexion entre la couche cachée et la couche de sortie. Les valeurs de C_j et σ_j peuvent être fixées en utilisant un algorithme de clustering ainsi que des méthodes heuristiques [164].

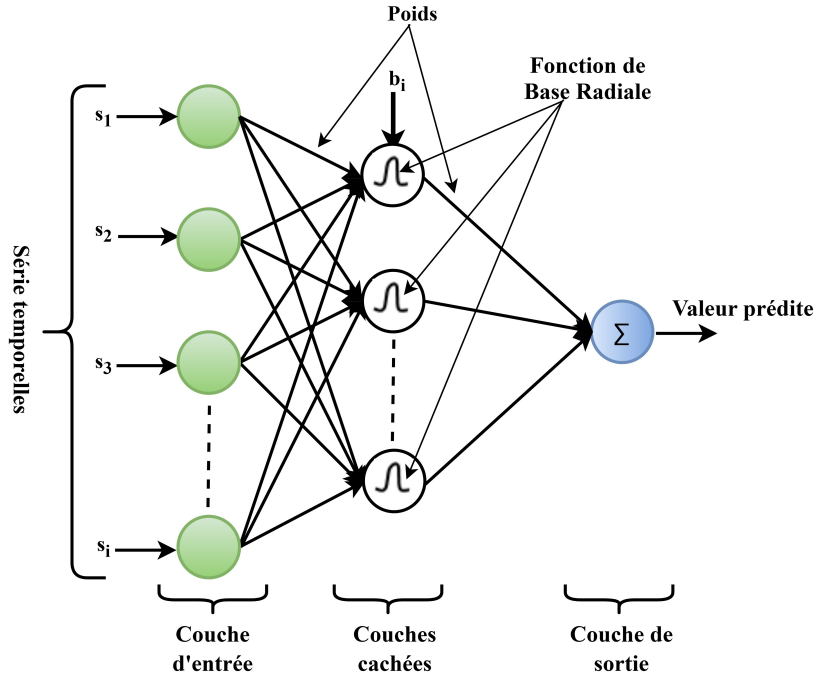


FIGURE 5.2 – Architecture du réseau neuronal RBF.

Les ELM ainsi que les Réseaux de ERNN sont exposés en détail dans les sous sections 4.3.1 et 4.3.2

5.4.2 Modèles d'apprentissage profond

5.4.2.1 Réseaux de neurones récurrents à mémoire long court terme

Le réseau à mémoire long court terme (LSTM), introduit par Hochreiter et Schmidhuber en 1997 [52], est une extension des RNN conçue pour apprendre des dépendances à long terme. L'architecture a ensuite été améliorée par l'introduction de la porte d'oubli, facilitant la gestion de l'information temporelle [165, 166]. Aujourd'hui, le LSTM-RNN est largement utilisé dans des domaines variés tels que le traitement du langage, la reconnaissance d'images, les vidéos, ainsi que la prédiction de séries temporelles. Contrairement aux réseaux classiques, il repose sur des blocs de mémoire comprenant trois types de portes : oubli, entrée et sortie [167, 168], qui assurent un traitement efficace des données séquentielles tout en limitant la perte d'information [169].

La figure 5.3 illustre l'architecture interne d'une cellule mémoire LSTM-RNN.

Les expressions suivantes représentent le processus de calcul interne d'une cellule LSTM-RNN :

$$f_t = \delta(X_f \times [h_{t-1}, I_t] + \beta_f) \quad (4.24)$$

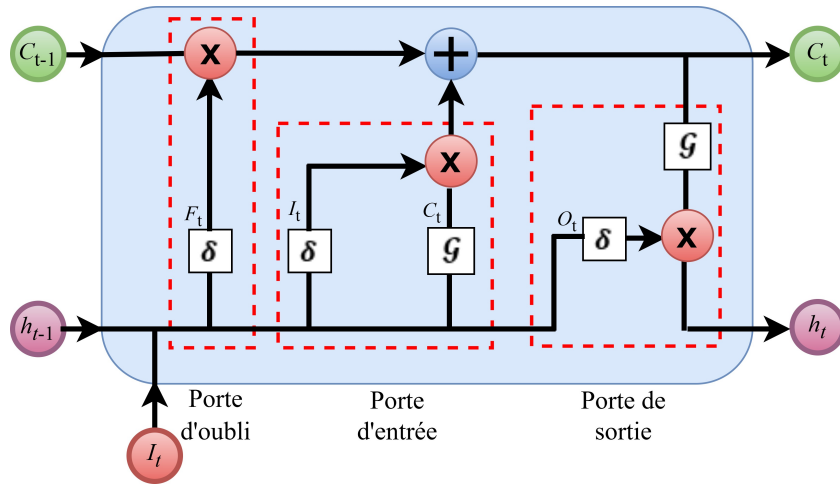


FIGURE 5.3 – Structure de base du modèle LSTM-RNN.

où :

- f_t est la porte d'oubli (Forget Gate),
- δ représente la fonction d'activation sigmoïde,
- X_f est la matrice de poids entre la porte d'oubli et la porte d'entrée,
- h_{t-1} est l'état caché précédent,
- I_t est la valeur d'entrée du LSTM-RNN au temps actuel,
- β_f est le biais de la porte d'oubli.

Ensuite, le calcul de la porte d'entrée se fait par :

$$i_t = \delta(X_i \times [h_{t-1}, I_t] + \beta_i) \quad (4.25)$$

L'état candidat de la cellule est donné par :

$$\tilde{C}_t = G(X_C \times [h_{t-1}, I_t] + \beta_C) \quad (4.26)$$

L'état de la cellule est mis à jour par la relation :

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (4.27)$$

où :

- i_t est la porte d'entrée (Input Gate),
- \tilde{C}_t est l'état candidat de la cellule,
- C_t est l'état mis à jour de la cellule,
- C_{t-1} est l'état de la cellule au pas de temps précédent,
- G est la fonction d'activation tangente hyperbolique (tanh),
- X_i et β_i sont respectivement la matrice de poids et le biais de la porte d'entrée,
- X_C et β_C sont respectivement la matrice de poids et le biais pour la génération des valeurs candidates.

Le calcul de l'état caché à l'instant t est donné par :

$$h_t = o_t \times G(C_t) \quad (4.28)$$

Enfin, la porte de sortie est calculée par :

$$o_t = \delta(X_o \times [h_{t-1}, I_t] + \beta_o) \quad (4.29)$$

où :

- h_t est l'état caché au pas de temps actuel,
- o_t représente la porte de sortie (Output Gate), qui contrôle la quantité d'information de C_t incluse dans h_t ,
- X_o et β_o sont respectivement la matrice de poids et le biais de la porte de sortie.

Les fonctions sigmoïde et tangente hyperbolique (\tanh) sont des fonctions d'activation non linéaires définies par :

$$\delta(Z) = \frac{1}{1 + \exp(-Z)} \quad (4.30)$$

$$G(Z) = \tanh(Z) = \frac{e^Z - e^{-Z}}{e^Z + e^{-Z}} \quad (4.31)$$

Ces fonctions convertissent la sortie en une valeur comprise entre -1 et 1.

5.4.2.2 Réseaux de neurones récurrents à mémoire long court terme bidirectionnels

Le réseau à mémoire long court terme bidirectionnel (BiLSTM), proposé par Schuster et Paliwal en 1997 [57], constitue une extension des LSTM classiques, conçue pour capturer les dépendances contextuelles dans les deux directions temporelles. Contrairement aux LSTM standards, le BiLSTM intègre deux couches LSTM : l'une traitant la séquence dans le sens chronologique et l'autre dans le sens inverse [170]. Cette architecture permet de modéliser simultanément les informations passées et futures, ce qui en fait un outil performant pour des tâches séquentielles complexes comme la prédiction de la vitesse du vent. La figure 5.4 illustre cette structure, où les sorties des deux couches sont combinées pour former l'état caché final à chaque pas de temps.

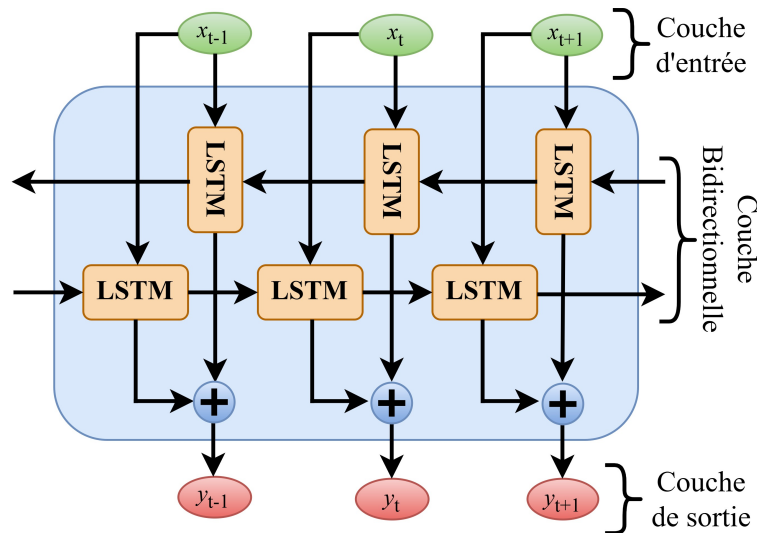


FIGURE 5.4 – Architecture du modèle BiLSTM.

À chaque pas de temps t , les états cachés des couches avant et arrière sont calculés indépendamment. L'état caché avant, noté h_t^{\rightarrow} , et l'état caché arrière, noté h_t^{\leftarrow} , sont déterminés à l'aide des équations suivantes :

$$h_t^{\rightarrow} = \delta(W^{\rightarrow} \cdot [h_{t-1}^{\rightarrow}, x_t] + b^{\rightarrow}) \quad (4.32)$$

$$h_t^{\leftarrow} = \delta(W^{\leftarrow} \cdot [h_{t+1}^{\leftarrow}, x_t] + b^{\leftarrow}) \quad (4.33)$$

où :

- δ désigne la fonction d'activation sigmoïde,
- x_t est le vecteur d'entrée au pas de temps t ,
- h_{t-1}^{\rightarrow} et h_{t+1}^{\leftarrow} représentent respectivement les états cachés des pas de temps précédents et suivants pour les couches LSTM avant et arrière,
- W^{\rightarrow} et W^{\leftarrow} sont les matrices de poids associées aux directions avant et arrière.

Les vecteurs h_t^{\rightarrow} et h_t^{\leftarrow} sont ensuite combinés, généralement par concaténation, pour former une représentation bidirectionnelle de la séquence à chaque pas de temps :

$$h_t = \begin{bmatrix} h_t^{\rightarrow} & h_t^{\leftarrow} \end{bmatrix} \quad (4.34)$$

La concaténation des sorties avant et arrière permet au BiLSTM-RNN de tirer parti du contexte passé et futur, renforçant ainsi ses performances. Grâce à la capture des dépendances bidirectionnelles à long terme, il se révèle particulièrement performant dans les tâches nécessitant une compréhension globale de la séquence pour une prédiction précise.

5.4.2.3 Réseaux de neurones à unités récurrentes fermées

Les réseaux de neurones à unités récurrentes fermées (GRU) constituent une variante des réseaux de neurones récurrents, introduite par Cho et al. en 2014. Ce modèle a été conçu pour résoudre les problèmes de gradient évanescent et de gradient explosif, tout en simplifiant la complexité des réseaux à mémoire long court terme (LSTM). Les GRU se distinguent par leur capacité à modéliser efficacement les données séquentielles et ont démontré de solides performances dans diverses applications, telles que la prédiction de la vitesse du vent et la reconnaissance vocale [171, 172].

L'architecture des GRU repose sur deux portes principales :

- La porte de mise à jour (Update Gate), qui contrôle la quantité d'information du passé à conserver ;
- La porte de réinitialisation (Reset Gate), qui détermine quelles parties de l'état précédent doivent être oubliées [173].

Ensemble, ces portes régulent dynamiquement le flux d'informations à travers les pas de temps, garantissant ainsi une rétention adaptative de la mémoire.

La figure 5.5 présente un schéma de l'architecture des GRU, illustrant le flux d'information à travers les portes de mise à jour et de réinitialisation.

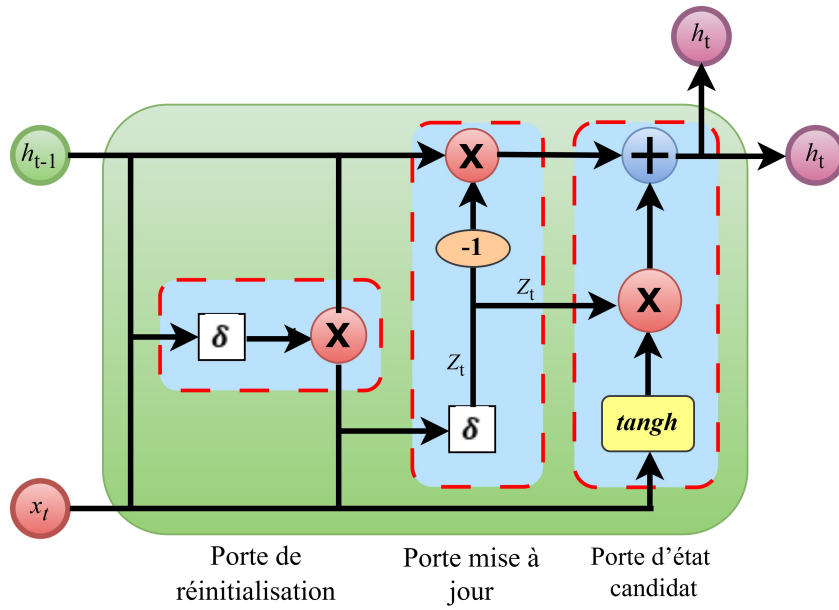


FIGURE 5.5 – Architecture du modèle GRU.

La porte de mise à jour z_t est définie par l'expression suivante :

$$z_t = \delta(W_Z \cdot [h_{t-1}, x_t] + b_z) \quad (4.35)$$

où :

- δ est la fonction d'activation sigmoïde,
- W_Z est la matrice de poids associée à cette porte,
- h_{t-1} est l'état caché du pas de temps précédent,
- x_t est l'entrée actuelle,
- b_z est le terme de biais.

La porte de réinitialisation r_t est calculée de manière similaire :

$$r_t = \delta(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (4.36)$$

où :

- W_r et b_r sont respectivement la matrice de poids et le biais associés à la porte de réinitialisation.

Ensemble, ces portes régulent dynamiquement le flux d'informations à travers les pas de temps, permettant ainsi une rétention adaptative de la mémoire. À l'aide de la porte de réinitialisation, le GRU calcule un état caché candidat \tilde{h}_t défini par :

$$\tilde{h}_t = \tanh(W \cdot [r_t \odot h_{t-1}, x_t] + b) \quad (4.37)$$

où :

- \tanh est la fonction d'activation tangente hyperbolique,
- \odot représente la multiplication élément par élément,
- W et b sont respectivement la matrice de poids et le terme de biais associés à l'état caché candidat.

Enfin, l'état caché mis à jour h_t est calculé comme une combinaison de l'état caché précédent h_{t-1} et de l'état caché candidat \tilde{h}_t , pondérée par la porte de mise à jour z_t :

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (4.38)$$

Cette formulation permet au GRU d'intégrer simultanément l'état caché passé et l'entrée actuelle, équilibrant ainsi la rétention des informations historiques et l'incorporation des nouvelles données [174].

5.4.2.4 Réseaux neuronaux récurrents bidirectionnels à portes

Les réseaux de neurones à unités récurrentes à portes bidirectionnelles (BiGRU) représentent une amélioration des réseaux récurrents traditionnels, spécialement conçue pour capturer les dépendances temporelles dans les deux directions : passée et future. Contrairement à un GRU standard, qui traite les séquences dans une seule direction, le BiGRU combine deux couches GRU distinctes : l'une traite les données dans le sens direct (du passé vers le futur), tandis que l'autre les traite dans le sens inverse (du futur vers le passé). Cette approche permet de mieux contextualiser les séquences temporelles complexes en intégrant des informations provenant à la fois du passé et du futur. Le BiGRU s'avère particulièrement efficace dans des applications telles que la prédiction de l'énergie éolienne, où les corrélations temporelles bidirectionnelles jouent un rôle crucial [175, 176].

L'unité BiGRU peut être décrite par les équations suivantes :

$$h_t^f = \text{GRU}(x_t, h_{t-1}^f) \quad (4.39)$$

$$h_t^b = \text{GRU}(x_t, h_{t+1}^b) \quad (4.40)$$

où :

- h_t^f et h_t^b représentent respectivement les états cachés générés dans les directions avant et arrière,
- x_t est l'entrée au temps t .

La sortie finale est obtenue en combinant ces deux états :

$$h_t = [h_t^f, h_t^b] \quad (4.41)$$

La figure 5.6 illustre l'architecture du BiGRU-NN, mettant en évidence ses deux flux de traitement parallèles (avant et arrière) et leur fusion, permettant ainsi de produire une sortie enrichie par un contexte temporel global.

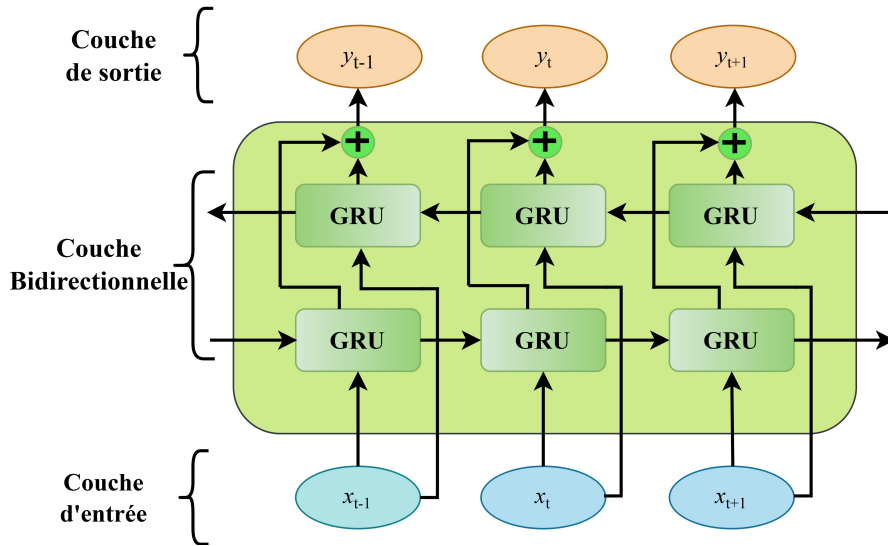


FIGURE 5.6 – Architecture du modèle BiGRU-NN.

5.5 Stratégies de fusion des prédictions

5.5.1 Scénarios classiques

5.5.1.1 Moyenne simple

Les méthodes de combinaison des prédictions, notamment celles qui attribuent un poids égal à chaque modèle, sont parmi les plus simples et les plus couramment utilisées. Dans ce scénario, un poids égal est attribué à toutes les prédictions individuelles x_i par leur nombre n [177]. L'expression mathématique associée à cette méthode est donnée par :

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (4.42)$$

Le facteur $\frac{1}{n}$ est appelé le poids, et la somme des poids est égale à 1.

5.5.1.2 Surperformance

Dans cette approche proposée par D. W. Bunn en 1975 [178], le poids attribué à un modèle est basé sur le nombre de fois où il a surpassé les autres modèles. Pour simplifier, supposons la combinaison de deux modèles de prédiction individuels, $SF1$ et $SF2$, comme suit :

$$\tilde{y}_m = w \cdot \tilde{y}_m^{(1)} + (1 - w) \cdot \tilde{y}_m^{(2)} \quad \forall m = 1, 2, \dots, M \quad (4.43)$$

Ici, nous supposons que la performance des deux modèles est mesurée par l'erreur absolue, et que les résultats sont comptabilisés K fois. Le modèle ayant l'erreur absolue la plus faible est considéré comme ayant surpassé l'autre. Si $SF1$ a surpassé $SF2$ k fois, soit une fraction de K , on suppose que cette fraction suit une distribution $\beta(m|a_1, a_2)$ avec $0 \leq m \leq 1$ et $(\eta_1, \eta_2 > 0)$. La variable de Bernoulli δ_i pour chaque prédiction i est définie par :

$$\delta_i = \begin{cases} 1 & \text{si } SF1 \text{ surpasse } SF2 \\ 0 & \text{sinon} \end{cases} \quad (4.44)$$

Ce cadre peut être généralisé à K modèles, où les fractions k_i ($i = 1, 2, \dots, K$) des modèles individuels suivent une distribution Beta, équivalente à une distribution de Dirichlet.

5.5.1.3 Fusion basée sur l'erreur

Dans cette méthode, la série temporelle est d'abord subdivisée en deux sous-ensembles complémentaires : l'un pour l'apprentissage et l'autre pour le test. L'entraînement des modèles individuels est effectué sur l'ensemble d'apprentissage, tandis que les erreurs de prédiction résultantes sont obtenues à partir des données du sous-ensemble de test. Les poids correspondants pour chaque modèle individuel sont ensuite calculés comme suit :

$$w_k = \frac{e_k^{-1}}{\sum_{k=1}^N e_k^{-1}} \quad \forall k = 1, 2, \dots, K \quad (4.45)$$

où : e_k est l'erreur du k -ème modèle individuel.

5.5.1.4 Régression des moindres carrés

Cette méthode utilise la somme des erreurs quadratiques (SSE), un outil classique pour mesurer l'écart entre les données prédites et observées. Une combinaison linéaire des modèles est ainsi développée en attribuant des poids à chaque modèle de prédiction. La formule classique de cette combinaison linéaire est donnée par :

$$\tilde{Y} = MW \quad (4.46)$$

où :

$$M = \begin{bmatrix} \tilde{y}_1^{(1)} & \tilde{y}_1^{(2)} & \dots & \tilde{y}_1^{(n)} \\ \tilde{y}_2^{(1)} & \tilde{y}_2^{(2)} & \dots & \tilde{y}_2^{(n)} \\ \vdots & \vdots & \ddots & \vdots \\ \tilde{y}_N^{(1)} & \tilde{y}_N^{(2)} & \dots & \tilde{y}_N^{(n)} \end{bmatrix}$$

et

$$W = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix}$$

où : \tilde{Y} et Y sont respectivement les valeurs prédites et observées, et W est le vecteur des poids des modèles individuels.

L'expression de la SSE est donnée par :

$$SSE = \sum_{t=1}^N (y_t - \tilde{y}_t)^2 = (Y - MW)^T (Y - MW) = Y^T Y - 2W^T M^T Y + W^T M^T M W \quad (4.47)$$

Le vecteur optimal des poids est obtenu en minimisant la SSE par rapport à W :

$$W = (M^T M)^{-1} M^T Y \quad (4.48)$$

5.5.1.5 Pondération différentielle

Comme la méthode de régression des moindres carrés, les poids sont obtenus en minimisant la variance de l'erreur de prédiction combinée. Cette approche nécessite la connaissance de la matrice de covariance des erreurs de prédiction. Le poids w_i de chaque modèle participant à la combinaison linéaire est défini comme suit :

$$w_i = \frac{\left(\sum_{s=t-v}^{t-1} e_s^{(i)}\right)^2}{\sum_{j=1}^n \left(\sum_{s=t-v}^{t-1} e_s^{(j)}\right)^2} \quad (4.49)$$

où :

- n est le nombre de modèles individuels,
- t est la période de prédiction,
- v est un paramètre constant,
- $e_t^{(i)}$ représente le pourcentage d'erreur de prédiction au temps t .

5.5.1.6 Technique basée sur la classification

La stratégie basée sur la classification repose sur l'hypothèse selon laquelle les modèles prédictifs présentent des niveaux de performance variables en fonction des différentes régions de l'espace des variables d'entrée des données temporelles. Pour exploiter cette variabilité, la stratégie segmente l'espace d'entrée en régions distinctes, chacune étant associée au modèle prédictif qui minimise l'erreur de prédiction dans cette région spécifique. Au cours de la phase d'apprentissage, le modèle optimal pour chaque segment est déterminé par une analyse approfondie de l'ensemble d'apprentissage. Ce processus de segmentation garantit que chaque région est associée au prédicteur le plus précis, ce qui améliore la précision globale des prédictions [121, 179, 180].

Le prédicteur optimal $\hat{P}(Z)$ pour une série temporelle donnée S est sélectionné selon la relation suivante :

$$\hat{P}(Z) = \arg \min_{i=1,2,\dots,N} |f_i(S_j) - y_j| \quad (4.50)$$

où :

- $f_i(S_j)$ représente la prédiction du modèle i pour la série S_j ,
- y_j est la valeur réelle observée.

Une fois la segmentation établie, toute nouvelle donnée de série temporelle est classée dans une région spécifique, et le modèle optimal correspondant est appliqué pour effectuer la prédiction. La prédiction obtenue $\hat{F}(Z)$ est donnée par :

$$\hat{F}(Z) = f_{\hat{P}(Z)}(Z) \quad (4.51)$$

L'efficacité de cette stratégie réside dans sa capacité à exploiter dynamiquement les forces de différents modèles en fonction des caractéristiques des données, ce qui améliore la précision globale des prédictions. Comme l'illustre la figure 5.7, cette méthode comprend deux phases principales :

- L'apprentissage, durant lequel l'espace des variables est segmenté,
- Le test, où le modèle optimal est sélectionné pour chaque nouvelle série temporelle.

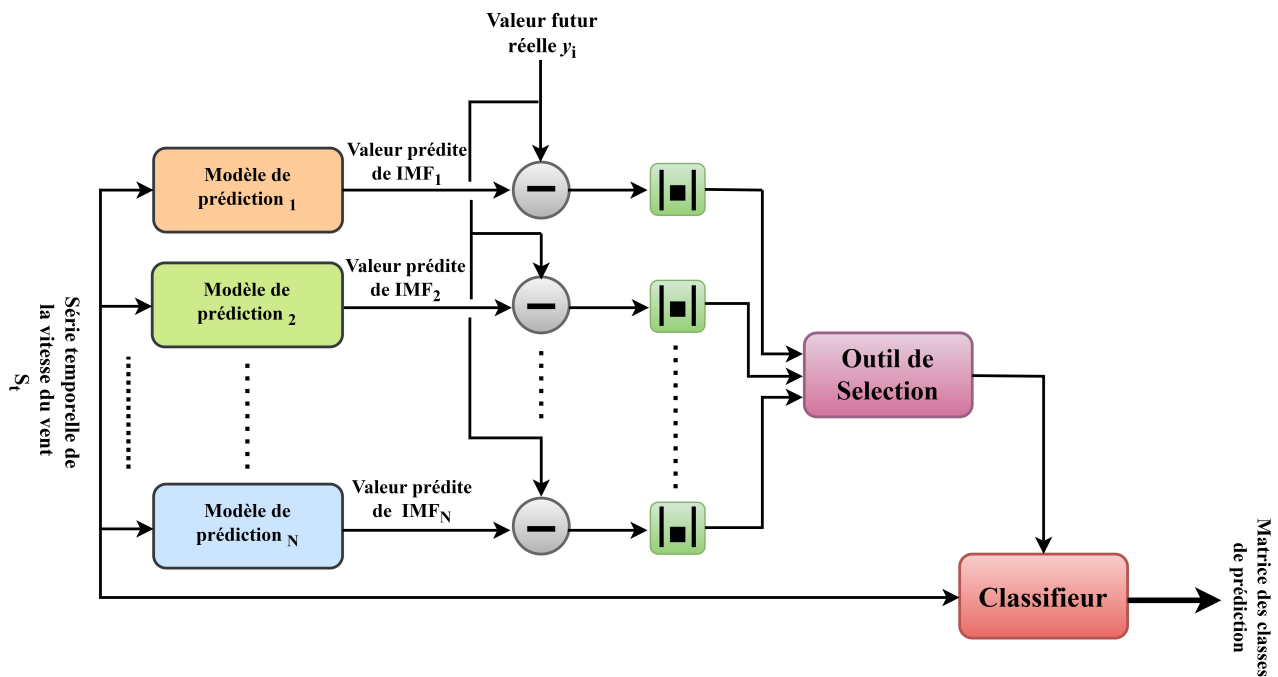


FIGURE 5.7 – Organigramme de la technique basée sur la classification.

5.6 Expérimentation et évaluation des performances

5.6.1 Description des données utilisés

5.6.1.1 Jeu de données # 1

Les données utilisées dans cette étude proviennent de plusieurs sites répartis en Algérie, un pays situé dans la zone subtropicale de l’Afrique du Nord. Les différentes régions du pays présentent une diversité climatique notable, à la fois d’Est en Ouest et du Nord au Sud. Le climat méditerranéen prédomine sur la frange nord, englobant l’Atlas tellien et la côte, caractérisé par des hivers humides et frais ainsi que des étés chauds et secs. En revanche, les hauts plateaux situés au centre du pays connaissent un climat semi-aride, tandis que le climat désertique domine au-delà de l’Atlas saharien.

Dans cette étude, des séries temporelles quotidiennes moyennes de vitesse du vent ont été recueillies sur sept sites durant une période de dix ans, de 1995 à 2004. Le tableau 5.1 présente les noms des sites, ainsi que leurs coordonnées géographiques (latitude, longitude), leur altitude et le nombre de points de données recueillis pour chacun. Ces stations ont été sélectionnées afin de couvrir les quatre directions géographiques de l’Algérie (du sud au nord et de l’ouest à l’est), ainsi que la zone centrale [121].

Les caractéristiques statistiques des sept sites sont résumées dans le tableau 5.2.

5.6.1.2 Jeu de données # 2

Des expériences de simulation ont été menées à l’aide de données historiques de séries temporelles de vitesse du vent, provenant de deux sites situés dans le sud de l’Algérie, afin d’évaluer la précision et l’efficacité de l’approche hybride proposée. Le premier site fournit des données enregistrées toutes les 30 minutes sur une période d’un an, s’étendant du 1^{er} janvier au 31 décembre 2016, tandis que le second site a enregistré des données toutes les

TABLE 5.1 – Caractéristiques géographiques des sept sites étudiés.

Site	Position géographique	Altitude (m)	Latitude (°)	Longitude (°)	# jours
Adrar	Sud-Ouest	263	27.88	-0.28	3653
Bechar	Sud-Ouest	733	31.5	-2.23	3653
Chlef	Nord-Ouest	143	36.21	1.33	3378
Oran	Nord-Ouest	90	35.63	-0.6	3653
Batna	Nord-Ouest	1052	35.75	6.18	3653
Annaba	Nord-Ouest	4	36.83	7.81	3653
Tamanrasset	Sud	1377	22.8	5.46	3653

TABLE 5.2 – Caractéristiques statistiques des sites étudiés.

Site	Moy. (m/s)	Écart type (m/s)	Max. (m/s)	Médiane (m/s)	Min. (m/s)
Adrar	6.20	1.99	16.17	6.08	0.67
Bechar	3.84	1.36	14.86	3.64	0.53
Chlef	3.56	2.22	16.05	3.33	0
Oran	4.41	2.32	19.08	4.11	0
Batna	2.98	1.50	14.36	2.78	0
Annaba	3.26	1.94	16.78	2.94	0
Tamanrasset	3.64	1.88	11.47	3.44	0

15 minutes sur une période similaire, du 1^{er} janvier au 31 décembre 2019. Ces sites ont été sélectionnés pour représenter des régimes éoliens distincts.

Le tableau 5.3 présente les caractéristiques géographiques des deux sites, incluant la latitude, la longitude, l'altitude ainsi que la taille des données associées à chaque site. Cinquante valeurs (50) des séries temporelles sont utilisées comme données d'entrée, tandis que la 51^e valeur sert de cible pour la prédiction (valeur future).

TABLE 5.3 – Caractéristiques géographiques des sites de test #1 et #2.

Données	Position	Altitude (m)	Latitude (°)	Longitude (°)	Taille
Site #1	Sud-Ouest	263	27.88	-0.28	10 172
Site #2	Sud-Est	450	36.667	5.667	34 943

Le tableau 5.4 présente un résumé des caractéristiques statistiques des données issues des sites #1 et #2, incluant notamment la moyenne, l'écart-type ainsi que les valeurs extrêmes de la vitesse du vent.

5.7 Mesures de performance

Pour évaluer la performance du processus de prédiction et comparer l'efficacité des différents modèles proposés pour prédire la vitesse du vent, quatre indicateurs statistiques basés sur les valeurs prédites et réelles ont été retenus : RMSE, MABE, MAPE et le coefficient de détermination (R^2). Les formules de ces métriques sont exprimées par les équations suivantes :

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (4.52)$$

TABLE 5.4 – Caractéristiques statistiques des deux sites #1 et #2.

Données	Résolution	Moy. (m/s)	Écart type (m/s)	Max. (m/s)	Médiane (m/s)	Min. (m/s)
Site #1	30 min	5.39	2.89	21.80	4.9	0
Site #2	15 min	4.69	3.45	23.30	4.0	0

$$\text{MABE} = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (4.53)$$

$$\text{MAPE} = \frac{100}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (4.54)$$

$$R^2 = 1 - \frac{\text{var}(y_i - \hat{y}_i)}{\text{var}(y_i)} \quad (4.55)$$

Où \hat{y}_i et y_i représentent respectivement les valeurs prédites et observées de la vitesse du vent, $\text{var}(y_i)$ désigne la variance des valeurs mesurées, et N est le nombre total d'observations dans la série temporelle.

5.8 Résultats Expérimentaux

5.8.1 Modèles hybrides : EMD/VMD et RNA

L'approche hybride se décompose en plusieurs étapes : la décomposition des séries temporelles, l'utilisation des réseaux de neurones artificiels (RNA), l'agrégation des prédictions issues des modèles individuels, ainsi que l'application de diverses stratégies de combinaison. La figure 5.8 présente le schéma général de l'approche hybride proposée pour la prédiction de la vitesse du vent.

Le processus débute par l'application des techniques de décomposition EMD et VMD (présentées respectivement aux sous-sections 5.2.1 et 5.2.2) afin de fragmenter les données initiales de vitesse du vent en un ensemble de sous-séries distinctes, chaque composant pouvant être prédit de manière indépendante. Pour chacune de ces sous-séries, plusieurs modèles de prédiction fondés sur les RNA sont élaborés afin de générer les prédictions correspondantes. L'étape suivante consiste en l'agrégation des prédictions des sous-séries issues d'un même modèle RNA individuel. Enfin, divers scénarios de combinaison, détaillés dans la section 5.5.1, sont appliqués aux prédictions produites par les RNA afin d'obtenir la prédiction globale de la vitesse du vent.

5.8.1.1 Expériences de prédiction

Les enregistrements originaux de la vitesse du vent, collectés sur chaque site et présentés à la sous-section 5.6.1.1, sont employés afin de démontrer la validité et l'efficacité des approches proposées. Trois groupes distincts de modèles hybrides sont développés pour la prédiction de la vitesse quotidienne du vent. L'organigramme du processus de prédiction hybride est illustré à la figure 5.9.

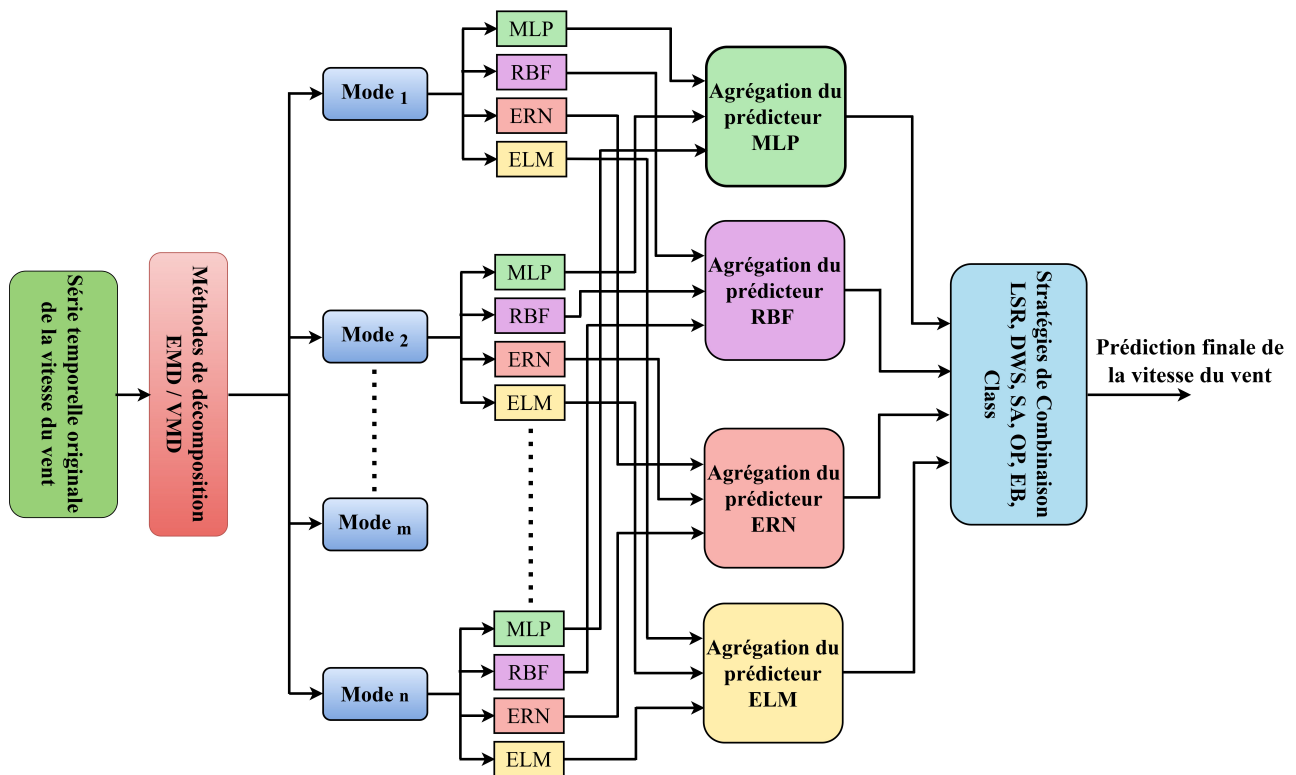


FIGURE 5.8 – Schéma général de l'approche hybride proposée.

5.8.1.2 Résultats des différents modèles et analyse

Trois groupes de modèles hybrides sont conçus pour prédire la vitesse du vent en combinant les avantages des méthodes de décomposition (VMD, EMD), des réseaux de neurones artificiels (MLPNN, RBFNN, ERNN, ELMNN) et des scénarios de combinaison (SA, OP, EB, LSR, DWS, CB).

- **Le premier groupe** utilise exclusivement des réseaux de neurones artificiels comme modèles individuels, appliqués directement aux séries temporelles originales de vitesse du vent, ainsi que des scénarios de combinaison pour agréger les différentes prédictions produites par ces RNA ;
- **Le deuxième groupe** intègre la méthode de décomposition EMD afin de segmenter les signaux originaux de vitesse du vent. Ensuite, les modèles RNA individuels sont employés pour prévoir chaque sous-série. La sortie de chaque modèle individuel est obtenue par l'agrégation des prédictions partielles des sous-séries correspondantes. Enfin, la prédiction globale est générée par la combinaison des résultats de tous les modèles RNA ;
- **Le troisième groupe** suit une approche similaire, en substituant la méthode EMD par la technique de décomposition VMD pour segmenter les vitesses de vent originales. Les modèles RNA individuels prévoient ensuite chaque sous-série, dont les résultats sont sommés pour chaque modèle individuel. La prédiction globale est alors calculée en combinant les résultats des différents modèles RNA.

Les performances statistiques des trois groupes pour les sept localités étudiées sont présentées dans les tableaux 5.5 à 5.7. Les données utilisées pour l'évaluation de ces méthodologies correspondent aux séries temporelles de vitesse du vent enregistrées dans sept localités algériennes, représentatives de différents sous-climats, comme illustré à la figure 5.10.

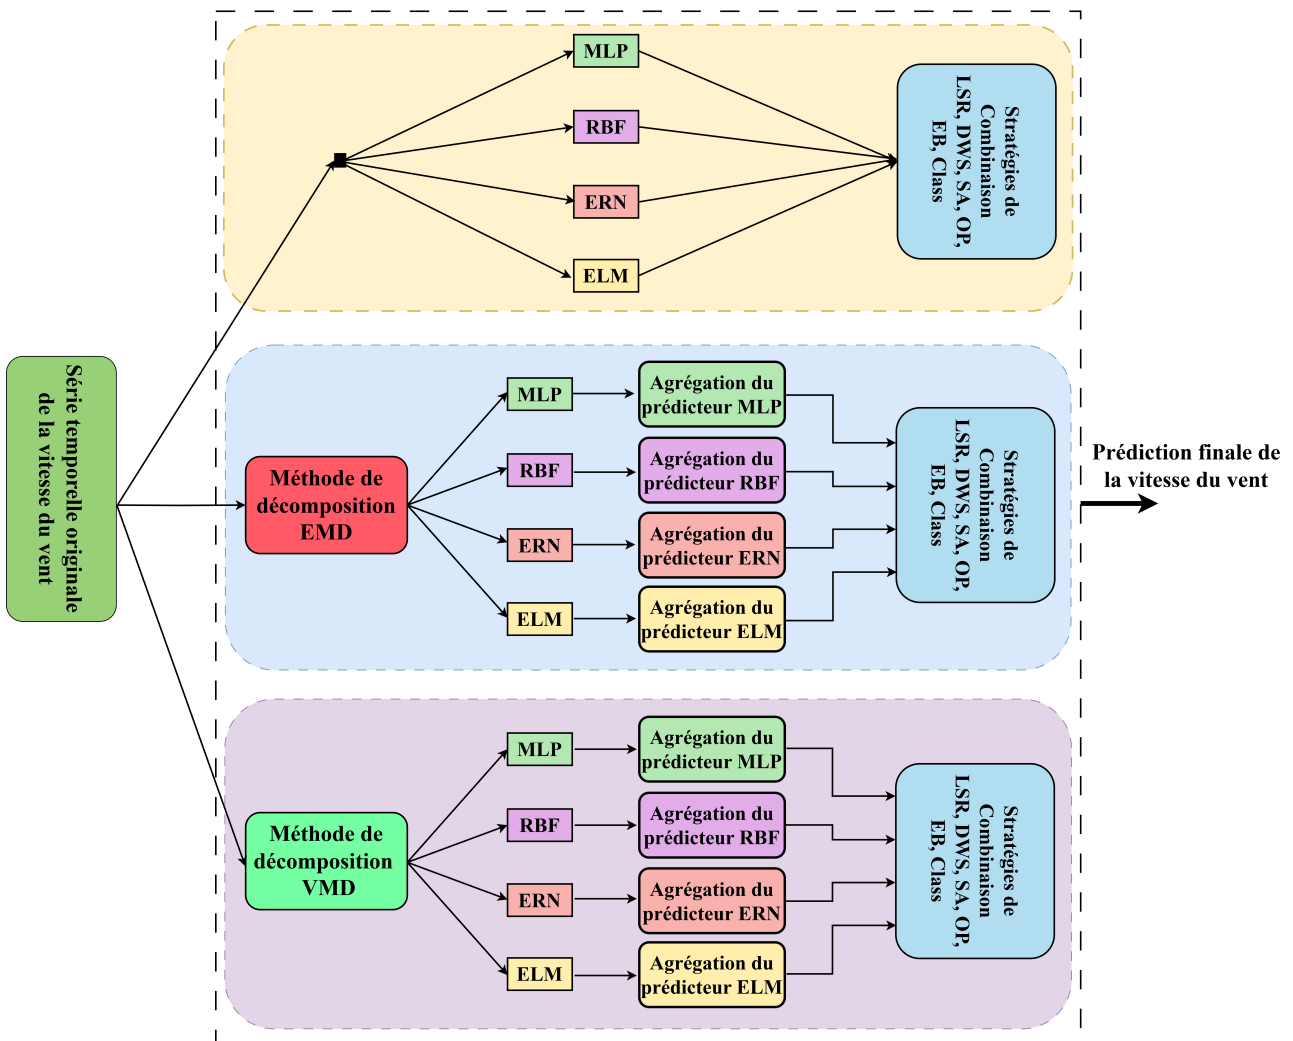


FIGURE 5.9 – Organigramme du processus de prédiction hybride.

5.8.1.3 Résultats obtenus avec le premier groupe de modèles hybrides

Dans ce groupe, les résultats obtenus par les modèles individuels, à savoir ERNN, MLPNN, RBFNN et ELMNN, combinés selon différents scénarios, sont présentés dans le tableau 5.5. La majorité des indicateurs statistiques montre que les modèles MLPNN, et dans une moindre mesure les ERNN, affichent les meilleures performances. Cette supériorité s'explique par la nature des modèles MLPNN, qui reposent sur des architectures flexibles comportant une ou plusieurs couches cachées, leur permettant d'approximer toute fonction non linéaire. Quant aux ERNN, ils intègrent un mécanisme de mémoire interne capable de retenir les entrées des fonctions à prédire, ce qui les rend particulièrement adaptés aux problèmes d'apprentissage automatique impliquant des séries temporelles et des données séquentielles. La figure 5.11 illustre un exemple de prédictions réalisées sur le site de test d'Annaba à l'aide des modèles RNA individuels uniquement.

Afin d'améliorer les performances des modèles individuels RNA, plusieurs scénarios de combinaison ont été implémentés dans le but d'exploiter conjointement la capacité prédictive de chaque technique individuelle. Les résultats obtenus sont présentés à la figure 5.12 pour le même site de test, Annaba. Globalement, les indicateurs statistiques de ce groupe révèlent des performances satisfaisantes en termes d'erreurs et de précision, attestant de la supériorité des scénarios de combinaison par rapport aux modèles individuels simples. Notamment, la meilleure performance est observée lorsque CB est employée.

TABLE 5.5 – Résultats de prédiction obtenus utilisant le premier groupe de modèles hybrides.

Location / méthodes	Modèles individuels				Scénarios de combinaison					
	ERNN	MLPNN	ELMNN	RBFNN	LSR	OP	SA	DW	EB	CB
Adrar										
R ²	22.2	23.2	21.9	20.1	24.0	23.5	23.6	23.2	23.6	41.3
RMSE	1.816	1.804	1.819	1.840	1.794	1.800	1.799	1.804	1.800	1.577
MAPE	28.77	28.57	28.71	29.32	28.24	28.62	28.62	28.77	28.64	23.79
MABE	1.436	1.438	1.442	1.461	1.422	1.430	1.430	1.437	1.431	1.173
Annaba										
R ²	21.8	21.3	17.6	16.9	22.4	21.8	21.7	21.8	21.5	41.3
RMSE	1.286	1.290	1.320	1.325	1.281	1.286	1.286	1.286	1.288	1.114
MAPE	27.42	27.31	28.62	28.16	27.51	27.46	27.48	27.29	27.53	21.55
MABE	0.931	0.930	0.964	0.961	0.927	0.930	0.931	0.927	0.933	0.729
Batna										
R ²	39.1	40.3	29.5	25.3	45.8	36.4	36.1	38.3	35.6	55
RMSE	1.338	1.325	1.440	1.482	1.262	1.367	1.371	1.347	1.376	1.150
MAPE	52.43	51.49	55.99	59.45	45.21	53.94	54.19	52.80	54.41	41.30
MABE	1.068	1.049	1.140	1.211	0.921	1.099	1.104	1.075	1.108	0.841
Bechar										
R ²	25.68	26.91	24.01	25.84	27.83	27.61	27.58	26.57	27.58	46.32
RMSE	2.075	2.057	2.098	2.072	2.044	2.047	2.048	2.062	2.048	1.763
MAPE	41.90	41.45	42.53	41.49	41.12	41.31	41.3	41.38	41.31	32.85
MABE	1.645	1.627	1.669	1.629	1.614	1.622	1.621	1.624	1.621	1.290
Chlef										
R ²	10.02	6.93	8.97	7.12	11.38	10.08	10.35	9.90	10.07	36.36
RMSE	1.211	1.256	1.218	1.230	1.202	1.210	1.209	1.212	1.210	1.018
MAPE	38.13	34.32	37.06	39.25	36.75	36.26	36.69	37.82	36.55	27.21
MABE	0.913	0.907	0.910	0.938	0.902	0.900	0.903	0.914	0.903	0.678
Oran										
R ²	22.54	22.37	17.10	21.98	24.98	23.79	23.86	23.08	23.67	44.81
RMSE	1.487	1.489	1.538	1.493	1.464	1.475	1.474	1.482	1.476	1.255
MAPE	37.10	37.73	38.44	37.858	36.05	36.93	36.92	37.20	36.95	28.09
MABE	1.084	1.103	1.123	1.11	1.054	1.079	1.079	1.087	1.080	0.821
Tamanrasset										
R ²	24.14	22.76	19.71	22.13	25.31	23.73	23.82	23.89	23.75	42.43
RMSE	1.477	1.490	1.519	1.496	1.465	1.481	1.480	1.479	1.480	1.286
MAPE	41.54	42.23	42.90	42.00	40.61	41.82	41.81	41.83	41.82	34.02
MABE	1.198	1.218	1.238	1.212	1.172	1.206	1.206	1.207	1.2067	0.981




FIGURE 5.10 – Les enregistrements complets de la vitesse du vent pour les sept sites de test.

5.8.1.4 Résultats obtenus avec le deuxième groupe de modèles hybrides

Au sein de ce groupe de modèles, dans le but d’améliorer la précision des prédictions, une étape de traitement supplémentaire est mise en œuvre via la technique de décomposition par mode empirique (EMD) appliquée aux séries temporelles originales de vitesse du vent. Cette méthode d’analyse temps-espace adaptative permet de traiter des séries temporelles non stationnaires et non linéaires en les décomposant en modes intrinsèques (IMFs) dans le domaine temporel, sans recourir à une transformation fréquentielle.

À l’instar d’autres approches basées sur l’analyse temps-espace, l’EMD ne repose pas sur des principes physiques explicites, bien que les modes extraits puissent révéler des informations pertinentes sur les signaux sous-jacents composant les données temporelles. Cette méthode est particulièrement adaptée à l’analyse des signaux naturels, souvent caractérisés par leur non-stationnarité et leur non-linéarité. Un exemple des différentes composantes extraites sur le site de test de Chlef est présenté à la figure 5.13.

Les résultats des différents modèles hybrides, à savoir EMD-ERNN, EMD-MLPNN, EMD-RBFNN et EMD-ELMNN, sont présentés dans la figure 5.14. Dans ce cadre, seules deux étapes de traitement sont considérées : la décomposition et la prédiction. Les résultats numériques des indicateurs statistiques, exposés dans le tableau 5.6, révèlent que les modèles EMD-ERNN et EMD-MLPNN surpassent les autres modèles selon l’ensemble des mesures d’erreur évaluées.

La seconde phase de ce groupe intègre un bloc additif visant à agréger les résultats issus de la phase précédente (décomposition et prédiction). Dans ce cadre, plusieurs modèles hybrides sont élaborés, notamment EMD-ANN-LSR, EMD-ANN-OP, EMD-ANN-SA, EMD-ANN-DWS, EMD-ANN-EB et EMD-ANN-CB, combinant la méthode de décomposition EMD, les modèles de réseaux de neurones artificiels (RNA) ainsi que divers scénarios de combinaison.

Les résultats correspondants sont présentés à la figure 5.15 pour le même site de test, Chlef. Il en ressort que le modèle EMD-ANN-CB, reposant sur un scénario basé sur la classification, surpasse les autres modèles utilisant différents scénarios de combinaison.




FIGURE 5.11 – Vitesse du vent mesurée et prédite du site de test — Annaba — obtenue avec les modèles RNA uniquement et sans décomposition.




FIGURE 5.12 – Vitesse du vent mesurée et prédite du site de test — Annaba — obtenue avec les modèles RNA combinés et sans décomposition.

TABLE 5.6 – Résultats de prédiction obtenus en utilisant le deuxième groupe de modèles hybrides.

Location / méthodes	EMD - Modèles Individuels				EMD - Scénarios de combinaison					
	ERNN	MLPNN	ELMNN	RBFNN	LSR	OP	SA	DWS	EB	CB
Adrar										
R ²	68.8	69.8	63.4	50.4	70.5	68.2	68.0	66.5	67.2	83.9
RMSE	1.149	1.131	1.246	1.450	1.118	1.161	1.164	1.192	1.179	0.826
MAPE	17.69	17.68	19.14	22.88	17.28	18.26	18.32	18.68	18.56	11.46
MABE	0.902	0.892	0.990	1.138	0.882	0.920	0.923	0.950	0.933	0.571
Annaba										
R ²	67.2	67.2	62.8	54.5	68.2	67.0	67.1	56.5	66.9	82.1
RMSE	0.833	0.832	0.887	0.981	0.820	0.835	0.834	0.958	0.837	0.614
MAPE	17.28	17.27	18.87	21.80	16.91	17.82	17.77	21.22	17.90	11.45
MABE	0.601	0.599	0.658	0.729	0.597	0.614	0.613	0.710	0.616	0.394
Batna										
R ²	76.1	69.9	73.6	40.9	78.1	75.0	73.0	76.8	71.8	88.9
RMSE	0.839	0.941	0.881	1.318	0.803	0.857	0.891	0.827	0.910	0.572
MAPE	28.98	35.95	30.63	52.32	28.75	31.34	33.41	29.18	34.45	17.55
MABE	0.590	0.732	0.624	1.065	0.585	0.640	0.680	0.594	0.702	0.357
Bechar										
R ²	68.6	68.5	62.5	55.1	68.9	67.5	67.6	68.6	67.3	81.8
RMSE	1.348	1.351	1.473	1.613	1.342	1.372	1.369	1.348	1.375	1.025
MAPE	26.58	26.68	29.19	31.63	26.52	27.15	27.09	26.68	27.21	18.11
MABE	1.043	1.047	1.146	1.241	1.041	1.065	1.063	1.047	1.068	0.711
Chlef										
R ²	64.3	64.3	58.6	46.7	65.5	64.1	64.3	64.4	63.7	80.3
RMSE	0.763	0.762	0.822	0.932	0.750	0.764	0.763	0.762	0.769	0.566
MAPE	22.74	22.91	25.41	28.36	22.25	23.06	23.00	22.89	23.23	14.52
MABE	0.565	0.566	0.634	0.716	0.563	0.579	0.577	0.565	0.583	0.369
Oran										
R ²	64.9	62.2	61.0	48.9	67.1	64.9	64.5	65.0	64.0	82.0
RMSE	1.001	1.039	1.055	1.208	0.969	1.001	1.006	1.000	1.013	0.716
MAPE	25.16	26.36	26.55	31.20	24.74	25.32	25.51	25.21	25.74	15.38
MABE	0.735	0.770	0.776	0.912	0.723	0.740	0.746	0.737	0.752	0.449
Tamanrasset										
R ²	74.0	72.8	68.7	59.3	74.6	73.6	73.2	74.1	72.9	86.7
RMSE	0.864	0.885	0.948	1.082	0.854	0.871	0.877	0.863	0.882	0.618
MAPE	23.42	23.57	26.15	29.94	23.05	23.76	23.98	23.13	24.15	14.43
MABE	0.676	0.680	0.754	0.864	0.665	0.685	0.692	0.667	0.697	0.416




FIGURE 5.13 – Les formes d’onde des composantes EMD et le terme résiduel du site de test — Chlef —.

5.8.1.5 Résultats obtenus avec le troisième groupe de modèles hybrides

Afin d’évaluer plus en profondeur la méthodologie de décomposition dans le cadre de la prédiction, une méthode alternative reconnue est ici étudiée : la décomposition modale variationnelle (VMD). Cette technique récente de décomposition, utilisée pour résoudre divers problèmes d’ingénierie, se présente comme une alternative à la méthode classique de décomposition empirique modale (EMD). Toutefois, la performance de la VMD dépend essentiellement d’un paramètre critique à déterminer : le nombre de modes.

Un exemple d’application de la VMD aux séries temporelles issues du site de test d’Adrar est présenté à la figure 5.16. Les différentes valeurs des indicateurs statistiques correspondants sont synthétisées dans le tableau 5.7.

Par ailleurs, un graphique comparatif présentant les résultats de la première phase du troisième groupe de modèles hybrides, à savoir VMD-ERNN, VMD-MLPNN, VMD-RBFNN et VMD-ELMNN (décomposition-prédiction), est présenté à la figure 5.17. Dans ce contexte, les modèles VMD-ERNN et VMD-MLPNN se distinguent comme les plus performants, comme en témoignent les indicateurs d’erreur et les coefficients de corrélation observés sur l’ensemble des sites de test. Ces résultats illustrent une amélioration notable par rapport à ceux obtenus avec la technique EMD.

Par ailleurs, les performances de la seconde phase de ce groupe, comprenant les modèles VMD-ANN-LSR, VMD-ANN-OP, VMD-ANN-SA, VMD-ANN-DWS, VMD-ANN-EB et VMD-ANN-CB, surpassent nettement celles des modèles ne comportant que deux blocs de traitement (voir figure 5.18).

Afin de comparer de manière intuitive la précision des prédictions obtenues par les différentes approches proposées dans cette étude, un diagramme de Taylor est utilisé. Il s’agit d’une représentation graphique alternative permettant d’évaluer simultanément les performances des modèles selon plusieurs métriques. Ce diagramme met en évidence trois statistiques : l’écart-type, le coefficient de corrélation ainsi que la différence centrée de la racine carrée de l’erreur quadratique moyenne (CRMSE) [181].

TABLE 5.7 – Résultats de prédiction obtenus en utilisant le troisième groupe de modèles hybrides.

Location / Méthode	VMD - Modèles individuels				VMD - Scénarios de combinaison					
	ERNN	MLPNN	ELMNN	RBFNN	LSR	OP	SA	DW	EB	CB
Adrar										
R ²	92.9	91.9	86.2	78.1	94.4	93.0	92.6	91.9	92.2	97.4
RMSE	0.546	0.586	0.763	0.886	0.486	0.544	0.559	0.586	0.576	0.335
MAPE	8.17	8.74	11.88	13.07	7.45	8.42	8.68	8.74	8.99	4.76
MABE	0.434	0.464	0.611	0.691	0.385	0.428	0.440	0.463	0.453	0.243
Annaba										
R ²	91.6	91.5	87.7	83.7	93.2	92.2	92.5	91.5	92.3	97.5
RMSE	0.421	0.423	0.510	0.536	0.379	0.405	0.398	0.424	0.402	0.230
MAPE	9.04	8.96	10.82	9.24	7.98	8.23	8.13	8.96	8.17	4.36
MABE	0.310	0.310	0.372	0.345	0.271	0.288	0.284	0.311	0.286	0.152
Batna										
R ²	94.2	83.5	78.8	75.1	96.9	91.5	89.0	85.9	88.6	97.3
RMSE	0.411	0.697	0.789	0.815	0.300	0.501	0.569	0.644	0.579	0.282
MAPE	16.84	28.45	30.86	32.28	11.51	20.42	23.16	26.39	23.56	10.83
MABE	0.343	0.579	0.629	0.658	0.234	0.416	0.472	0.537	0.480	0.221
Bechar										
R ²	91.8	91.9	87.8	81.4	93.9	93.0	93.1	93.2	93.0	97.2
RMSE	0.687	0.686	0.839	1.013	0.594	0.634	0.632	0.629	0.635	0.399
MAPE	13.6	13.67	16.53	19.90	11.63	12.40	12.36	12.34	12.41	7.06
MABE	0.534	0.536	0.649	0.781	0.757	0.487	0.485	0.484	0.487	0.277
Chlef										
R ²	92.5	92.9	88.9	84.6	96.0	94.8	94.8	84.1	94.8	97.9
RMSE	0.348	0.340	0.426	0.496	0.256	0.292	0.290	0.508	0.290	0.184
MAPE	9.25	8.93	11.36	13.37	6.97	7.82	7.72	13.67	7.75	4.56
MABE	0.265	0.256	0.326	0.383	0.200	0.224	0.221	0.392	0.222	0.131
Oran										
R ²	95.7	94.9	85.0	88.2	96.7	96.1	95.8	92.4	95.7	98.3
RMSE	0.352	0.379	0.655	0.547	0.289	0.316	0.328	0.442	0.332	0.209
MAPE	9.00	9.75	16.77	13.66	7.31	7.92	8.22	10.92	8.30	4.87
MABE	0.263	0.285	0.490	0.399	0.213	0.232	0.240	0.319	0.243	0.142
Tamanrasset										
R ²	95.0	94.9	79.6	69.0	95.4	93.2	91.0	91.3	90.2	97.4
RMSE	0.379	0.386	0.765	0.896	0.361	0.443	0.507	0.499	0.531	0.271
MAPE	10.28	10.52	21.34	25.41	9.75	12.45	14.31	14.01	14.97	6.87
MABE	0.297	0.303	0.616	0.733	0.281	0.359	0.413	0.404	0.432	0.198




FIGURE 5.14 – Vitesse du vent mesurée et prédite du site de test — Chlef — obtenue avec les modèles RNA après la décomposition EMD.

Les diagrammes de Taylor correspondant aux trois groupes de modèles hybrides, appliqués aux différents sites de test, sont présentés respectivement aux figures 5.19, 5.20 et 5.21. Ils montrent que les coefficients de corrélation entre les vitesses réelles et prédites du vent se situent dans l'intervalle $[0,40 - 0,75]$ pour les modèles du premier groupe, dans $[0,75 - 0,90]$ pour le deuxième groupe, et dans $[0,90 - 0,99]$ pour le troisième groupe. Cette progression témoigne d'une amélioration significative des performances lors du passage d'un groupe à l'autre, confirmant ainsi l'efficacité des méthodes de décomposition employées.

Par ailleurs, les diagrammes de Taylor illustrent également l'écart-type et l'erreur centrée (RMSD) entre les valeurs mesurées et prédites des séries temporelles, proportionnelle à la distance radiale entre ces valeurs. Ces analyses démontrent clairement que les modèles hybrides basés sur VMD-ANN-CB surpassent tous les autres modèles hybrides proposés.

5.8.2 Modèles basée sur la décomposition ICEEMDAN, entropie de l'échantillon et apprentissage profond

Cette thèse propose une approche hybride alternative. Celle-ci débute par la collecte de séries temporelles de données anémométriques, en veillant à constituer un ensemble de données fiable et représentatif. Un processus rigoureux de prétraitement est ensuite appliqué, comprenant l'imputation des valeurs manquantes ainsi que la normalisation des données par la méthode du *Z-score*, afin d'assurer leur homogénéité et leur comparabilité pour les analyses ultérieures. Les données ainsi normalisées sont décomposées au moyen d'ICEEMDAN, générant plusieurs fonctions de mode intrinsèque (IMF), chacune représentant des composantes fréquentielles spécifiques. Afin d'isoler les composantes les plus pertinentes, l'entropie d'échantillon (SE) est calculée pour chaque IMF. Seules celles présentant les valeurs d'entropie les plus élevées, traduisant leur importance, sont sélectionnées. Ces IMFs sélectionnées sont ensuite reconstruites pour constituer un jeu de données raffiné, capturant la dynamique essentielle des séries temporelles de vitesse du vent.




FIGURE 5.15 – Vitesse du vent mesurée et prédite du site de test — Chlef — obtenue avec la combinaison des modèles RNA après la décomposition EMD.




FIGURE 5.16 – Les formes d’onde des composantes VMD et le terme résiduel du site de test — Adrar —.




FIGURE 5.17 – Vitesse du vent mesurée et prédite du site de test — Adrar — obtenue avec les modèles RNA après la décomposition VMD.




FIGURE 5.18 – Vitesse du vent mesurée et prédite du site de test — Adrar — obtenue avec la combinaison des modèles RNA après la décomposition VMD.




FIGURE 5.19 – Diagramme de Taylor de la vitesse du vent mesurée et prédite du site de test — Annaba — obtenue avec les modèles RNA combinés et sans décomposition.




FIGURE 5.20 – Diagramme de Taylor de la vitesse du vent mesurée et prédite du site de test — Chlef — obtenue avec la combinaison des modèles RNA après la décomposition EMD.




FIGURE 5.21 – Diagramme de Taylor de la vitesse du vent mesurée et prédite du site de test — Adrar — obtenue avec la combinaison des modèles RNA après la décomposition VMD.

Ce jeu de données raffiné sert d’entrée à plusieurs modèles d’apprentissage profond, notamment les réseaux LSTM, BiLSTM, GRU et BiGRU, conçus pour modéliser les motifs temporels complexes et les dépendances au sein des données séquentielles. Les prédictions issues de ces modèles sont intégrées via une technique d’agrégation fondée sur la classification, combinant les forces de chaque modèle afin de produire une prédiction finale optimisée.

Le schéma complet de cette méthodologie est présenté à la figure 5.22, offrant une représentation claire de l’architecture du système et de ses étapes successives.

5.8.2.1 Expériences de prédiction

Les données originales de vitesse du vent provenant des deux sites d’expérimentation, décrits dans la sous-section 5.6.1.2, sont exploitées pour valider et démontrer l’efficacité de l’approche proposée. À cette fin, deux ensembles distincts de modèles hybrides sont développés, visant à prévoir avec précision la vitesse du vent à court terme pour chacun des sites.

5.8.2.2 Résultats des différents modèles et discussion

Cette étude mobilise deux approches complémentaires pour la prédiction de la vitesse du vent, en tirant parti des avantages offerts par la méthode de décomposition ICEEMDAN, des réseaux de neurones profonds, notamment LSTM, BiLSTM, GRU et BiGRU, ainsi que d’une technique de combinaison fondée sur la classification.

- **Première approche** : cette méthode repose exclusivement sur des réseaux de neurones profonds considérés comme modèles individuels, appliqués directement aux séries temporelles originales de vitesse du vent. Une technique d’agrégation par classification est ensuite utilisée pour fusionner les résultats produits par ces différents réseaux.

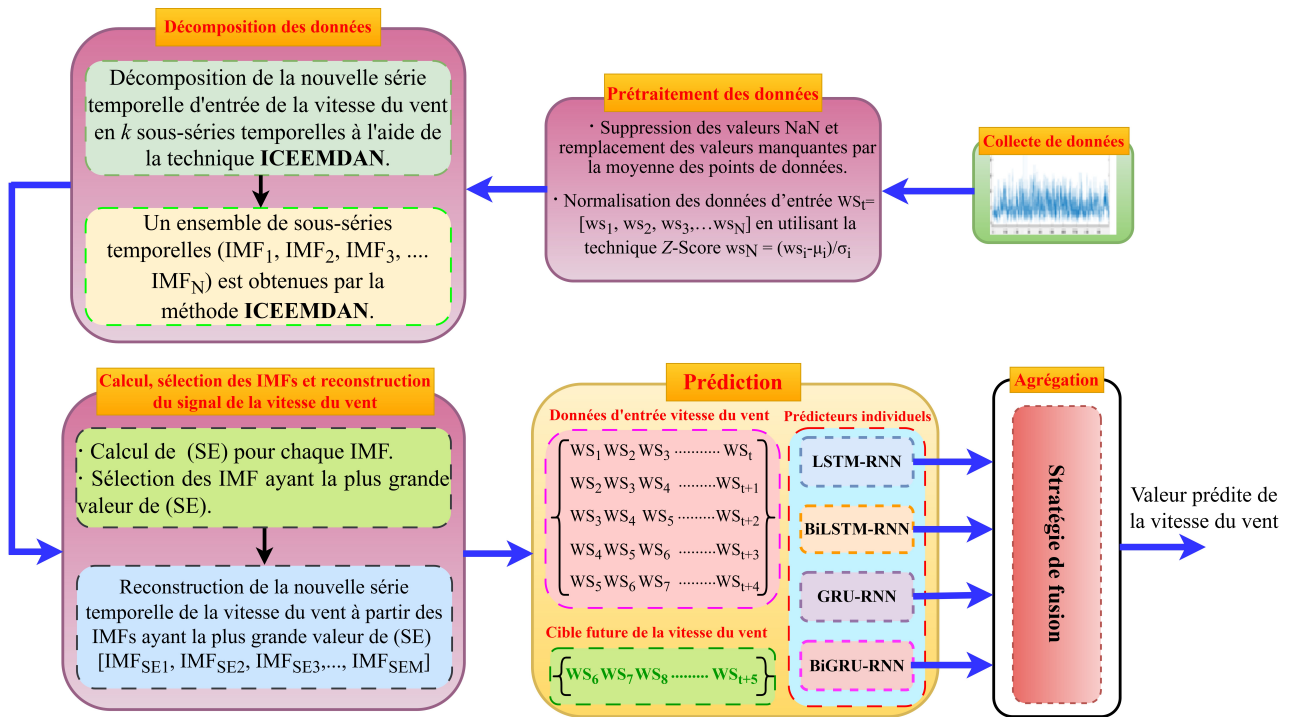


FIGURE 5.22 – Organigramme de l’approche ICEEMDAN-SE-DL proposée pour la prédiction de la vitesse du vent.

— **Deuxième approche** : cette approche intègre la méthode de décomposition *ICEEMDAN* afin de décomposer les signaux originaux de vitesse du vent. L’entropie d’échantillon (SE) est ensuite employée pour sélectionner les fonctions de mode intrinsèque (IMFs) les plus pertinentes. Les modèles optimaux sont obtenus par un réglage fin (*fine tuning*) et une validation croisée. La prédiction finale est générée par l’agrégation des résultats issus de l’ensemble des modèles de réseaux de neurones profonds (DNN).

Les performances statistiques des deux approches, appliquées aux deux sites, sont présentées dans les tableaux 5.8 et 5.10, où les meilleurs résultats sont indiqués en gras.

Les données utilisées dans cette étude pour évaluer les différentes méthodologies consistent en des séries temporelles de vitesse du vent enregistrées sur deux sites en Algérie, représentant deux sous-climats distincts, comme illustré dans la figure 5.23. Les échantillons normalisés correspondants à chaque site sont présentés dans la figure 5.24.

5.8.2.3 Résultats obtenus avec la première approche

Cette étude analyse la performance des modèles individuels (LSTM, BiLSTM, GRU et BiGRU) et leur combinaison dans une approche de classification. Les résultats, présentés au tableau 5.8, montrent que les BiGRU, grâce à leur architecture légère et efficace, surpassent les BiLSTM en offrant une meilleure précision avec une complexité réduite. Bien que les BiLSTM capturent des relations complexes à long terme, les BiGRU s’avèrent plus adaptés aux prédictions séquentielles grâce à leur apprentissage rapide. Les figures 5.25 et 5.26 illustrent que la combinaison des modèles améliore la précision globale tout en réduisant les erreurs, confirmant ainsi l’efficacité des approches hybrides.




FIGURE 5.23 – Une petite fenêtre des séries temporelles originales de la vitesse du vent des deux sites de test.

5.8.2.4 Résultats obtenus avec la deuxième approche

Dans cette approche, une nouvelle étape de traitement fondée sur la technique ICEEMDAN est introduite et intégrée afin d'améliorer la précision des prédictions de la vitesse du vent. Cette méthode d'analyse spatio-temporelle permet de décomposer les séries temporelles non stationnaires et non linéaires en fonctions de mode intrinsèque (IMFs), tout en optimisant la stabilité et la précision de la décomposition. L'ajout de bruit adaptatif contribue à atténuer les phénomènes de sur-décomposition et améliore la fiabilité des composantes extraites, offrant ainsi une meilleure représentation des signaux complexes, notamment ceux de nature naturelle. Les composantes extraites pour les deux sites de test sont présentées respectivement dans les figures 5.27 et 5.28.

Les composantes IMFs optimales sont sélectionnées à l'aide de la méthode de l'entropie d'échantillon (*Sample Entropy*), comme présenté dans le tableau 5.9. Suite à cette sélection, le signal est reconstruit puis transmis aux modèles individuels de prédiction pour l'étape de prédiction. Afin d'améliorer davantage les performances des modèles individuels de réseaux de neurones profonds (DNN), un module additif incorporant une stratégie de combinaison fondée sur la classification est introduit, permettant d'agréger les résultats produits par les différents prédicteurs. Les performances des modèles hybrides (ICEEMDAN-LSTM, ICEEMDAN-BiLSTM, ICEEMDAN-GRU, ICEEMDAN-BiGRU) et de leur combinaison via la stratégie de classification sont présentées dans les figures 5.29 et 5.30 pour les deux sites de test. Le tableau 5.10 révèle que le modèle hybride combiné (ICEEMDAN-DNN-Class) offre les meilleures performances. Les résultats dans les figures 5.31 et 5.32, sous forme d'histogrammes de la métrique RMSE pour les sites de test #1 et #2, indiquent que «Class» est la stratégie la plus efficace pour réduire les erreurs de prédiction.

TABLE 5.8 – Détails des métriques d'évaluation des performances des modèles sans décomposition.

Sites de Test / Méthodes	Sans Décomposition				
	LSTM-NN	BiLSTM-NN	GRU-NN	BiGRU-NN	Class
Site #1					
RMSE	1.45	0.39	1.40	0.43	0.30
MAPE	21.77	5.93	20.98	6.92	4.29
MABE	0.05	0.11	0.09	0.27	0.21
R ²	0.69	0.97	0.71	0.98	0.98
Site #2					
RMSE	1.50	0.83	1.48	0.64	0.53
MAPE	26.25	14.69	26.05	12.08	8.72
MABE	0.009	0.12	0.031	0.175	0.36
R ²	0.71	0.91	0.71	0.95	0.96

TABLE 5.9 – Entropie d'échantillon des différentes composantes IMF pour les deux sites.

Site	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8	IMF9	IMF10	IMF11
Site #1	1.63	1.73	0.95	0.61	0.25	0.11	0.05	0.02	0.01	0.007	0.001
Site #2	1.50	1.64	1.07	0.53	0.24	0.11	0.04	0.01	0.009	0.004	0.001

TABLE 5.10 – Détails des métriques d'évaluation des performances des modèles avec décomposition.

Sites de Test / Méthodes	Décomposition avec ICEEMDAN				
	LSTM-NN	BiLSTM-NN	GRU-NN	BiGRU-NN	Class
Site #1					
RMSE	1.44	0.33	1.39	0.32	0.21
MAPE	21.92	5.00	20.97	5.00	3.08
MABE	0.08	0.08	0.08	0.08	0.15
R ²	0.69	0.98	0.71	0.98	0.99
Site #2					
RMSE	1.47	0.74	1.48	0.54	0.41
MAPE	25.67	13.22	25.63	10.22	6.83
MABE	0.019	0.026	0.027	0.246	0.289
R ²	0.712	0.927	0.718	0.968	0.979




FIGURE 5.24 – Une petite fenêtre des séries temporelles de la vitesse du vent provenant des deux sites de test après normalisation.

- **Pour le site #1** : cette méthode atteint un RMSE de 0,30 sans décomposition, valeur qui est réduite à 0,21 lorsqu'elle est associée à la méthode de décomposition ICEEMDAN.
- **Pour le site #2** : le RMSE diminue de 0,53 (sans décomposition) à 0,41 avec l'intégration d'ICEEMDAN.

Ces résultats mettent en évidence l'impact significatif de l'intégration des techniques de décomposition, notamment ICEEMDAN, dans l'amélioration des performances prédictives. Les modèles bidirectionnels tels que BiGRU et BiLSTM atteignent des valeurs de RMSE inférieures à celles des modèles unidirectionnels, mais sont néanmoins dépassés par la méthode « Class », particulièrement lorsqu'elle est combinée à ICEEMDAN.

Ces conclusions soulignent la capacité des approches combinées, renforcées par des techniques de décomposition avancées, à améliorer de manière significative la précision et la stabilité des prédictions, confirmant ainsi leur efficacité pour une prédiction fiable de la vitesse du vent sur les deux sites de test.

5.8.2.5 Comparaison avec les méthodes existantes dans la littérature

L'approche proposée est évaluée en comparaison avec plusieurs méthodes de pointe issues de la littérature, dans le but de démontrer son efficacité et sa supériorité. Le tableau 5.11 présente une comparaison détaillée entre la méthode proposée et certaines techniques existantes, en mettant en évidence des métriques clés de performance telles que le RMSE, le MAE, le MSE et le MAPE. Cette comparaison se concentre exclusivement sur des modèles d'apprentissage profond avancés.

Le tableau 5.11 compare les performances de prédiction de divers modèles selon différentes résolutions temporelles. Par exemple :




FIGURE 5.25 – Vitesse du vent mesurée et prédite du site de test — Site #1 — sans décomposition, utilisant les modèles d’apprentissage profond combinés.

- **SSA-CNNGRU-SVR** atteint un MAPE de 0,97 et un MAE de 1,72 à une résolution de 15 minutes.
- **SD-BiGRU** démontre des performances solides avec MAE = 0,1456 et RMSE = 0,1871 à une résolution de 10 minutes.

L’approche proposée *ICEEMDAN-SA-DL-Class* affiche des résultats compétitifs :

- **Pour le Site 1 (résolution de 30 minutes)** : RMSE = 0,21, MAPE = 3,08 et MABE = 0,15.
- **Pour le Site 2 (résolution de 15 minutes)** : RMSE = 0,41, MAPE = 6,83 et MABE = 0,289.

Ces résultats soulignent l’efficacité de la méthode proposée pour atteindre une haute précision de prédiction sur différentes échelles temporelles.




FIGURE 5.26 – Vitesse du vent mesurée et prédite du site de test — Site #2 — sans décomposition, utilisant les modèles d’apprentissage profond combinés.




FIGURE 5.27 – Formes d’onde des composantes ICEEMDAN de la série temporelle de la vitesse du vent du site de test — Site #1.

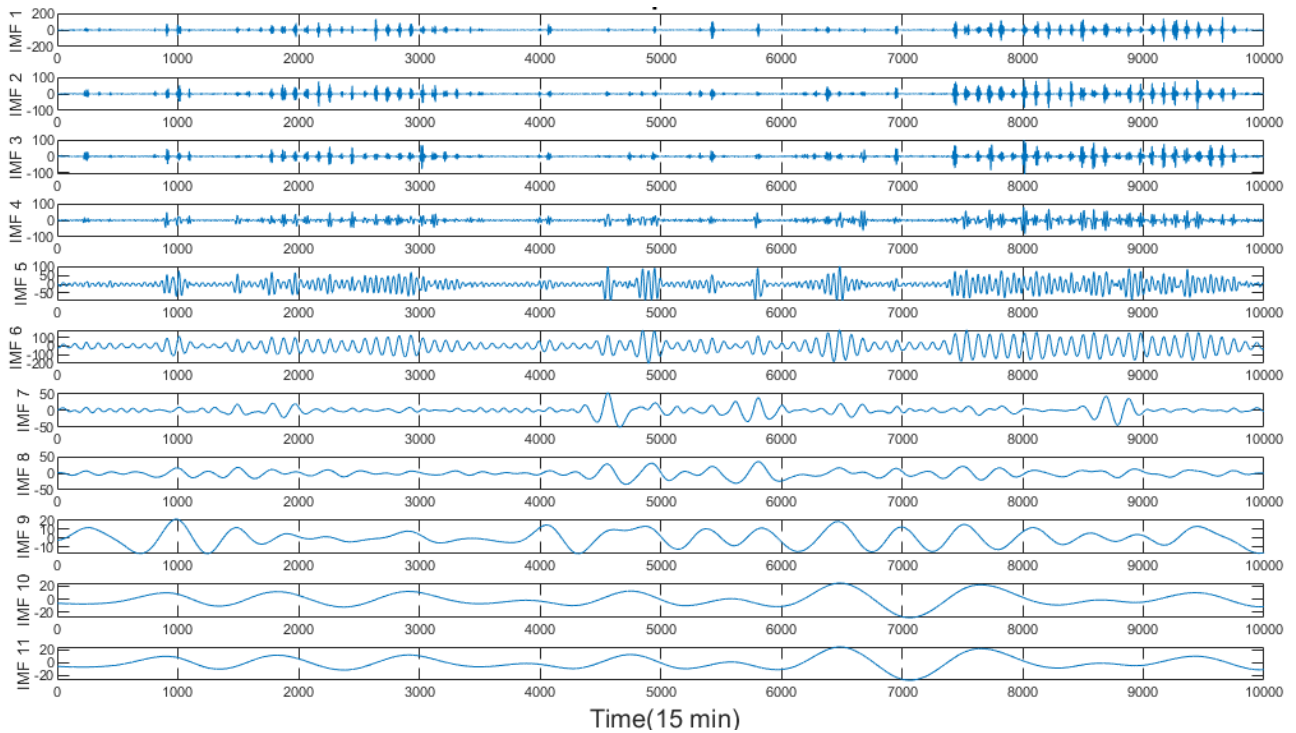


FIGURE 5.28 – Formes d’onde des composantes ICEEMDAN de la série temporelle de la vitesse du vent du site de test — Site #2.




FIGURE 5.29 – Vitesse du vent mesurée et prédite du site de test — Site #1 — avec décomposition, utilisant les modèles d’apprentissage profond combinés selon la méthode de classification (*Class*).




FIGURE 5.30 – Vitesse du vent mesurée et prédite du site de test — Site #2 — avec décomposition, utilisant les modèles d’apprentissage profond combinés selon la méthode de classification (*Class*).




FIGURE 5.31 – Histogramme des erreurs RMSE pour différentes approches pour le site de test — Site #1.




FIGURE 5.32 – Histogramme des erreurs RMSE pour différentes approches pour le site de test — Site #2.

TABLE 5.11 – Comparaison avec certaines méthodes existantes dans la littérature.

Référence	Résolution	Modèle	Performance de Prédiction
[182]	15 min	SSA-CNNGRU-SVR	MAPE = 0.97 MAE = 1.72
[183]	10 min	SD-BiGRU	MAE = 0.1456 MAPE = 4.78 RMSE = 0.1871
[184]	10 min	NESN-MP	MAE = 0.3 RMSE = 0.43 MSE = 0.19
[185]	1 h	SDAE-ELM	RMSE = 0.21 MAE = 0.28
[186]	1 h	WSTDGRU	RMSE = 0.3757
Notre approche	Site # 1 : 30 min	ICEEMDAN-SA-DL-Class	RMSE = 0.21 MAPE = 3.08 MABE = 0.15
	Site # 2 : 15 min	–	RMSE = 0.41 MAPE = 6.83 MABE = 0.289

5.9 Conclusion

La prédiction de la vitesse du vent constitue un enjeu stratégique pour l'intégration efficace de l'énergie éolienne dans les réseaux électriques. Ce chapitre a exploré un ensemble de techniques de décomposition avancées des séries temporelles, visant à surmonter la non-stationnarité intrinsèque des signaux de vent. Les techniques EMD, VMD et ICEEMDAN ont été examinées comme moyens de transformer les séries brutes en composantes intrinsèques plus simples (IMF), offrant une meilleure lisibilité des dynamiques sous-jacentes. Dans un second temps, une méthode de sélection fondée sur l'entropie d'échantillon a permis d'identifier les IMFs les plus informatives, en réduisant le bruit et la redondance. Ces composantes ont ensuite été utilisées pour alimenter différents modèles de prédiction, notamment des réseaux de neurones artificiels (RNA), ainsi que des modèles d'apprentissage profond plus performants tels que les LSTM, BiLSTM, GRU et BiGRU.

L'intégration de ces prédicteurs dans des cadres hybrides multi étapes a montré des résultats très prometteurs. En particulier, les stratégies de combinaison et de fusion des prédictions, notamment celles basées sur des scénarios de classification, ont permis de tirer parti de la complémentarité entre les modèles et d'améliorer significativement la précision de la prédiction. Les expérimentations, réalisées sur dix années de données mesurées dans sept régions d'Algérie aux climats variés, ont validé la robustesse et la généralisation des approches proposées.

Les résultats obtenus confirment que les modèles hybrides fondés sur la décomposition, la sélection par entropie et l'apprentissage profond surpassent largement les modèles individuels, aussi bien en termes de précision que de stabilité. Cette amélioration est particulièrement marquée lorsqu'une combinaison judicieuse des IMFs et des prédictions est mise en œuvre.

En conclusion, ce chapitre a mis en lumière le potentiel des approches hybrides à trois niveaux — décomposition, sélection et prédiction — pour construire des systèmes de prédiction de la vitesse du vent plus précis, plus stables et plus adaptatifs. Ces approches permettent non seulement de mieux représenter les caractéristiques dynamiques et multi-échelles des signaux de vent, mais aussi d'exploiter pleinement les capacités des modèles d'apprentissage avancés.

CHAPITRE 6

CONCLUSIONS GÉNÉRALES ET PERSPECTIVES

Sommaire du chapitre

6.1 Synthèse des travaux et portée scientifique	105
6.2 Contributions majeures de la thèse	106
6.3 Perspectives de recherche	106

6.1 Synthèse des travaux et portée scientifique

La présente thèse s'inscrit dans le contexte stratégique de la transition énergétique et de l'essor des énergies renouvelables, en particulier l'énergie éolienne. Son objectif principal est le développement de techniques avancées pour la prédiction précise de la vitesse du vent, en vue d'une intégration optimale de l'énergie éolienne aux réseaux électriques. Cette intégration passe par une meilleure compréhension du potentiel énergétique du vent, ainsi que par l'optimisation de son exploitation à des fins de planification, de gestion et de régulation du système électrique.

Dans cette optique, les travaux menés ont été centrés sur l'amélioration de la précision des prédictions, pour finalité de proposer des outils d'aide à la décision fiables pour évaluer la disponibilité, la rentabilité et les performances des ressources éoliennes. Ainsi, cette recherche contribue à renforcer la robustesse des systèmes de production et de gestion de l'énergie éolienne, tout en soutenant les objectifs de durabilité environnementale et d'indépendance énergétique.

L'étude a couvert un large éventail de techniques de prédiction, allant des modèles classiques fondés sur les séries temporelles aux approches modernes reposant sur l'intelligence artificielle et les combinaisons hybrides. Les résultats obtenus témoignent de l'efficacité des solutions proposées pour l'optimisation des systèmes éoliens et pour la réduction de l'incertitude inhérente à la nature intermittente du vent.

6.2 Contributions majeures de la thèse

Les contributions scientifiques et techniques apportées par cette thèse peuvent être résumées comme suit :

1. **Développement de modèles hybrides performants** : Des architectures prédictives innovantes ont été conçues, combinant des techniques d'apprentissage automatique, des méthodes de décomposition (telles que EMD, VMD, et ICEEMDAN), des algorithmes de réduction de dimensionnalité (comme PCA, KPCA et AE) et des réseaux de neurones profonds. Ces modèles surpassent les approches classiques en termes de précision et de robustesse.
2. **Optimisation de la gestion des parcs éoliens** : Les modèles développés permettent une meilleure anticipation des variations de la vitesse du vent, conduisant à une amélioration significative de la gestion opérationnelle des parcs éoliens, notamment en ce qui concerne la planification de la production et la maintenance préventive.
3. **Proposition de stratégies de prétraitement innovantes** : De nouvelles méthodologies de prétraitement des données ont été introduites, intégrant des techniques de nettoyage, de lissage et de transformation des séries temporelles, qui ont permis d'améliorer la qualité des données d'entrée et, par conséquent, les performances prédictives.
4. **Validation empirique sur des données réelles** : L'ensemble des modèles proposés ont été testés sur des jeux de données issues de sites réels, démontrant leur efficacité dans des conditions opérationnelles variées et confirmant leur potentiel de généralisation.

Ces contributions apportent une avancée significative dans le domaine de la prévision éolienne, en proposant des solutions concrètes pour améliorer l'efficacité énergétique, réduire les incertitudes liées à l'intermittence du vent, et faciliter l'intégration des énergies renouvelables dans les réseaux électriques intelligents.

6.3 Perspectives de recherche

Les travaux réalisés dans cette thèse ouvrent plusieurs pistes de recherche prometteuses, susceptibles d'enrichir davantage les connaissances dans le domaine et de prolonger les contributions apportées :

1. **Amélioration des modèles hybrides** : Une orientation future consistera à intégrer davantage de variables exogènes (humidité, pression, température à différentes altitudes, etc.) et à exploiter les capacités de réseaux neuronaux de dernière génération, tels que les architectures Transformers ou Graph Neural Networks (GNN).
2. **Développement de modèles multi-échelles** : Il serait pertinent de concevoir des systèmes prédictifs capables de fonctionner simultanément sur plusieurs horizons temporels (très court, court, moyen et long terme), afin de répondre aux besoins différenciés du pilotage en temps réel et de la planification stratégique.
3. **Couplage avec d'autres sources renouvelables** : L'intégration de la prévision de la vitesse du vent avec d'autres sources d'énergie renouvelable, telles que le solaire photovoltaïque, permettra d'optimiser la gestion conjointe des ressources dans des systèmes hybrides, renforçant la stabilité et la flexibilité du réseau.

4. **Exploitation de technologies avancées de mesure du vent** : L'intégration de dispositifs comme le LIDAR, le SODAR ou les mesures 3D de champ de vent pourrait améliorer considérablement la précision des estimations locales et enrichir les bases de données utilisées pour l'apprentissage des modèles.
5. **Généralisation des modèles à grande échelle** : Des validations à plus grande échelle, sur plusieurs parcs éoliens situés dans des zones géographiques diverses, sont nécessaires pour garantir la robustesse et l'universalité des modèles proposés.

En conclusion, cette thèse constitue une contribution substantielle à la recherche sur la prévision de la vitesse du vent. Elle propose des outils performants et adaptables aux exigences actuelles de gestion de l'énergie éolienne, tout en traçant des perspectives solides pour des avancées futures dans le cadre d'un système énergétique mondial plus intelligent, plus vert et plus résilient.

Articles de revue

- [J1] H. Mezaache, H. Bouzgou, C. Raymond, and N. Zemouri, "A Novel Approach for Accurate Wind Speed Time Series Forecasting Using ICEEMDAN Decomposition and Sample Entropy through Integration of Deep Learning Models," *International Journal of Engineering*, vol. 39, no. 2, pp. 309–320, 2026. DOI: [10.5829/ije.2026.39.02b.03](https://doi.org/10.5829/ije.2026.39.02b.03)

Conférences internationales

- [C1] H. Mezaache, H. Bouzgou, and C. Raymond, "Kernel principal components analysis with extreme learning machines for wind speed prediction," in *Proc. 7th Int. Renewable Energy Congress (IREC'16)*, Hammamet, Tunisia, pp. 1–5, Mar. 2016.
- [C2] H. Mezaache and H. Bouzgou, "Auto-encoder with neural networks for wind speed forecasting," in *Proc. Int. Conf. Communications and Electrical Engineering (ICCEE)*, El Oued, Algeria, pp. 1–5, Dec. 2018, IEEE. DOI: [10.1109/CCEE.2018.8634551](https://doi.org/10.1109/CCEE.2018.8634551)

BIBLIOGRAPHIE

- [1] T. Muneer, E. J. Gago, and S. E. Berrizbeitia, *The Coming of Age of Solar and Wind Power*. Springer Nature, 2022. doi : [10.1007/978-3-030-92010-4](https://doi.org/10.1007/978-3-030-92010-4). 1
- [2] M. R. Patel and O. Beik, *Wind and solar power systems : design, analysis, and operation*. CRC press, 2021. doi : [10.1201/9781003042952](https://doi.org/10.1201/9781003042952). 1
- [3] B. Stoevesandt, G. Schepers, P. Fuglsang, and Y. Sun, *Handbook of wind energy aerodynamics*. Springer Nature, 2022. doi : [10.1007/978-3-030-31307-4](https://doi.org/10.1007/978-3-030-31307-4). 1
- [4] M. Lydia, G. Edwin Prem Kumar, and R. Akash, “Wind speed and wind power forecasting models,” *Energy and Environment*, p. 0958305X241228515, 2024. doi : [10.1177/0958305X241228515](https://doi.org/10.1177/0958305X241228515). 2
- [5] J. Manwell, J. McGowan, and A. Rogers, *Wind Energy Explained : Theory, Design and Application*, 2nd ed. Wiley, 2009. doi : [10.1002/9781119994367](https://doi.org/10.1002/9781119994367). 2, 5, 7, 13
- [6] Wind My Roof, “Une histoire d'éolienne,” feb 2023, consulté le 08 mai 2025. [Online]. Available : <https://www.windmyroof.com/2023/02/01/histoire-eolienne/> 5
- [7] S. T. U. of Science and Technology, “Ancient machinery research center,” 2024, consulté le 07 mai 2025. [Online]. Available : <https://amc.stust.edu.tw/en/node/t015>
- [8] T. Burton, N. Jenkins, D. Sharpe, and E. Bossanyi, *Wind Energy Handbook*, 2nd ed. John Wiley and Sons, 2011. doi : [10.1002/9781119992714](https://doi.org/10.1002/9781119992714). 5
- [9] V. Quaschnig, *Understanding renewable energy systems*. Routledge, 2014. doi : [10.4324/9781315800493](https://doi.org/10.4324/9781315800493). 6, 7
- [10] M. A. El-Sharkawi, *Wind energy : an introduction*. CRC Press, 2015. doi : [10.1201/b18363](https://doi.org/10.1201/b18363). 7
- [11] E. Hau and H. Renouard, *Wind turbines : fundamentals, technologies, application, economics*. Springer, 2006, vol. 2. doi : [10.1007/978-3-642-27151-9](https://doi.org/10.1007/978-3-642-27151-9). 7
- [12] O. GUERRI, “L'Énergie Éolienne en algérie : Un bref aperçu,” *Bulletin des Énergies Renouvelables*, no. 21, pp. 25–32, 2011, consulté le 8 mai 2025. [Online]. Available : https://www.umc.edu.dz/images/ber37_6_7.pdf 9, 12
- [13] M. Z. Jacobson and M. A. Delucchi, “Providing all global energy with wind, water, and solar power, part i : Technologies, energy resources, quantities and areas of infrastructure, and materials,” *Energy Policy*, vol. 39, no. 3, pp. 1154–1169, 2011. doi : [10.1016/j.enpol.2010.11.040](https://doi.org/10.1016/j.enpol.2010.11.040). 9

- [14] W. W. E. Association, "Wwea annual report 2022," 2022, consulté le 08 mai 2025. [Online]. Available : <https://wwindea.org/wwea-annual-report-2022> 10
- [15] EurObserv'ER, "Baromètre éolien 2023," 2023, consulté le 08 mai 2025. [Online]. Available : <https://www.eurobserv-er.org/barometre-eolien-2023/> 10
- [16] I. E. Agency, "World energy outlook 2022 : Executive summary," PDF disponible sur le site officiel de l'Agence Internationale de l'Énergie, 2022, consulté le 8 mai 2025. [Online]. Available : <https://www.iea.org/reports/world-energy-outlook-2022> 10, 11
- [17] I. R. E. A. (IRENA), "Renewable energy capacity statistics 2022," PDF disponible sur le site officiel de l'IRENA, 2022, consulté le 8 mai 2025. [Online]. Available : https://www.spr.pe/wp-content/uploads/2022/04/IRENA_RE_Capacity_Statistics_2022.pdf 10, 11
- [18] A. E. E. (AEE), "Anuario 2022 : La voz del sector eólico," PDF disponible sur le site officiel de l'Association Espagnole de l'Énergie Éolienne (AEE), 2022, consulté le 8 mai 2025. [Online]. Available : <https://aeolica.org/wp-content/uploads/2022/07/AF-ANUARIO-AEE-2022-web.pdf> 10
- [19] C. Européenne, "Progrès réalisés en matière de compétitivité des énergies propres," Rapport de la Commission Européenne, COM(2022) 643 final, 2022, consulté le 8 mai 2025. [Online]. Available : <https://eur-lex.europa.eu/legal-content/FR/TXT/PDF/?uri=CELEX:52022DC0643> 10
- [20] GWEC, "Global Wind Energy Council, Global wind report 2022," *Wind energy technology*, 2022, consulté le 8 mai 2025. [Online]. Available : <https://www.gwec.net/reports/globalwindreport/2022> 10, 11, 18
- [21] Statista, "Projection de la capacité éolienne cumulée installée dans le monde," 2025, consulté le 8 mai 2025. [Online]. Available : <https://fr.statista.com/statistiques/549845/projection-capacite-eolienne-cumulee-installee-dans-le-monde/> 11
- [22] Statista, "Capacité de puissance éolienne selon le pays dans le monde," <https://fr.statista.com/statistiques/753591/capacite-puissance-eolienne-selon-le-pays-monde/>, 2025, consulté le 8 mai 2025. 11
- [23] N. K. Merzouk, "Evaluation du gisement énergétique éolien contribution à la détermination du profil vertical de la vitesse du vent en algérie," *PhD thèse. Université Abou Bekr Belkaid De Tlemcen*, 2006. [Online]. Available : <https://bucket.theses-algerie.com/files/repositories-dz/3088327294071962.pdf> 12
- [24] D. N. Hafida, "L'énergie éolienne en algérie : un potentiel considérable et un développement en croissance," *Bulletin des Énergies Renouvelables*, no. 46, pp. 7–9, 2018, consulté le 8 mai 2025. [Online]. Available : https://www.cder.dz/vlib/bulletin/pdf/ber46_07_09.pdf 12
- [25] A. Ministère de l'Énergie et des Mines, "Énergies nouvelles, renouvelables et maîtrise de l'énergie," 2025, consulté le 25 mai 2024. [Online]. Available : <https://www.energy.gov.dz/?rubrique=energies-nouvelles-renouvelables-et-maitrise-de-lrenergie> 13
- [26] Parlons sciences, "Météorologie : Le vent," 2022, consulté le 11 mai 2025. [Online]. Available : <https://parlonssciences.ca/ressources-pedagogiques/documents-dinformation/meteorologie-le-vent> 15
- [27] W. M. O. (WMO), *Guide to Meteorological Instruments and Methods of Observation*. WMO, 2018, consulté le 11 mai 2025. [Online]. Available : https://community.wmo.int/en/activity-areas/imop/wmo-no_8 18

- [28] F. Poitiers, "Etude et commande de génératrices asynchrones pour l'utilisation de l'énergie éolienne-machine asynchrone a cage autonome-machine asynchrone a double alimentation reliée au réseau," Ph.D. dissertation, Université de Nantes, 2003, thèse de doctorat, Université de Nantes. [Online]. Available : <https://theses.hal.science/tel-00011383v1> 18
- [29] F. Zeman, *Metropolitan Sustainability : Understanding and Improving the Urban Environment*, ser. Woodhead Publishing Series in Energy. Cambridge, UK : Woodhead Publishing / Elsevier, 2012, vol. 22. 24, 25
- [30] A. Beainy, C. Maatouk, N. Moubayed, and F. Kaddah, "Comparison of different types of generator for wind energy conversion system topologies," in *2016 3rd International Conference on Renewable Energies for Developing Countries (REDEC)*, 2016, pp. 1–6. doi : [10.1109/REDEC.2016.7577535](https://doi.org/10.1109/REDEC.2016.7577535) . 28, 29
- [31] M. L. FRIKH, "Contribution à l'étude d'un système de production d'énergie éolienne," Thèse de doctorat, Université Badji Mokhtar – Annaba, 2022. [Online]. Available : <https://biblio.univ-annaba.dz/wp-content/uploads/2023/06/These-Frikh-mohamed-lamine.pdf> 29
- [32] S. S. Soman, H. Zareipour, O. Malik, and P. Mandal, "A review of wind power and wind speed forecasting methods with different time horizons," in *North American power symposium 2010*. IEEE, 2010, pp. 1–8. doi : [10.1109/NAPS.2010.5619586](https://doi.org/10.1109/NAPS.2010.5619586) . 35, 47
- [33] H. Liu and C. Chen, "Data processing strategies in wind energy forecasting models and applications : A comprehensive review," *Applied Energy*, vol. 249, pp. 392–408, 2019. doi : [10.1016/j.apenergy.2019.04.188](https://doi.org/10.1016/j.apenergy.2019.04.188) . 35
- [34] G. Riahy and M. Abedi, "Short term wind speed forecasting for wind turbine applications using linear prediction method," *Renewable energy*, vol. 33, no. 1, pp. 35–41, 2008. doi : [10.1016/j.renene.2007.01.014](https://doi.org/10.1016/j.renene.2007.01.014) . 36
- [35] J. Zhang, J. Yan, D. Infield, Y. Liu, and F.-s. Lien, "Short-term forecasting and uncertainty analysis of wind turbine power based on long short-term memory network and gaussian mixture model," *Applied Energy*, vol. 241, pp. 229–244, 2019. doi : [10.1016/j.apenergy.2019.03.044](https://doi.org/10.1016/j.apenergy.2019.03.044) . 36
- [36] H. Wang, G. Wang, G. Li, J. Peng, and Y. Liu, "Deep belief network based deterministic and probabilistic wind speed forecasting approach," *Applied energy*, vol. 182, pp. 80–93, 2016. doi : [10.1016/j.apenergy.2016.08.108](https://doi.org/10.1016/j.apenergy.2016.08.108) . 37, 42
- [37] H. Liu, C. Chen, X. Lv, X. Wu, and M. Liu, "Deterministic wind energy forecasting : A review of intelligent predictors and auxiliary methods," *Energy Conversion and Management*, vol. 195, pp. 328–345, 2019. doi : [10.1016/j.enconman.2019.05.020](https://doi.org/10.1016/j.enconman.2019.05.020) . 37, 42
- [38] W.-Y. Chang *et al.*, "A literature review of wind forecasting methods," *Journal of Power and Energy Engineering*, vol. 2, no. 04, p. 161, 2014. doi : [10.4236/jpee.2014.24023](https://doi.org/10.4236/jpee.2014.24023) . 37, 38, 42, 47
- [39] E. Kalnay, *Atmospheric Modeling, Data Assimilation and Predictability*. Cambridge University Press, 2003. doi : [10.1017/CBO9780511802270](https://doi.org/10.1017/CBO9780511802270) . 37
- [40] W. C. Skamarock, J. B. Klemp, J. Dudhia, D. O. Gill, D. M. Barker, M. G. Duda, X.-Y. Huang, W.-C. Wang, and J. G. Powers, "A description of the advanced research wrf version 3," *NCAR Technical Note*, no. 475, 2008. doi : [10.5065/D68S4MVH](https://doi.org/10.5065/D68S4MVH) . 37

- [41] J. Jung and R. P. Broadwater, "Current status and future advances for wind speed and power forecasting," *Renewable and Sustainable Energy Reviews*, vol. 31, pp. 762–777, 2014. doi : [10.1016/j.rser.2013.12.054](https://doi.org/10.1016/j.rser.2013.12.054). 37, 38
- [42] A. Augustyn and J. Kamiński, "A review of methods applied for wind power generation forecasting," *Polityka Energetyczna*, vol. 21, no. 2, pp. 139–150, 2018. doi : [10.24425/122767](https://doi.org/10.24425/122767). 37, 38
- [43] G. E. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, *Time Series Analysis : Forecasting and Control*. John Wiley and Sons, 2015. doi : [10.1111/jtsa.12194](https://doi.org/10.1111/jtsa.12194). 38
- [44] Y. Wang, R. Zou, F. Liu, L. Zhang, and Q. Liu, "A review of wind speed and wind power forecasting with deep neural networks," *Applied energy*, vol. 304, p. 117766, 2021. doi : [10.1016/j.apenergy.2021.117766](https://doi.org/10.1016/j.apenergy.2021.117766). 38
- [45] L. Breiman, "Random forests," *Machine learning*, vol. 45, no. 1, pp. 5–32, 2001. doi : [10.1023/A:1010933404324](https://doi.org/10.1023/A:1010933404324). 38
- [46] V. N. Vapnik, *The Nature of Statistical learning theory*. Wiley, 1998. [Online]. Available : <https://link.springer.com/book/10.1007/978-1-4757-3264-1> 38
- [47] N. Mandal and T. Sarode, "Prediction of wind speed using machine learning," *International Journal of Computer Applications*, vol. 176, no. 32, pp. 34–37, 2020. doi : [10.5120/ijca2020920370](https://doi.org/10.5120/ijca2020920370). 38, 42
- [48] G. Drisya, K. Asokan, K. S. Kumar *et al.*, "Wind speed forecast using random forest learning method," *arXiv preprint arXiv :2203.14909*, 2022. doi : [10.48550/arXiv.2203.14909](https://doi.org/10.48550/arXiv.2203.14909). 38
- [49] M. A. Mohandes, S. Rehman, and T. O. Halawani, "A neural networks approach for wind speed prediction," *Renewable Energy*, vol. 13, no. 3, pp. 345–354, 1998. doi : [10.1016/S0960-1481\(98\)00001-9](https://doi.org/10.1016/S0960-1481(98)00001-9). 38
- [50] B. H. Mahdi, K. M. Yousif, and A. I. Melhum, "Application of artificial neural network to predict wind speed : Case study in duhok city, iraq," in *Journal of Physics : Conference Series*, vol. 1829, no. 1. IOP Publishing, 2021, p. 012002. doi : [10.1088/1742-6596/1829/1/012002](https://doi.org/10.1088/1742-6596/1829/1/012002). 38
- [51] Ümmühan Başaran Filik and T. Filik, "Wind speed prediction using artificial neural networks based on multiple local measurements in eskisehir," *Energy Procedia*, vol. 107, pp. 264–269, 2017. doi : [10.1016/j.egypro.2016.12.147](https://doi.org/10.1016/j.egypro.2016.12.147). 38
- [52] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural computation*, vol. 9, no. 8, pp. 1735–1780, 1997. doi : [10.1162/neco.1997.9.8.1735](https://doi.org/10.1162/neco.1997.9.8.1735). 38, 70
- [53] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998. doi : [10.1109/5.726791](https://doi.org/10.1109/5.726791). 38
- [54] P. Prabha, V. Vanitha, and R. Resmi, "Wind speed forecasting using long short term memory networks," in *2019 2nd international conference on intelligent computing, instrumentation and control technologies (ICICICT)*, vol. 1. IEEE, 2019, pp. 1310–1314. doi : [10.1109/ICICICT46008.2019.8993279](https://doi.org/10.1109/ICICICT46008.2019.8993279). 39
- [55] Z. Shen, X. Fan, L. Zhang, and H. Yu, "Wind speed prediction of unmanned sailboat based on cnn and lstm hybrid neural network," *Ocean Engineering*, vol. 254, p. 111352, 2022. doi : [10.1016/j.oceaneng.2022.111352](https://doi.org/10.1016/j.oceaneng.2022.111352). 39

- [56] L. P. Joseph, R. C. Deo, R. Prasad, S. Salcedo-Sanz, N. Raj, and J. Soar, "Near real-time wind speed forecast model with bidirectional lstm networks," *Renewable Energy*, vol. 204, pp. 39–58, 2023. doi : [10.1016/j.renene.2022.12.123](https://doi.org/10.1016/j.renene.2022.12.123) . 39
- [57] M. Schuster and K. K. Paliwal, "Bidirectional recurrent neural networks," *IEEE transactions on Signal Processing*, vol. 45, no. 11, pp. 2673–2681, 1997. doi : [10.1109/78.650093](https://doi.org/10.1109/78.650093) . 39, 72
- [58] K. Cho, B. Van Merriënboer, D. Bahdanau, and Y. Bengio, "Learning phrase representations using rnn encoder-decoder for statistical machine translation," in *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. Association for Computational Linguistics, 2014, pp. 1724–1734. doi : [10.48550/arXiv.1406.1078](https://doi.org/10.48550/arXiv.1406.1078) . 39
- [59] K. U. Jaseena and B. C. Koor, "Decomposition-based hybrid wind speed forecasting model using deep bidirectional lstm networks," *Energy Conversion and Management*, vol. 234, p. 113944, 2021. doi : [10.1016/j.enconman.2021.113944](https://doi.org/10.1016/j.enconman.2021.113944) . 39
- [60] D. Fantini, R. Silva, M. Siqueira, M. Pinto, M. Guimarães, and A. B. Junior, "Wind speed short-term prediction using recurrent neural network gru model and stationary wavelet transform gru hybrid model," *Energy Conversion and Management*, vol. 308, p. 118333, 2024. doi : [10.1016/j.enconman.2024.118333](https://doi.org/10.1016/j.enconman.2024.118333) . 39
- [61] C. Chen and H. Liu, "Dynamic ensemble wind speed prediction model based on hybrid deep reinforcement learning," *Advanced Engineering Informatics*, vol. 48, p. 101290, 2021. doi : [10.1016/j.aei.2021.101290](https://doi.org/10.1016/j.aei.2021.101290) . 39
- [62] A. Lawal, S. Rehman, L. M. Alhems, and M. M. Alam, "Wind speed prediction using hybrid 1d cnn and blstm network," *IEEE Access*, vol. 9, pp. 156 672–156 679, 2021. doi : [10.1109/ACCESS.2021.3129883](https://doi.org/10.1109/ACCESS.2021.3129883) . 39
- [63] D. E. Goldberg, *Genetic Algorithms in Search, Optimization, and Machine Learning*. Reading, MA, USA : Addison-Wesley, 1989. [Online]. Available : <https://dl.acm.org/doi/10.5555/534133> 39
- [64] J. Kennedy and R. Eberhart, "Particle swarm optimization," *Proceedings of the IEEE International Conference on Neural Networks*, vol. 4, pp. 1942–1948, 1995. doi : [10.1109/ICNN.1995.488968](https://doi.org/10.1109/ICNN.1995.488968) . 39
- [65] H. Liu, H.-q. Tian, C. Chen, and Y.-f. Li, "An experimental investigation of two wavelet-mlp hybrid frameworks for wind speed prediction using ga and pso optimization," *International Journal of Electrical Power and Energy Systems*, vol. 52, pp. 161–173, 2013. doi : [10.1016/j.ijepes.2013.03.034](https://doi.org/10.1016/j.ijepes.2013.03.034) . 39
- [66] D. Liu, D. Niu, H. Wang, and L. Fan, "Short-term wind speed forecasting using wavelet transform and support vector machines optimized by genetic algorithm," *Renewable energy*, vol. 62, pp. 592–597, 2014. doi : [10.1016/j.renene.2013.08.011](https://doi.org/10.1016/j.renene.2013.08.011) . 39
- [67] A. T. Dosdoğru and A. Boru İpek, "Hybrid boosting algorithms and artificial neural network for wind speed prediction," *International Journal of Hydrogen Energy*, vol. 47, no. 3, pp. 1449–1460, 2022. doi : [10.1016/j.ijhydene.2021.10.154](https://doi.org/10.1016/j.ijhydene.2021.10.154) . 39
- [68] M. Zontul, F. Aydın, G. Doğan, S. Şener, and O. Kaynar, "Wind speed forecasting using reptree and bagging methods in kirkklareli-turkey," *Scientific Research and Essays*, 2013. [Online]. Available : <https://www.jatit.org/volumes/Vol56No1/3Vol56No1.pdf> 39

- [69] L. Zhang, J. Wang, and X. Niu, "Wind speed prediction system based on data pre-processing strategy and multi-objective dragonfly optimization algorithm." pp. 101–346, 2021. doi : [10.1016/j.seta.2021.101346](https://doi.org/10.1016/j.seta.2021.101346). 39, 40
- [70] A. Ahmad, X. Xiao, H. Mo, and D. Dong, "Tuning data preprocessing techniques for improved wind speed prediction," *Energy Reports*, vol. 11, pp. 287–303, 2024. doi : [10.1016/j.egyr.2023.11.056](https://doi.org/10.1016/j.egyr.2023.11.056). 39, 40
- [71] R. Mei, Z. Lv, Y. Tang, W. Gu, J. Feng, and J. Ji, "Short-term prediction of wind power based on principal component analysis and elman neural network," in *Sustainable Power and Energy Conference (iSPEC)*. IEEE, 2021, pp. 3669–3674. doi : [10.1109/iSPEC53008.2021.9735980](https://doi.org/10.1109/iSPEC53008.2021.9735980). 40
- [72] D. Geng, H. Zhang, and H. Wu, "Short-term wind speed prediction based on principal component analysis and lstm," *Applied sciences*, vol. 10, no. 13, p. 4416, 2020. doi : [10.3390/app10134416](https://doi.org/10.3390/app10134416). 40
- [73] L. Lian, "Short-term wind speed prediction based on dimension reduction and deep learning models," *Earth Science Informatics*, vol. 18, no. 3, pp. 1–23, 2025. doi : [10.1007/s12145-025-01992-w](https://doi.org/10.1007/s12145-025-01992-w). 40
- [74] D. Liu, J. Wang, and H. Wang, "Short-term wind speed forecasting based on spectral clustering and optimised echo state networks," *Renewable Energy*, vol. 78, pp. 599–608, 2015. doi : [10.1016/j.renene.2015.01.022](https://doi.org/10.1016/j.renene.2015.01.022). 40
- [75] W. Dong, H. Sun, Z. Li, J. Zhang, and H. Yang, "Short-term wind-speed forecasting based on multiscale mathematical morphological decomposition, k-means clustering and stacked denoising autoencoders," *Ieee Access*, vol. 8, pp. 146 901–146 914, 2020. doi : [10.1109/ACCESS.2020.3015336](https://doi.org/10.1109/ACCESS.2020.3015336). 40
- [76] M. R. Babu, A. Q. H. Badar, and S. Balasubramani, "Fuzzy-c means clustering based anfis wind speed forecast," in *2020 21st National Power Systems Conference (NPSC)*, 2020, pp. 1–6. doi : [10.1109/NPSC49263.2020.9331828](https://doi.org/10.1109/NPSC49263.2020.9331828). 40
- [77] N. Sharma and R. Deo, "Chapter 14 - wind speed forecasting in nepal using self-organizing map-based online sequential extreme learning machine," in *Predictive Modelling for Energy Management and Power Systems Engineering*, R. Deo, P. Samui, and S. S. Roy, Eds. Elsevier, 2021, pp. 437–484. doi : [10.1016/B978-0-12-817772-3.00014-8](https://doi.org/10.1016/B978-0-12-817772-3.00014-8). 40
- [78] J. C. Palomares-Salas, A. Agüera-Pérez, J. J. G. de la Rosa, J. M. Sierra-Fernández, and A. Moreno-Munoz, "Exogenous measurements from basic meteorological stations for wind speed forecasting," *Energies*, vol. 6, no. 11, pp. 5807–5825, 2013. doi : [10.3390/en6115807](https://doi.org/10.3390/en6115807). 40
- [79] V. Perumpalot, G. Drisya, and K. S. Kumar, "Cross-location wind speed forecasting for wind energy applications using machine learning based models," *arXiv preprint arXiv :1808.03480*, 2018. doi : [10.48550/arXiv.1808.03480](https://doi.org/10.48550/arXiv.1808.03480). 40
- [80] N. Huang, E. Xing, G. Cai, Z. Yu, B. Qi, and L. Lin, "Short-term wind speed forecasting based on low redundancy feature selection," *Energies*, vol. 11, no. 7, p. 1638, 2018. doi : [10.3390/en11071638](https://doi.org/10.3390/en11071638). 40
- [81] C. Skittides and W.-G. Früh, "Wind forecasting using principal component analysis," *Renewable Energy*, vol. 69, pp. 365–374, 2014. doi : [10.1016/j.renene.2014.03.068](https://doi.org/10.1016/j.renene.2014.03.068). 40
- [82] Z. Zhang, A. Deng, Z. Wang, J. Li, H. Zhao, and X. Yang, "Wind power prediction based on emd-kpca-bilstm-att model," *Energies*, vol. 17, no. 11, p. 2568, 2024. doi : [10.3390/en17112568](https://doi.org/10.3390/en17112568). 40

- [83] A. Barjasteh, S. H. Ghafouri, and M. Hashemi, "A hybrid model based on discrete wavelet transform (dwt) and bidirectional recurrent neural networks for wind speed prediction," *Engineering Applications of Artificial Intelligence*, vol. 127, p. 107340, 2024. doi : [10.1016/j.engappai.2023.107340](https://doi.org/10.1016/j.engappai.2023.107340) . 41
- [84] R. Ye, Z. Guo, R. Liu, and J. Liu, "Short-term wind speed forecasting method based on wavelet packet decomposition and improved elman neural network," in *2016 International Conference on Probabilistic Methods Applied to Power Systems (PMAPS)*, 2016, pp. 1–6. doi : [10.1109/PMAPS.2016.7764077](https://doi.org/10.1109/PMAPS.2016.7764077) . 41
- [85] S. Pei, H. Qin, Z. Zhang, L. Yao, Y. Wang, C. Wang, Y. Liu, Z. Jiang, J. Zhou, and T. Yi, "Wind speed prediction method based on empirical wavelet transform and new cell update long short-term memory network," *Energy Conversion and Management*, vol. 196, pp. 779–792, 2019. doi : [10.1016/j.enconman.2019.06.041](https://doi.org/10.1016/j.enconman.2019.06.041) . 41
- [86] J. Wang, W. Zhang, Y. Li, J. Wang, and Z. Dang, "Forecasting wind speed using empirical mode decomposition and elman neural network," *Applied soft computing*, vol. 23, pp. 452–459, 2014. doi : [10.1016/j.asoc.2014.06.027](https://doi.org/10.1016/j.asoc.2014.06.027) . 41, 63
- [87] S. Wang, N. Zhang, L. Wu, and Y. Wang, "Wind speed forecasting based on the hybrid ensemble empirical mode decomposition and ga-bp neural network method," *Renewable Energy*, vol. 94, pp. 629–636, 2016. doi : [10.1016/j.renene.2016.03.103](https://doi.org/10.1016/j.renene.2016.03.103) . 41
- [88] H. Liu, H. Tian, X. Liang, and Y. Li, "New wind speed forecasting approaches using fast ensemble empirical model decomposition, genetic algorithm, mind evolutionary algorithm and artificial neural networks," *Renewable Energy*, vol. 83, pp. 1066–1075, 2015. doi : [10.1016/j.renene.2015.06.004](https://doi.org/10.1016/j.renene.2015.06.004) . 41
- [89] Y. Ding, Z. Chen, H. Zhang, X. Wang, and Y. Guo, "A short-term wind power prediction model based on ceemd and woa-kelm," *Renewable Energy*, vol. 189, pp. 188–198, 2022. doi : [10.1016/j.renene.2022.02.108](https://doi.org/10.1016/j.renene.2022.02.108) . 41
- [90] I. Karijadi, S.-Y. Chou, and A. Dewabharata, "Wind power forecasting based on hybrid ceemdan-ewt deep learning method," *Renewable Energy*, vol. 218, p. 119357, 2023. doi : [10.1016/j.renene.2023.119357](https://doi.org/10.1016/j.renene.2023.119357) . 41
- [91] B. S. Bommidi, V. Kosana, K. Teeparthi, and S. Madasthu, "A hybrid approach to ultra short-term wind speed prediction using ceemdan and informer," in *2022 22nd National Power Systems Conference (NPSC)*, 2022, pp. 207–212. doi : [10.1109/NPSC57038.2022.10069064](https://doi.org/10.1109/NPSC57038.2022.10069064) . 41
- [92] K. Dragomiretskiy and D. Zosso, "Variational mode decomposition," *IEEE Transactions on Signal Processing*, vol. 62, no. 3, pp. 531–544, 2014. doi : [10.1109/TSP.2013.2288675](https://doi.org/10.1109/TSP.2013.2288675) . 41
- [93] H. Hu, L. Wang, and R. Tao, "Wind speed forecasting based on variational mode decomposition and improved echo state network," *Renewable Energy*, vol. 164, pp. 729–751, 2021. doi : [10.1016/j.renene.2020.09.109](https://doi.org/10.1016/j.renene.2020.09.109) . 41
- [94] Y. Wang, J. Liu, D. Wang *et al.*, "Noise reduction method for mine wind speed sensor data based on ceemdan-wavelet threshold," *Scientific Reports*, vol. 14, p. 24869, 2024. doi : [10.1038/s41598-024-75288-2](https://doi.org/10.1038/s41598-024-75288-2) . 41
- [95] X. Mi and S. Zhao, "Wind speed prediction based on singular spectrum analysis and neural network structural learning," *Energy Conversion and Management*, vol. 216, p. 112956, 2020. doi : [10.1016/j.enconman.2020.112956](https://doi.org/10.1016/j.enconman.2020.112956) . 41

- [96] Q. Lin, J. Wang, and W. Qiao, "Denoising of wind speed data by wavelet thresholding," in *2013 Chinese Automation Congress*, 2013, pp. 518–521. doi : [10.1109/CAC.2013.6775789](https://doi.org/10.1109/CAC.2013.6775789) . 41
- [97] F. A. Nahid, W. Ongsakul, and N. M. Manjiparambil, "Very short term wind speed forecasting using convolutional long short term memory recurrent neural network," in *2020 international conference and utility exhibition on energy, environment and climate change (ICUE)*. IEEE, 2020, pp. 1–8. doi : [10.1109/ICUE49301.2020.9307061](https://doi.org/10.1109/ICUE49301.2020.9307061) . 42
- [98] A. S. Mogos, M. Salauddin, X. Liang, and C. Y. Chung, "Very short-term wind speed prediction techniques using machine learning," in *2021 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE)*. IEEE, 2021, pp. 1–6. doi : [10.1109/CCECE53047.2021.9569134](https://doi.org/10.1109/CCECE53047.2021.9569134) . 42
- [99] Z. Liu, P. Jiang, L. Zhang, and X. Niu, "A combined forecasting model for time series : Application to short-term wind speed forecasting," *Applied Energy*, vol. 259, p. 114137, 2020. doi : [10.1016/j.apenergy.2019.114137](https://doi.org/10.1016/j.apenergy.2019.114137) . 42
- [100] C. Zhang, H. Wei, J. Zhao, T. Liu, T. Zhu, and K. Zhang, "Short-term wind speed forecasting using empirical mode decomposition and feature selection," *Renewable Energy*, vol. 96, pp. 727–737, 2016. doi : [10.1016/j.renene.2016.05.023](https://doi.org/10.1016/j.renene.2016.05.023) . 42
- [101] Z. Jiang, J. Che, and L. Wang, "Ultra-short-term wind speed forecasting based on emd-var model and spatial correlation," *Energy Conversion and Management*, vol. 250, p. 114919, 2021. doi : [10.1016/j.enconman.2021.114919](https://doi.org/10.1016/j.enconman.2021.114919) . 42
- [102] Y. Zhang, G. Pan, B. Chen, J. Han, Y. Zhao, and C. Zhang, "Short-term wind speed prediction model based on ga-ann improved by vmd," *Renewable energy*, vol. 156, pp. 1373–1388, 2020. doi : [10.1016/j.renene.2019.12.047](https://doi.org/10.1016/j.renene.2019.12.047) . 43
- [103] J. Song, J. Wang, and H. Lu, "A novel combined model based on advanced optimization algorithm for short-term wind speed forecasting," *Applied energy*, vol. 215, pp. 643–658, 2018. doi : [10.1016/j.apenergy.2018.02.070](https://doi.org/10.1016/j.apenergy.2018.02.070) . 43
- [104] R. G. da Silva, S. R. Moreno, M. H. D. M. Ribeiro, J. H. K. Larcher, V. C. Mariani, and L. dos Santos Coelho, "Multi-step short-term wind speed forecasting based on multi-stage decomposition coupled with stacking-ensemble learning approach," *International Journal of Electrical Power and Energy Systems*, vol. 143, p. 108504, 2022. doi : [10.1016/j.ijepes.2022.108504](https://doi.org/10.1016/j.ijepes.2022.108504) . 43
- [105] M. Liu, Z. Cao, J. Zhang, L. Wang, C. Huang, and X. Luo, "Short-term wind speed forecasting based on the jaya-svm model," *International Journal of Electrical Power and Energy Systems*, vol. 121, p. 106056, 2020. doi : [10.1016/j.ijepes.2020.106056](https://doi.org/10.1016/j.ijepes.2020.106056) . 43
- [106] Y. Cai and Y. Li, "Short-term wind speed forecast based on dynamic spatio-temporal directed graph attention network," *Applied Energy*, vol. 375, p. 124124, 2024. doi : [10.1016/j.apenergy.2024.124124](https://doi.org/10.1016/j.apenergy.2024.124124) . 43
- [107] R. G. Kavasseri and K. Seetharaman, "Day-ahead wind speed forecasting using f-arima models," *Renewable energy*, vol. 34, no. 5, pp. 1388–1393, 2009. doi : [10.1016/j.renene.2008.09.006](https://doi.org/10.1016/j.renene.2008.09.006) . 43
- [108] L. Dejun, L. Hui, and M. Zhonghua, "One hour ahead prediction of wind speed based on data mining," in *2010 2nd International Conference on Advanced Computer Control*, vol. 5. IEEE, 2010, pp. 199–203. doi : [10.1109/ICACC.2010.5487258](https://doi.org/10.1109/ICACC.2010.5487258) . 43
- [109] Z. Zhang, H. Dai, D. Jiang, Y. Yu, and R. Tian, "Multi-step ahead forecasting of wind vector for multiple wind turbines based on new deep learning model," *Energy*, vol. 304, p. 131964, 2024. doi : [10.1016/j.energy.2024.131964](https://doi.org/10.1016/j.energy.2024.131964) . 44

- [110] C. Shu, B. Qin, and X. Wang, "Wind speed prediction based on improved vmd-bp-cnn-lstm model," *Journal of Power and Energy Engineering*, vol. 12, no. 1, pp. 29–43, 2024. doi : [10.4236/jpee.2024.121003](https://doi.org/10.4236/jpee.2024.121003) . 44
- [111] H. Cai, X. Jia, J. Feng, Q. Yang, Y.-M. Hsu, Y. Chen, and J. Lee, "A combined filtering strategy for short term and long term wind speed prediction with improved accuracy," *Renewable energy*, vol. 136, pp. 1082–1090, 2019. doi : [10.1016/j.renene.2018.09.080](https://doi.org/10.1016/j.renene.2018.09.080) . 44
- [112] H. Malik, V. Padmanabhan, and R. Sharma, "Pso-nn-based hybrid model for long-term wind speed prediction : a study on 67 cities of india," in *Applications of Artificial Intelligence Techniques in Engineering : SIGMA 2018, Volume 2*. Springer, 2019, pp. 319–327. doi : [10.1007/978-981-13-1822-1_29](https://doi.org/10.1007/978-981-13-1822-1_29) . 44
- [113] H. Malik *et al.*, "Application of artificial neural network for long term wind speed prediction," in *2016 Conference on Advances in Signal Processing (CASP)*. IEEE, 2016, pp. 217–222. doi : [10.1109/CASP.2016.7746168](https://doi.org/10.1109/CASP.2016.7746168) . 44
- [114] M. Paula, C. Marilaine, F. J. Nuno, and C. Wallace, "Predicting long-term wind speed in wind farms of northeast brazil : A comparative analysis through machine learning models," *IEEE Latin America Transactions*, vol. 18, no. 11, pp. 2011–2018, 2021. doi : [10.1109/TLA.2020.9398643](https://doi.org/10.1109/TLA.2020.9398643) . 44
- [115] M. Madhiarasan, "Long-term wind speed prediction using artificial neural network-based approaches," *AIMS Geosciences*, vol. 7, no. 4, pp. 542–552, 2021. doi : [10.3934/geosci.2021031](https://doi.org/10.3934/geosci.2021031) . 44
- [116] D. Zejli and R. Benchrifa, "L'énergie éolienne : de la source d'énergie renouvelable la moins prometteuse à la plus convoitée," *Revue des Energies Renouvelables, SMEE'10*, pp. 359–368, 2010. [Online]. Available : https://www.cder.dz/download/smee2010_37.pdf 46, 55
- [117] H. Bouzougou, "A fast and accurate model for forecasting wind speed and solar radiation time series based on extreme learning machines and principal components analysis," *Journal of Renewable and Sustainable Energy*, vol. 6, no. 1, 2014. doi : [10.1063/1.4862488](https://doi.org/10.1063/1.4862488) . 46, 52
- [118] M. Ahlstrom and R. Zavadil, "The role of wind forecasting in grid operations and reliability," in *Proc. Reliability, Transmission and Distribution Conference and Exhibition : Asia and Pacific. Dalian, China, 2005*. doi : [10.1109/TDC.2005.1547203](https://doi.org/10.1109/TDC.2005.1547203) . 46
- [119] X. Wang, P. Guo, and 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](https://doi.org/10.1016/j.egypro.2011.10.103) . 47
- [120] Z. Wei and W. Weimin, "Wind speed forecasting via ensemble kalman filter," in *2010 2nd International Conference on Advanced Computer Control*, vol. 2. IEEE, 2010, pp. 73–77. doi : [10.1109/ICACC.2010.5487187](https://doi.org/10.1109/ICACC.2010.5487187) . 47
- [121] H. Bouzougou and N. Benoudjit, "Multiple architecture system for wind speed prediction," *Applied Energy*, vol. 88, no. 7, pp. 2463–2471, 2011. doi : [10.1016/j.apenergy.2011.01.037](https://doi.org/10.1016/j.apenergy.2011.01.037) . 47, 63, 78, 79
- [122] A. Kusiak, H. Zheng, and Z. Song, "Short-term prediction of wind farm power : a data mining approach," *IEEE Transactions on energy conversion*, vol. 24, no. 1, pp. 125–136, 2009. doi : [10.1109/TEC.2008.2006552](https://doi.org/10.1109/TEC.2008.2006552) . 47
- [123] Q. Hu, R. Zhang, and Y. Zhou, "Transfer learning for short-term wind speed prediction with deep neural networks," *Renewable Energy*, vol. 85, pp. 83–95, 2016. doi : [10.1016/j.renene.2015.06.034](https://doi.org/10.1016/j.renene.2015.06.034) . 47

- [124] K. Pearson, "On lines and planes of closest fit to systems of points in space," *Philosophical Magazine*, vol. 2, no. 11, pp. 559–572, 1901. doi : [10.1080/14786440109462720.47,48](https://doi.org/10.1080/14786440109462720.47,48)
- [125] B. Schölkopf, A. Smola, and K.-R. Müller, "Nonlinear component analysis as a kernel eigenvalue problem," *Neural computation*, vol. 10, no. 5, pp. 1299–1319, 1998. doi : [10.1162/089976698300017467](https://doi.org/10.1162/089976698300017467). 47, 49
- [126] J.-M. Lee, C. Yoo, S. W. Choi, P. A. Vanrolleghem, and I.-B. Lee, "Nonlinear process monitoring using kernel principal component analysis," *Chemical engineering science*, vol. 59, no. 1, pp. 223–234, 2004. doi : [10.1016/j.ces.2003.09.012](https://doi.org/10.1016/j.ces.2003.09.012). 49
- [127] M. Fauvel, J. Chanussot, and J. A. Benediktsson, "Kernel principal component analysis for feature reduction in hyperspectral images analysis," in *Proceedings of the 7th Nordic Signal Processing Symposium-NORSIG 2006*. IEEE, 2006, pp. 238–241. doi : [10.1109/NORSIG.2006.275232](https://doi.org/10.1109/NORSIG.2006.275232). 49
- [128] G. E. Hinton and R. R. Salakhutdinov, "Reducing the dimensionality of data with neural networks," *science*, vol. 313, no. 5786, pp. 504–507, 2006. doi : [10.1126/science.1127647](https://doi.org/10.1126/science.1127647). 50
- [129] S. Haykin, *Neural Networks and Learning Machines*, 3rd ed. Upper Saddle River, NJ, USA : Prentice Hall, 2009. [Online]. Available : <https://dai.fmph.uniba.sk/courses/NN/haykin.neural-networks.3ed.2009.pdf> 52, 69
- [130] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine : Theory and applications," *Neurocomputing*, vol. 70, no. 1-3, pp. 489–501, 2006. doi : [10.1016/j.neucom.2005.12.126](https://doi.org/10.1016/j.neucom.2005.12.126). 52
- [131] J. L. Elman, "Finding structure in time," *Cognitive Science*, vol. 14, no. 2, pp. 179–211, 1990. doi : [10.1016/0364-0213\(90\)90002-E](https://doi.org/10.1016/0364-0213(90)90002-E). 52, 54
- [132] H. Mezaache, H. Bouzgou, and C. Raymond, "Kernel principal components analysis with extreme learning machines for wind speed prediction," in *Seventh International Renewable Energy Congress, IREC2016*, 2016. [Online]. Available : <https://inria.hal.science/hal-01394000v1/file/irec2016.pdf> 52
- [133] R. Penrose, "A generalized inverse for matrices," *Mathematical Proceedings of the Cambridge Philosophical Society*, vol. 51, no. 3, pp. 406–413, 1955. doi : [10.1017/S0305004100030401](https://doi.org/10.1017/S0305004100030401). 53
- [134] L. R. Medsker and L. C. Jain, "Recurrent neural networks : Design and applications," CRC Press, 1999. [Online]. Available : <https://dl.acm.org/doi/book/10.5555/55301154>
- [135] T. Koskela, M. Lehtokangas, J. P. Saarinen, and K. Kaski, "Time series prediction with multilayer perception, fir and elman neural networks," *semantic scholar*, 1996. [Online]. Available : <https://api.semanticscholar.org/CorpusID:60452714> 55
- [136] H. Bouzgou and C. A. Gueymard, "Fast short-term global solar irradiance forecasting with wrapper mutual information," *Renewable Energy*, vol. 133, pp. 1055–1065, 2019. doi : [10.1016/j.renene.2018.10.096](https://doi.org/10.1016/j.renene.2018.10.096). 55
- [137] B. Hassen and G. Christian A, "Minimum redundancy – maximum relevance with extreme learning machines for global solar radiation forecasting : Toward an optimized dimensionality reduction for solar time series," *Solar Energy*, vol. 158, pp. 595–609, 2017. doi : [10.1016/j.solener.2017.10.035](https://doi.org/10.1016/j.solener.2017.10.035). 55

- [138] H. Abdelnabi, A. Brown, T. Couture, A. Elguindy, B. Epp, N. Gibb, F. Joubert, N. Ledanois, R. Levin, H. Murdock *et al.*, “Renewables 2022 global status report,” 2022. [Online]. Available : https://www.ren21.net/wp-content/uploads/2019/05/GSR2022_Full_Report.pdf 63
- [139] A. McCrone, U. Moslener, F. d’Estais, C. Grüning, and M. Emmerich, “Global trends in renewable energy investment 2020,” 2020, consulter le : 16-05-2025. [Online]. Available : https://www.fs-unep-centre.org/wp-content/uploads/2020/06/GTR_2020.pdf 63
- [140] S. Heier, *Grid integration of wind energy : Onshore and Offshore conversion systems*. John Wiley and Sons, 2014. doi : [10.1002/9781118703274](https://doi.org/10.1002/9781118703274) . 63
- [141] S. R. Sinsel, R. L. Riemke, and V. H. Hoffmann, “Challenges and solution technologies for the integration of variable renewable energy sources—a review,” *renewable energy*, vol. 145, pp. 2271–2285, 2020. doi : [10.1016/j.renene.2019.06.147](https://doi.org/10.1016/j.renene.2019.06.147) . 63
- [142] W. P. Mahoney, K. Parks, G. Wiener, Y. Liu, W. L. Myers, J. Sun, L. Delle Monache, T. Hopson, D. Johnson, and S. E. Haupt, “A wind power forecasting system to optimize grid integration,” *IEEE Transactions on Sustainable Energy*, vol. 3, no. 4, pp. 670–682, 2012. doi : [10.1109/TSTE.2012.2201758](https://doi.org/10.1109/TSTE.2012.2201758) . 63
- [143] F. Cassola and 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](https://doi.org/10.1016/j.apenergy.2012.03.054) . 63
- [144] M. Santhosh, C. Venkaiah, and D. Vinod Kumar, “Current advances and approaches in wind speed and wind power forecasting for improved renewable energy integration : A review,” *Engineering Reports*, vol. 2, no. 6, p. e12178, 2020. doi : [10.1002/eng2.12178](https://doi.org/10.1002/eng2.12178) . 63
- [145] A. Ahmed and M. Khalid, “A review on the selected applications of forecasting models in renewable power systems,” *Renewable and Sustainable Energy Reviews*, vol. 100, pp. 9–21, 2019. doi : [10.1016/j.rser.2018.09.046](https://doi.org/10.1016/j.rser.2018.09.046) . 63
- [146] Z. Qu, W. Mao, K. Zhang, W. Zhang, and Z. Li, “Multi-step wind speed forecasting based on a hybrid decomposition technique and an improved back-propagation neural network,” *Renewable energy*, vol. 133, pp. 919–929, 2019. doi : [10.1016/j.renene.2018.10.043](https://doi.org/10.1016/j.renene.2018.10.043) . 63
- [147] C. Li, Z. Zhu, H. Yang, and R. Li, “An innovative hybrid system for wind speed forecasting based on fuzzy preprocessing scheme and multi-objective optimization,” *Energy*, vol. 174, pp. 1219–1237, 2019. doi : [10.1016/j.energy.2019.02.194](https://doi.org/10.1016/j.energy.2019.02.194) . 63
- [148] N. Bokde, A. Feijóo, D. Villanueva, and K. Kulat, “A review on hybrid empirical mode decomposition models for wind speed and wind power prediction,” *Energies*, vol. 12, no. 2, p. 254, 2019. doi : [10.3390/en12020254](https://doi.org/10.3390/en12020254) . 63
- [149] H. Liu, H.-q. Tian, D.-f. Pan, and Y.-f. Li, “Forecasting models for wind speed using wavelet, wavelet packet, time series and artificial neural networks,” *Applied Energy*, vol. 107, pp. 191–208, 2013. doi : [10.1016/j.apenergy.2013.02.002](https://doi.org/10.1016/j.apenergy.2013.02.002) . 63
- [150] S.-w. Fei and Y. He, “Wind speed prediction using the hybrid model of wavelet decomposition and artificial bee colony algorithm-based relevance vector machine,” *International Journal of Electrical Power and Energy Systems*, vol. 73, pp. 625–631, 2015. doi : [10.1016/j.ijepes.2015.04.019](https://doi.org/10.1016/j.ijepes.2015.04.019) . 63

- [151] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, N.-C. Yen, C. C. Tung, and H. H. Liu, "The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis," *Proceedings of the Royal Society of London. Series A : mathematical, physical and engineering sciences*, vol. 454, no. 1971, pp. 903–995, 1998. doi : [10.1098/rspa.1998.0193](https://doi.org/10.1098/rspa.1998.0193) . 63
- [152] N. Bokde, A. Feijóo, N. Al-Ansari, S. Tao, and Z. M. Yaseen, "The hybridization of ensemble empirical mode decomposition with forecasting models : Application of short-term wind speed and power modeling," *Energies*, vol. 13, no. 7, p. 1666, 2020. doi : [10.3390/en13071666](https://doi.org/10.3390/en13071666) . 63
- [153] N. E. Huang and N. O. Attoh-Okine, *The Hilbert-Huang transform in engineering*. CrC Press, 2005. doi : [10.1201/9781420027532](https://doi.org/10.1201/9781420027532) . 63
- [154] H. Liang, S. L. Bressler, R. Desimone, and P. Fries, "Empirical mode decomposition : a method for analyzing neural data," *Neurocomputing*, vol. 65, pp. 801–807, 2005. doi : [10.1016/j.neucom.2004.10.077](https://doi.org/10.1016/j.neucom.2004.10.077) . 63
- [155] K. Dragomiretskiy and D. Zosso, "Variational mode decomposition," *IEEE transactions on signal processing*, vol. 62, no. 3, pp. 531–544, 2013. doi : [10.1109/TSP.2013.2288675](https://doi.org/10.1109/TSP.2013.2288675) . 64
- [156] Y. Zhang and G. Pan, "A hybrid prediction model for forecasting wind energy resources," *Environmental science and pollution research*, vol. 27, pp. 19 428–19 446, 2020. doi : [10.1007/s11356-020-08452-6](https://doi.org/10.1007/s11356-020-08452-6) . 64, 65
- [157] S. Boyd, N. Parikh, E. Chu, B. Peleato, J. Eckstein *et al.*, "Distributed optimization and statistical learning via the alternating direction method of multipliers," *Foundations and Trends® in Machine learning*, vol. 3, no. 1, pp. 1–122, 2011. doi : [10.1561/22000000016](https://doi.org/10.1561/22000000016) . 65
- [158] M. A. Colominas, G. Schlotthauer, and M. E. Torres, "Improved complete ensemble emd : A suitable tool for biomedical signal processing," *Biomedical Signal Processing and Control*, vol. 14, pp. 19–29, 2014. doi : [10.1016/j.bspc.2014.06.009](https://doi.org/10.1016/j.bspc.2014.06.009) . 67
- [159] S. Ghimire, R. C. Deo, D. Casillas-Perez, and S. Salcedo-Sanz, "Improved complete ensemble empirical mode decomposition with adaptive noise deep residual model for short-term multi-step solar radiation prediction," *Renewable Energy*, vol. 190, pp. 408–424, 2022. doi : [10.1016/j.renene.2022.03.120](https://doi.org/10.1016/j.renene.2022.03.120) . 67
- [160] X. Xia and X. Wang, "A novel hybrid model for short-term wind speed forecasting based on twice decomposition, psr, and imvo-elm," *Complexity*, vol. 2022, no. 1, p. 4014048, 2022. doi : [10.1155/2022/4014048](https://doi.org/10.1155/2022/4014048) . 67
- [161] J. S. Richman and J. R. Moorman, "Physiological time-series analysis using approximate entropy and sample entropy," *American journal of physiology-heart and circulatory physiology*, vol. 278, no. 6, pp. H2039–H2049, 2000. doi : [10.1152/ajpheart.2000.278.6.H2039](https://doi.org/10.1152/ajpheart.2000.278.6.H2039) . 68
- [162] P. Yao, J. Xue, K. Zhou, and X. Wang, "Sample entropy-based approach to evaluate the stability of double-wire pulsed mig welding," *Mathematical Problems in Engineering*, vol. 2014, no. 1, p. 869631, 2014. doi : [10.1155/2014/869631](https://doi.org/10.1155/2014/869631) . 68
- [163] J. Che, Y. Ye, H. Wang, and W. Huang, "A sample entropy parsimonious model using decomposition-ensemble with ssa and ceemdan for short-term wind speed prediction." *Engineering Letters*, vol. 31, no. 1, 2023. 68

- [164] J. Park and I. W. Sandberg, "Universal approximation using radial-basis-function networks," *Neural computation*, vol. 3, no. 2, pp. 246–257, 1991. doi : [10.1162/neco.1991.3.2.246](https://doi.org/10.1162/neco.1991.3.2.246) . 70
- [165] F. A. Gers, J. Schmidhuber, and F. Cummins, "Learning to forget : Continual prediction with lstm," *Neural computation*, vol. 12, no. 10, pp. 2451–2471, 2000. doi : [10.1049/cp:19991218](https://doi.org/10.1049/cp:19991218) . 70
- [166] K. Qadeer, W. U. Rehman, A. M. Sheri, I. Park, H. K. Kim, and M. Jeon, "A long short-term memory (lstm) network for hourly estimation of pm2. 5 concentration in two cities of south korea," *Applied Sciences*, vol. 10, no. 11, p. 3984, 2020. doi : [10.3390/app10113984](https://doi.org/10.3390/app10113984) . 70
- [167] K. Wang, X. Qi, and H. Liu, "Photovoltaic power forecasting based lstm-convolutional network," *Energy*, vol. 189, p. 116225, 2019. doi : [10.1016/j.energy.2019.116225](https://doi.org/10.1016/j.energy.2019.116225) . 70
- [168] X. Ai, S. Li, and H. Xu, "Short-term wind speed forecasting based on two-stage preprocessing method, sparrow search algorithm and long short-term memory neural network," *Energy Reports*, vol. 8, pp. 14997–15010, 2022. doi : [10.1016/j.egyr.2022.11.051](https://doi.org/10.1016/j.egyr.2022.11.051) . 70
- [169] A. Sedai, R. Dhakal, S. Gautam, A. Dhamala, A. Bilbao, Q. Wang, A. Wigington, and S. Pol, "Performance analysis of statistical, machine learning and deep learning models in long-term forecasting of solar power production," *forecasting*, vol. 5, no. 1, pp. 256–284, 2023. doi : [10.3390/forecast5010014](https://doi.org/10.3390/forecast5010014) . 70
- [170] J. Li, Z. Song, X. Wang, Y. Wang, and Y. Jia, "A novel offshore wind farm typhoon wind speed prediction model based on pso–bi-lstm improved by vmd," *Energy*, vol. 251, p. 123848, 2022. doi : [10.1016/j.energy.2022.123848](https://doi.org/10.1016/j.energy.2022.123848) . 72
- [171] X. Liu, Z. Lin, and Z. Feng, "Short-term offshore wind speed forecast by seasonal arima-a comparison against gru and lstm," *Energy*, vol. 227, p. 120492, 2021. doi : [10.1016/j.energy.2021.120492](https://doi.org/10.1016/j.energy.2021.120492) . 73
- [172] G. Zhang and D. Liu, "Causal convolutional gated recurrent unit network with multiple decomposition methods for short-term wind speed forecasting," *Energy Conversion and Management*, vol. 226, p. 113500, 2020. doi : [10.1016/j.enconman.2020.113500](https://doi.org/10.1016/j.enconman.2020.113500) . 73
- [173] E. Haque, S. Tabassum, and E. Hossain, "A comparative analysis of deep neural networks for hourly temperature forecasting," *IEEE Access*, vol. 9, pp. 160646–160660, 2021. doi : [10.1109/ACCESS.2021.3131533](https://doi.org/10.1109/ACCESS.2021.3131533) . 73
- [174] I. Bibi, A. Akhunzada, J. Malik, J. Iqbal, A. Musaddiq, and S. Kim, "A dynamic dl-driven architecture to combat sophisticated android malware," *IEEE Access*, vol. 8, pp. 129600–129612, 2020. doi : [10.1109/ACCESS.2020.3009819](https://doi.org/10.1109/ACCESS.2020.3009819) . 75
- [175] Y. Zhang, L. Zhang, D. Sun, K. Jin, and Y. Gu, "Short-term wind power forecasting based on vmd and a hybrid ssa-tcn-bigru network," *Applied Sciences*, vol. 13, no. 17, p. 9888, 2023. doi : [10.3390/app13179888](https://doi.org/10.3390/app13179888) . 75
- [176] C. Tao, T. Tao, S. He, X. Bai, and Y. Liu, "Wind turbine blade icing diagnosis using b-smote-bi-gru and rfe combined with icing mechanism," *Renewable Energy*, vol. 221, p. 119741, 2024. doi : [10.1016/j.renene.2023.119741](https://doi.org/10.1016/j.renene.2023.119741) . 75
- [177] I. Fischer and N. Harvey, "Combining forecasts : What information do judges need to outperform the simple average?" *International journal of forecasting*, vol. 15, no. 3, pp. 227–246, 1999. doi : [10.1016/S0169-2070\(98\)00073-9](https://doi.org/10.1016/S0169-2070(98)00073-9) . 76

- [178] D. W. Bunn, "A bayesian approach to the linear combination of forecasts," *Operational Research Quarterly*, vol. 26, no. 2, pp. 325–329, 1975. doi : [10.2307/3008467](https://doi.org/10.2307/3008467) . 76
- [179] N. Zemouri, H. Bouzgou, and C. A. Gueymard, "Multimodel ensemble approach for hourly global solar irradiation forecasting," *The European Physical Journal Plus*, vol. 134, no. 12, p. 594, 2019. doi : [10.1140/epjp/i2019-12966-5](https://doi.org/10.1140/epjp/i2019-12966-5) . 78
- [180] L. Bruzzone and F. Melgani, "Robust multiple estimator systems for the analysis of biophysical parameters from remotely sensed data," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, no. 1, pp. 159–174, 2005. doi : [10.1109/TGRS.2004.839818](https://doi.org/10.1109/TGRS.2004.839818) . 78
- [181] K. E. Taylor, "Summarizing multiple aspects of model performance in a single diagram," *Journal of geophysical research : atmospheres*, vol. 106, no. D7, pp. 7183–7192, 2001. doi : [10.1029/2000JD900719](https://doi.org/10.1029/2000JD900719) . 88
- [182] H. Liu, X. Mi, Y. Li, Z. Duan, and Y. Xu, "Smart wind speed deep learning based multi-step forecasting model using singular spectrum analysis, convolutional gated recurrent unit network and support vector regression," *Renewable energy*, vol. 143, pp. 842–854, 2019. doi : [10.1016/j.renene.2019.05.039](https://doi.org/10.1016/j.renene.2019.05.039) . 103
- [183] L. Xiang, J. Li, A. Hu, and Y. Zhang, "Deterministic and probabilistic multi-step forecasting for short-term wind speed based on secondary decomposition and a deep learning method," *Energy Conversion and Management*, vol. 220, p. 113098, 2020. doi : [10.1016/j.enconman.2020.113098](https://doi.org/10.1016/j.enconman.2020.113098) . 103
- [184] M. A. Chitsazan, M. S. Fadali, and A. M. Trzynadlowski, "Wind speed and wind direction forecasting using echo state network with nonlinear functions," *Renewable energy*, vol. 131, pp. 879–889, 2019. doi : [10.1016/j.renene.2018.07.060](https://doi.org/10.1016/j.renene.2018.07.060) . 103
- [185] L. Chen, Z. Li, and Y. Zhang, "Multiperiod-ahead wind speed forecasting using deep neural architecture and ensemble learning," *Mathematical Problems in Engineering*, vol. 2019, no. 1, p. 9240317, 2019. doi : [10.1155/2019/9240317](https://doi.org/10.1155/2019/9240317) . 103
- [186] Z. Peng, S. Peng, L. Fu, B. Lu, J. Tang, K. Wang, and W. Li, "A novel deep learning ensemble model with data denoising for short-term wind speed forecasting," *Energy Conversion and Management*, vol. 207, p. 112524, 2020. doi : [10.1016/j.enconman.2020.112524](https://doi.org/10.1016/j.enconman.2020.112524) . 103