



Université de Ghardaïa

N° d'ordre :
N° de série :

Faculté des Sciences et Technologies
Département Automatique et électromécanique

Mémoire présenté en vue de l'obtention du diplôme de

Master

Domaine : *Sciences et Technologies*

Filière : *Energies Renouvelables*

Spécialité : *Energies renouvelables en électrotechnique*

Par : **SAITI Tamer et HAMZA Abdelaziz**

Thème

**Etude de Prévion de la Production Electrique
des Energies Renouvelables**

Soutenu publiquement le : 22/10/2020

Devant le jury :

BECHOUAT Mohcine	Univ. Ghardaïa	Président
BAHRI Ahmed	Univ. Ghardaïa	Examineur
AMIER Bachir	Univ. Ghardaïa	Examineur
HAMID OUDJANA Samir	Univ. Ghardaïa	Encadreur
MOSBAH Mustafa	Univ. Ghardaïa	Co-encadreur

Année universitaire : 2019/2020

REMERCIEMENTS

*Avant tout nous remercions **DIEU** qui a éclairé nos esprits et nous a protégé de l'ignorance.*

Nous exprimons notre gratitude à nos encadreurs Mrs : Dr HAMID OUDJANA Samir, Maitre de recherche au centre de développement des énergies renouvelables à GHARDAIA et Mrs MOSBAH Mustapha, membre de recherche à laboratoire LACoSERE à l'université de LAGHOUAT, pour tous les conseils qui nous ont prodigués tout au long de la préparation de ce mémoire.

Nous remercions les membres du jury d'avoir acceptés d'examiner notre travail.

Nos remerciements vont également à tous les enseignants qui ont contribué à notre formation.

En fin, Nous remercions tous ceux, qui de prés ou de loin, nous ont aidé pour mettre à jour ce modeste travail.

SAITI Tamer

HAMZA Abdelaziz

LISTE DES TABLEAUX

Tableau I.1 : Niveaux de tension aux points de raccordement en fonction de la puissance installée

Tableau II.1 Classification temporelle pour la prévision du vent.

Tableau II.2 Résumé des méthodes statistiques.

Tableau III.1 Modélisation d'un réseau de neurone biologique.

Tableau III.2 Fonctions de transfert $a = f(n)$.

Tableau IV.1: un échantillon de la base des données.

Tableau IV.2 Erreur de prévision par perceptron simple pour différentes périodes.

LISTE DES FIGURES

Figure I.1 : Photographie de deux moulins à vent

Figure I.2 : Schéma d'une turbine éolienne

Figure I.3 : Schéma de différents types d'éoliennes Darrieus

Figure I.4 : Schéma d'une éoliennes Savonius

Figure I.5 : Schéma d'une éolienne à axe verticale

Figure I.6 : Schéma des différentes composantes d'une éolienne à axe horizontale

Figure I.7 : Colonne d'air

Figure I.8 : Schéma du courant d'air traversant une turbine

Figure I.9 : Structure d'une éolienne à vitesse fixe

Figure I.10 : Structure d'une éolienne à base MADA

Figure I.11 : Structure d'une éolienne à base de MS à aimant permanents

Figure I.12 : Modèle d'un départ HTA « à grandeurs uniformément réparties »

Figure I.13 : Illustration des configurations de raccordement (a) en départ mixte (b) en départ direct

Figure II.1 Exemple de grille. Image libre de droits .

Figure II.2 Utilisation des méthodes statistiques

Figure II.3 Structure d'un réseau de neurones artificiels

Figure III.1 Modèle d'un neurone artificiel

Figure III.2 Le neurone biologique

Figure III.3 Représentation matricielle du modèle d'un neurone artificiel

Figure III.4 Perceptron simple ou réseau ADALINE

Figure III.5 Représentation matricielle d'un réseau de trois couches

Figure III.6 Mode d'apprentissage des réseaux de neurones (a) supervisé, (b) non supervisé

Figure III.7 Retro-propagation de l'erreur

Figure III.8 Réseau RBF avec fonctions radiales gaussiennes

Figure IV.1 Carte d'Algérie

Figure IV.2 Variation journalière de la vitesse moyenne du vent

Figure IV.3 Variation mensuelle de la vitesse moyenne du vent

Figure IV.1 Variation annuelle de la vitesse moyenne du vent

Figure IV.5 Situation du site de Kabertène

Figure IV.6 Corrélation entre la production et la température

Figure IV.7 Courbe de production en utilisant la température comme une variable indépendante

Figure IV.8 Corrélation entre la production et la vitesse de vent

Figure IV.9 Courbe de production en utilisant la vitesse de vent comme variable indépendante

Figure IV.10 Production réalisée par la régression multiple en introduisant la température et la vitesse du vent.

Figure IV.11 Prévision d'échantillons de 2566 heures

Figure IV.12 Prévision d'échantillons de 3066 heures

Figure IV.13 Prévision d'échantillons de 2160 heures

Acronymes

PPCT	Prévision de la production à courte terme.
PPE	Prévision de la production éolienne.
EMAP	Erreur relative moyenne absolue de la prévision.

Nomenclature

ρ	La densité de l'air
P_v	La puissance du vent
$C_{gén}$	Le couple de génératrice
$\Omega_{Turbine}$	La vitesse angulaire d'aérogénérateur
J	Moment d'inertie de turbine
T	Température
Hr	Heure de la journée
V	Vitesse du vent
b_0	Paramètre standard dépendant
b_1	Paramètre de pondération des variables indépendantes
r	Coefficient de corrélation
W	Poids synaptiques
F	Fonction d'activation
b	Le biais
\emptyset	Fonction d'activation de type gaussienne

SOMMAIRE

Remerciements	i
Liste des tableaux	ii
Liste des figures	iii
Acronymes	v
Nomenclature	vi
Sommaire	vii
Introduction générale	1
Chapitre I : Notions générales sur l'énergie éolienne	
I.1 .Introduction.....	3
I.2 Les différents types d'énergie renouvelable.....	3
I.3 Historique de l'éolien.....	4
I.4 Définition de l'énergie éolienne.....	5
I.5 . Principe du vent.....	6
I.6 . Principe de conversion.....	6
I.7 Les différents types des turbines éoliennes.....	6
I.7.1 . Eolienne à axe verticale.....	7
I.7.2 Eolienne à axe horizontale.....	9
I.7.3 Composantes d'une éolienne à axe horizontale	9
I.7.4 L'énergie éolienne en Algérie.....	10
I.8 Modélisation de la turbine éolienne.....	11
I.8.1 L'énergie récupérable par une turbine et limite de Betz.....	11
I.8.2 Limite de Betz.....	12
I.8.3 Modèle du multiplicateur.....	14

I.8.4 Equation dynamique de l'arbre.....	14
I.9 Les générateurs éoliens.....	15
I.9.1 Eolienne à vitesse fixe.....	15
I.9.2 Eolienne à vitesse variable.....	16
I.9.2.1 Eolienne à base de machine asynchrone à double alimentation (MADA).....	16
I.9.2.2 Eolienne à base de machine synchrone à aimants permanents.....	17
I.10 Raccordement d'énergie renouvelable dans le réseau de distribution.....	18
I.10.1 Technique de raccordement.....	18
I.10.2 Connexion au réseau.....	18
I.10.3 Tension de raccordement.....	19
I.10.4 La capacité d'accueil des réseaux.....	19
I.10.5 Types de raccordement.....	21
I.11 Les impacts de l'intégration d'un système éolien dans le réseau.....	21
I.11.1 Impacts locaux.....	22
I.11.2 Impacts globaux.....	23
I.12 Conclusion.....	25

Chapitre II : Prédiction de la production éolienne (PPE)

II.1 Introduction.....	26
II.2 Qu'est-ce qu'une prédiction ?.....	26
II.3 Ce qui caractérise un problème de prédiction.....	26
II.4 Différentes échelles de temps de prévisions.....	27
II.5 Les méthodes de prévisions.....	29
II.6 Critères de validité de la méthode de prédiction.....	29
II.7 Les modèles de prédiction de l'énergie éolienne.....	30
II.7.1 Modèles physiques.....	30
II.7.2 Modèles de régression.....	31
II.7.3 Modèles de corrélation spatiale.....	32

II.7.4 Modèles statistiques.....	33
II.7.4.1 Séries temporelles.....	34
II.7.4.2 Approches par apprentissage.....	36
II.7.4.3 Sommaire des méthodes de prévision statistiques.....	40
II.7.5 Filtre de Kalman sur la puissance.....	42
II.8 Conclusion.....	42

Chapitre III : Modèles Appliqués sur la PPE

III.1 Introduction.....	44
III.2. Méthode de régression.....	44
III.2.1 Méthode de régression linéaire simple.....	44
III.2.1.1 Estimation des paramètres.....	45
III.2.1.2 Coefficient de corrélation.....	46
III.2.2 Méthode de régression linéaire multiple.....	46
III.3 Réseaux de neurones artificiels.....	47
III.3.1 Objectifs des réseaux de neurones.....	47
III.3.2 Histoire des réseaux de neurones.....	48
III.3.3 Applications.....	49
III.4 Modèle d'un neurone.....	50
III.5 Fonctions de transfert.....	53
III.6 Perceptron simple.....	54
III.7 Réseau multicouche.....	54
III.7.1 Apprentissage des réseaux de neurones.....	55
III.7.2 Rétro-propagation du gradient.....	56
III.8 Le réseau à fonction de base radiale RBF.....	58
III.9 Conclusion.....	59

Chapitre IV : Simulations et Analyses des Resultats

IV.1 Introduction.....	60
------------------------	----

IV.2 Centrale éolienne d'Adrar.....	60
IV.2.1 Situation.....	60
IV.2.2 Potentiel éolien à Adrar.....	60
IV.2.3 Etude prévisionnelle de la centrale éolienne de Kaberten.....	63
IV.3 Outil de simulation.....	64
IV.4 Application de la régression linéaire simple dans la PPCT.....	64
IV.4.1 Prévision de production par régression simple à base des données des températures.....	64
IV.4.2 Prévision de production par régression simple à base des données de vitesses du vent.....	66
IV.5 Application de la régression linéaire multiple dans la PPCT.....	68
IV.5.1 Régression multiple de la vitesse des vents et de la température.....	69
IV.6 Prévision de production à court terme en utilisant les réseaux de neurones.....	70
IV.6.1 Prévision de production avec le perceptron simple.....	70
IV.6.2 Erreur de prévision pour différentes échantillons.....	72
IV.7 Comparaison des résultats des méthodes.....	73
IV.8 Conclusion.....	73
Conclusion générale.....	75
Bibliographie.....	76

Introduction générale

De nos jours, la production de l'énergie en général est considérée comme un indice représentatif du développement économique d'un pays, et plus particulièrement l'énergie électrique. Celle-ci est à la base de toutes activités industrielles, elle constitue par conséquent un facteur très important à l'amélioration des conditions de vie des citoyens, à l'accession et à la modernité.

La croissance rapide de la consommation de cette énergie est due essentiellement au développement industriel, à la croissance démographique ainsi qu'à l'urbanisation de plus en plus des villes et des campagnes et l'utilisation des biens électroménagers, ce qui nécessite un réseau performant capable de répondre en permanence à cette demande sans cesse grandissante.

Face à cette demande croissante d'énergie et à l'épuisement à plus ou moins long terme des énergies fossiles ainsi que les problèmes rencontrés en termes de pollution des déchets radioactifs, du démantèlement prochain des vieilles centrales et du risque industriel, différentes solutions de substitution ont été envisagées. Certains pays ont mené une politique orientée vers le nucléaire alors que d'autres ont massivement utilisé des énergies renouvelables.

L'Algérie comme tout autre pays s'engage avec détermination sur la voie des énergies renouvelables afin d'apporter des solutions globales et durables aux défis environnementaux et aux problématiques de préservation des ressources énergétiques d'origine fossile.

Ce choix stratégique est motivé par l'immense potentiel en énergie solaire. Cette énergie constitue l'axe majeur du programme qui consacre au solaire thermique et au solaire photovoltaïque une part essentielle. Le solaire devrait atteindre d'ici 2030 plus de 37% de la production nationale d'électricité [1].

Malgré un potentiel assez faible, le programme n'exclut pas l'éolienne qui constitue le second axe de développement et dont la part devrait avoisiner les 3% de la production d'électricité en 2030[1].

Ainsi le secteur de l'énergie électrique et gazier représenté par la Société Nationale de l'Électricité et du Gaz (SONELGAZ) est considéré comme l'un des piliers de l'économie. Il a joué dans le passé un rôle primordial dans l'industrialisation du pays et il continue encore d'assurer les besoins nationaux dans les meilleures conditions de qualité de l'énergie électrique, de sécurité et de coût.

Comme l'énergie électrique est un produit non stockable, sa production, son transport et son utilisation nécessitent d'énormes investissements et aussi une planification et une gestion rigoureuse ainsi que des prévisions sur la consommation et la production d'électricité à partir d'énergie fossile ou d'énergie renouvelable. Et comme la production à partir des sources intermittentes dépend du changement climatique (instabilité) le besoin de prévoir devient une nécessité pour la SONELGAZ.

On s'intéressera dans ce modeste travail à la prévision de la production d'énergie renouvelable à savoir l'éolienne. Ce qui nous a mené à utiliser la méthode de régression linéaire simple et multiple et la technique des réseaux des neurones artificiels comme méthodes de prévision.

Pour cela on prend à titre d'exemple la série de la production de l'énergie éolienne de Kaberten pendant de 15/01/2016 au 31/12/2016.

Pour mener à bien cette étude et afin d'atteindre nos objectifs, nous allons dans un premier temps consacrer le premier chapitre aux notions générales sur l'énergie éolienne, et l'impact de l'intégration de cette énergie sur le réseau électrique.

Dans le deuxième chapitre, Nous allons citer la notion de prévision en sens générale, ainsi les différents outils existants sont utilisés dans la prévision des énergies renouvelables sur échelles de temps.

Le troisième chapitre, contient l'aspect théorique de la méthode de régression simple et multiple, ainsi la technique des réseaux des neurones, pour les appliquer à la prévision de la production de la centrale éolienne.

Le quatrième chapitre, représente l'application des méthodes proposées (la régression simple, multiple et la technique des réseaux des neurones) sur le problème de la prévision de la source éolienne, ainsi que les simulations par logiciel MATLAB et ensuite les résultats et les interprétations.

Nous terminons notre travail par une conclusion générale.

Chapitre I : Notions générales sur l'énergie éolienne

I.1 Introduction

L'énergie éolienne est l'une des sources renouvelable tirée directement du vent à travers un dispositif appelé éolienne. La production d'électricité par les éoliennes a adopté un développement significatif dans le monde, l'aspect technologique de la turbine éolienne et sa modélisation. Ainsi, les différents types des aérogénérateurs seront détaillés dans ce chapitre.

L'énergie éolienne est l'une des productions décentralisées dont le pouvoir de l'intégrer dans le réseau électrique. Cette intégration doit respecter certaines contraintes techniques et impose généralement des aménagements dans le réseau pour assurer un fonctionnement correct. Les techniques de raccordement imposé, le choix de niveau de tension d'intégration dans les réseaux électriques et ses impacts seront traités dans ce chapitre.

I.2 Les différents types d'énergie renouvelable

Parmi les énergies renouvelables, on distingue :

I.2.1 Thermo solaire

Le principe consiste à transformer de l'énergie des photons solaires pour chauffer les capteurs thermiques, ce qui donne des températures pouvant arriver jusqu'à 80°C. Ce type d'énergie à l'avantage d'être écologique, peu cher et longue durée de vie des capteurs utilisés. Par contre, leurs majeurs inconvénients, résident dans l'impossibilité de transporter l'énergie à grande distance.

I.2.2 Géothermie

Elle consiste à extraire de l'énergie contenue dans le sol, dont la température varie de 3°C par 100 m jusqu'à 180°C, suivant le gisement à exploiter. L'avantage principal est d'être dépendre du climat et inépuisable. Cependant, son coût demeure très élevé.

I.2.3 Biomasse

Elle constitue une source d'énergie qui provient de toute matière vivante d'origine végétale ou animale (bois, biocarburant et biogaz). Elle est utilisée généralement dans les petites chaufferies individuelles jusqu'à la production de la chaleur industrielle de plus de 15 MW.

I.2.4 Photovoltaïque

L'énergie photovoltaïque est obtenue directement à partir du rayonnement du soleil, à partir des panneaux composés des cellules photovoltaïques à base de silicium.

I.2.5 Hydraulique

La masse de l'eau constitue une source d'énergie potentielle. Par le biais des barrages, les pays riches en cours d'eau bénéficient ainsi de cette énergie qui est propre et stockable.

I.2.6 Eolienne

Le vent connaît depuis environ 30 ans une grande importance comme source d'énergie. En effet, depuis une dizaine d'années, cette énergie connaît une croissance de 30% par an. L'étude de cette énergie sera notre objectif dans ce travail [2].

I.3 Historique de l'éolien

Depuis l'Antiquité, les « moulins à vent » convertissent l'énergie éolienne en énergie mécanique, généralement utilisée pour moulin du grain (**Figure (I.1)**). De nos jours, on trouve encore des éoliennes couplées à des pompes à eau, souvent utilisées pour irriguer des zones sèches, assécher des zones humides ou abreuver le bétail. L'arrivée de l'électricité donne l'idée à « Poul La Cour » en 1891 d'associer à une turbine éolienne une génératrice. Ainsi, l'énergie en provenance du vent a pu être « redécouverte » et de nouveau utilisée (dans les années 40 au Danemark, 1300 éoliennes). Au début du siècle dernier, les aérogénérateurs ont fait une apparition massive (6 millions de pièces fabriquées) aux Etats-Unis où ils étaient le seul moyen d'obtenir de l'énergie électrique dans les campagnes isolées. Dans les années 60, fonctionnait dans le monde environ 1 million d'aérogénérateurs. Cette technologie a été quelque peu délaissée par la suite et il faudra attendre la crise pétrolière de 1974 qui a relancé les études et les expériences sur les éoliennes [3].



Figure I.1 : Photographie de deux moulins à vent [4]

I.4 Définition de l'énergie éolienne




Figure I.2 : Schéma d'une turbine éolienne [5]

L'éolienne ou l'aérogénérateur est un dispositif qui permet de transformer l'énergie cinétique du vent en énergie mécanique sur un arbre de transmission puis en énergie électrique par l'intermédiaire d'un générateur.

I.5 Principe du vent

Le vent, c'est de l'air qui se déplace à cause des différences de température et de pression dans l'atmosphère. En effet, l'air chaud est plus léger que l'air froid. C'est pourquoi, quand le soleil chauffe la mer ou le sol, l'air qui se trouve juste au-dessus se réchauffe, s'allège, et monte, en poussant l'air froid qui est plus haut. L'air froid, plus lourd, descend et vient remplacer l'air chaud, puis il se réchauffe à son tour, et ainsi de suite.

En plus, comme la Terre est ronde, le Soleil ne distribue pas la chaleur partout de façon égale, et celle-ci n'est pas absorbée de la même manière par la mer ou par le sol. Toutes ces différences font que les masses d'air se déplacent verticalement et horizontalement.

Il existe des sites plus ou moins venteux, selon leur emplacement et leur dégagement, mais aussi selon leur incidence sur la pression de l'air. Par exemple, les crêtes de montagne et le bord de mer connaissent des vents plutôt violents : dans ces endroits, il y a en effet peu d'obstacles naturels ou de bâtiments pour retenir le vent [6].

I.6 Principe de conversion

L'éolienne permet de convertir l'énergie cinétique du vent en énergie électrique, cette conversion se fait en deux étapes:

- La conversion d'une partie de l'énergie cinétique du vent en énergie mécanique ; cette conversion se fait au niveau de l'éolienne.
- La conversion de cette énergie mécanique en énergie électrique. Selon la technologie de l'éolienne utilisée, la transmission de l'énergie électrique au réseau soit directement, soit par l'intermédiaire total ou partiel d'une interface de l'électronique de puissance.

I.7 Les différents types des turbines éoliennes

Les éoliennes se divisent en deux grandes familles : les éoliennes à axe vertical qui tendent à disparaître, les éoliennes lentes à axe horizontal utilisées surtout pour le pompage et les éoliennes rapides à axe horizontal plus particulièrement utilisées dans la production d'énergie électrique.

I.7.1 Eolienne à axe verticale

Les pales de l'éolienne verticale, également nommée VAWT (Vertical Axis Wind Turbine), tournent autour d'une tige positionnée verticalement, comme son nom l'indique. Cette solution est moins répandue que l'éolienne horizontale mais tend progressivement à la remplacer [7].

Son principal atout est sa capacité à capter des vents faibles:

- L'éolienne verticale n'a donc pas besoin de rafales ou de vents puissants, voire violents, pour fonctionner, car elle n'a pas besoin de s'orienter par rapport au vent.

De plus, elle demande moins d'espace qu'une éolienne horizontale et peut fonctionner quel que soit le sens du vent. [8].

I.7.1.1 Les différents types d'éolienne à axe vertical

On distingue dans cette étude deux catégories d'éoliennes à axe verticale:

I.7.1.1.1 Les éoliennes verticales Darrieus.




Figure I.3 : Schéma de différents types d'éoliennes Darrieus [9]

L'éolienne verticale de type Darrieus produit de l'électricité grâce à un rotor, qui peut être lui aussi de différent type (hélicoïdale, H, cylindrique), qui tourne autour d'une tige fixe, appelée stator à ailettes.

Les avantages de l'éolienne verticale type Darrieus sont nombreux :

- Elle peut être installée dans des zones très venteuses, puisqu'elle peut subir des vents dépassant les 220 km/h.
- Elle émet moins de bruit qu'une éolienne horizontale et occupe moins de place. De plus, vous pouvez l'installer directement sur le toit.
- Autre aspect pratique, son générateur est installé en bas de celle-ci. il peut être vérifié et entretenu plus facilement.

I.7.1.1.2 Les éoliennes verticales Savonius




Figure I.4 : Schéma d'une éoliennes Savonius [9]

L'éolienne verticale Savonius consiste en au moins deux demi-cylindres installés de manière légèrement désaxée l'un par rapport à l'autre.

Le vent s'engouffre dans l'un des demi-cylindres et le pousse. Les demi-cylindres n'étant pas rattachés en un même point, mais légèrement désaxés, le vent continue sa course dans l'autre demi-cylindre, qu'il pousse à son tour.

Les avantages de cette éolienne verticale sont :

- d'une part, son esthétisme et la possibilité de l'installer sur une toiture,
- d'autre part, le fait qu'elle fonctionne même avec un vent faible (contrairement au système Darrieus), quelle que soit sa direction. [8]

I.7.2 Eolienne à axe horizontale




Figure I.5 : Schéma d'une éolienne à axe verticale [9]

L'éolienne horizontale, également appelée HAWT (Horizontal Axis Wind Turbine) est le modèle le plus répandu. Elle capte le vent (de face ou de dos selon le modèle) grâce à des pales assemblées en hélice. Celles-ci tournent autour d'un mât placé horizontalement par rapport au sol. Le générateur, actionné par la rotation de l'hélice, est situé en haut de l'éolienne. C'est la plus utilisée par les particuliers car son rendement est plus important [8].

I.7.3 Composantes d'une éolienne à axe horizontale

Les composantes les plus souvent utilisés pour décrire une éolienne retiennent principalement quatre sous-ensembles :

- **le rotor**, partie rotative de l'éolienne placée en hauteur afin de capter des vents forts et réguliers. Il est composé de pales (en général 3) en matériau composite qui sont mises en mouvement par l'énergie cinétique du vent. Reliées par un moyeu, ces dernières peuvent en moyenne mesurer chacune 25 à 60 m de long et tourner à une vitesse de 5 à 25 tours par minute;
- **la nacelle**, structure soutenue par le mât abritant les différents éléments mécaniques. On distingue les éoliennes à entraînement direct de celles équipées de train d'engrenages (multiplicateur/réducteur) selon le type d'alternateur utilisé. Les alternateurs classiques requièrent une adaptation de la vitesse de rotation par rapport au mouvement initial du rotor.

- **la tour**, composée du mât, du système de commande électrique et du transformateur. le mât supporte la nacelle. Il mesure entre 50 et 130 m de haut et a un diamètre à son pied compris entre 4 et 7 m. Une ouverture en bas du mât permet d'accéder aux différents équipements de l'éolienne parmi lesquels le transformateur qui permet d'augmenter la tension de l'électricité produite afin de l'injecter sur le réseau ;
- **la base**, souvent circulaire et en béton armé dans le cas des éoliennes terrestres, qui permet de maintenir la structure globale [10].




Figure I.6 : Schéma des différentes composantes d'une éolienne à axe horizontale [10]

I.7.4 L'énergie éolienne en Algérie

L'Algérie, accuse un retard important dans la course aux énergies renouvelables, malgré la décision gouvernementale qu'un programme ait été élaboré dans le plan d'action « 2011-2030 », dans l'objectif d'installation d'une puissance de 5.1 GW de source éolienne. A ce jour, une première et « unique » ferme éolienne de 10MW a été installée dans la région de Kaberten dans la wilaya d'Adrar [11].

I.8 Modélisation de la turbine éolienne

On fait la modélisation mathématique de la turbine éolienne.

I.8.1 L'énergie récupérable par une turbine et limite de Betz

Pour beaucoup plus comprendre de la part convertie de l'énergie cinétique du vent en énergie mécanique, On considère une colonne d'air de longueur dl , de section S , de masse volumique P animée d'une vitesse V conformément à la figure suivante :




Figure I.7 : Colonne d'air [11]

L'énergie cinétique de cette colonne d'air est donc :

$$dE_c = \frac{1}{2} dm \cdot v^2 \quad (\text{I.1})$$

Avec : $dm = \rho S dl$

Or nous savons que : $dl = v dt$ car $v = \frac{dl}{dt}$

D'où :

$$dE_c = \frac{1}{2} \rho S v^3 dt \quad (\text{I.2})$$

On en déduit alors l'expression de la puissance disponible :

$$P = \frac{dE_c}{dt} = \frac{1}{2} \rho S v^3 \quad (\text{I.3})$$

Donc la puissance du vent ou de puissance éolienne est de définie de la manière suivante:

$$P_v = \frac{1}{2} \rho S v^3 \quad (\text{I.4})$$

Où :

ρ est la densité de l'air (Approximativement 1.22 kg/m³ à la pression atmosphérique à 150C),

S est la surface balayée par la turbine, le rayon du cercle est déterminé par la longueur de la pale (S (m²)).

I.8.2 Limite de Betz

Considérons la figure ci-dessous : soit S la surface de la turbine éolienne, v_1 la vitesse d'entrée et v_2 la vitesse sortie de l'éolienne.




Figure I.8 : Schéma du courant d'air traversant une turbine [11]

Soit v_s la vitesse moyenne de l'air traversant S :

$$v_s = \frac{v_1 + v_2}{2} \quad (\text{I.5})$$

Soit $S v_s$, la masse d'air traversant S par unité de temps.

La variation d'énergie par unité de temps, donc la puissance, transmise au rotor de l'éolienne vaut :

$$P = \frac{1}{2} \rho S v_s (v_1^2 - v_2^2) = \frac{1}{4} \rho S (v_1 + v_2) (v_1^2 - v_2^2) \quad (\text{I.6})$$

Le maximum de l'équation (I.6) $P (v_2)$ s'obtient lorsque :

$$\frac{d}{dv_2} \left\{ \frac{1}{4} \rho S (v_1 + v_2) (v_1^2 - v_2^2) \right\} = 0 \quad (\text{I.7})$$

En développant, on obtient :

$$\frac{1}{4}\rho S(-3v_2^2 - 2v_1v_2 + v_1^2) = 0 \quad (\text{I.8})$$

Cette expression s'annule pour : $v_2 = \frac{v_1}{3}$

D'où la puissance maximale est :

$$P_{max} = \frac{8}{27}\rho S v_1^3 \quad (\text{I.9})$$

La fraction maximale de la puissance totale qu'il est possible de convertir en énergie mécanique et qui détermine la limite de Betz est donc donnée par :

$$C_p = \frac{P_{max}}{P_v} = \frac{16}{27} \approx 0.593$$

Cette fraction est définie par le *coefficient de puissance* C_p qui propre à chaque turbine et qui dépend à la fois de position angulaire de l'axe de la pale, caractérisée par son angle de calage β et du rapport de la vitesse spécifique λ donnée par conventionnel :

$$\lambda = \frac{R_{Turbine} \Omega_{Turbine}}{v} \quad (\text{I.10})$$

Où : λ est la vitesse spécifique (sans unité).

R_T est le rayon de la turbine (longueur de la pale (m)).

Ω_T est la vitesse angulaire de la turbine (rad/s).

Donc la puissance aérodynamique apparaissant au niveau du rotor s'écrit :

$$P_{aer} = C_p P_v = \frac{1}{2}\rho C_p(\lambda, \beta) S v^3 \quad (\text{I.11})$$

Connaissant la vitesse de turbine, le couple aérodynamique est donc directement déterminé par :

$$C_{aer} = \frac{P_{aer}}{\Omega_{Turbine}} = \frac{1}{\Omega_{Turbine}} C_p S v^3 \quad (\text{I.12})$$

I.8.3 Modèle du multiplicateur

Le multiplicateur de vitesse, qui est disposé entre la turbine éolienne et la génératrice, Il sert a adapté la vitesse plus lente de la turbine $\Omega_{Turbine}$ à celle la plus rapide de génératrice mec, il est souvent modélisé par les deux équations suivantes:

$$C_{gén} = \frac{C_{aer}}{G} \quad (\text{I.13})$$

$$\Omega_{Turbine} = \frac{\Omega_{mec}}{G} \quad (\text{I.14})$$

Où :

$C_{gén}$, C_{aer} : sont les couple de génératrice et l'aérogénérateur (N.m).

Ω_{mec} , $\Omega_{Turbine}$: sont les vitesses angulaire de génératrice et l'aérogénérateur (rad/s).

G : est le gain du multiplicateur.

I.8.4 Equation dynamique de l'arbre

La masse de la turbine éolienne est reportée sur l'arbre de la turbine sous la forme d'une inertie $J_{turbine}$ et comprend masse des pales et la masse du rotor de la turbine. Le modèle mécanique proposé considère l'inertie totale J constitué de l'inertie de la turbine reportée sur le rotor de la génératrice et de l'inertie.

$$J = \frac{J_{turbine}}{G^2} + J_{gén} \quad (\text{I.15})$$

L'équation fondamentale de la dynamique permet de déterminer l'évolution de la vitesse mécanique à partir du couple mécanique total C_{mec} appliqué au rotor :

$$J \frac{d\Omega_{mec}}{dt} = C_{Tot} - C_{vis} \quad (\text{I.16})$$

Où C_{vis} est le couple résistant dû aux frottements est modélisé par un coefficient de frottement visqueux f :

$$C_{vis} = f \Omega_{mec}$$

- C_{Tol} c'est le couple total qui égale à la superposition des couples de la génératrice $C_{gén}$ et électromagnétique $C_{ém}$.

$$C_{tol} = C_{gén} = C_{ém} \quad (\text{I.17})$$

L'équation de l'arbre mécanique devient alors :

$$J \frac{d\Omega_{mec}}{dt} = f \Omega_{mec} - C_{gén} - C_{ém} \quad (\text{I.18})$$

I.9 Les générateurs éoliens

Le générateur éoliens reçoit l'énergie mécanique et la convertit en énergie électrique. Il existe plusieurs types de technologies qui peuvent jouer le rôle de génératrice dans un système aérodynamique qui demande des caractéristiques très spécifique [5].

On décrit dans cette étude les principaux types de système éoliens:

I.9.1 Eolienne à vitesse fixe

Ces systèmes éoliens (figure) sont constitués d'une turbine éventuellement équipée de contrôle de l'angle de calage des pales β , d'un multiplicateur de vitesse et d'un générateur. Ce générateur est principalement une machine asynchrone directement couplée au réseau et en tournant en hyper synchronisme à la vitesse $\Omega_s (1-g)$ où g est le glissement de la machine ($g < 0$ dans ce cas) étant couplée directement au réseau, la vitesse est imposé par ce dernier et par conséquence quasiment constante. La puissance convertie par la machine est donnée au rendement près par l'expression suivante :

$$P_{éle} \cong \frac{1}{1-g} P_{mec} \quad (\text{I.19})$$

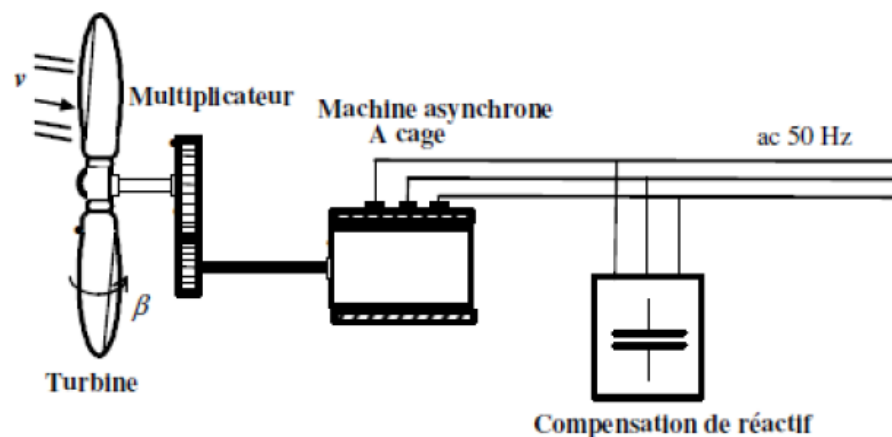


Figure I.9 : Structure d'une éolienne à vitesse fixe [5]

On note également la présence de batterie de compensation pour compenser la puissance réactive consommée par le maintien de la magnétisation de la machine.

Les principaux avantages de cette technologie sont sa robustesse et son faible coût, notamment dû à l'utilisation de machines standards. En revanche la puissance captée n'est pas optimisée, le coût de maintenance essentiellement imputé au multiplicateur est élevé et on ne peut pas contrôler l'énergie réactive. Par ailleurs la connexion directe de l'enroulement statorique de la génératrice au réseau entraîne une très forte sensibilité aux creux de tension.

I.9.2 Eolienne à vitesse variable

Cette technologie est basé sur une interface d'électronique entre le réseau et le rotor pour réguler la tension, et assure l'échange de puissance réactive entre le rotor et le réseau [12].

On distingue dans cette étude deux types d'éoliennes:

I.9.2.1 Eolienne à base de machine asynchrone à double alimentation (MADA)

La machine asynchrone à double alimentation est une machine asynchrone dont le rotor bobiné est raccordé au réseau par l'intermédiaire d'une interface d'électronique de puissance. Cette interface adapte l'amplitude et la fréquence des courants rotoriques en contrôlant la tension aux bornes du rotor en fonction du point de fonctionnement de la machine.

Le stator est connecté directement au réseau et fonctionne dans les conditions normales, sous des amplitudes de tension constante et à fréquence constante (généralement 50 Hz).

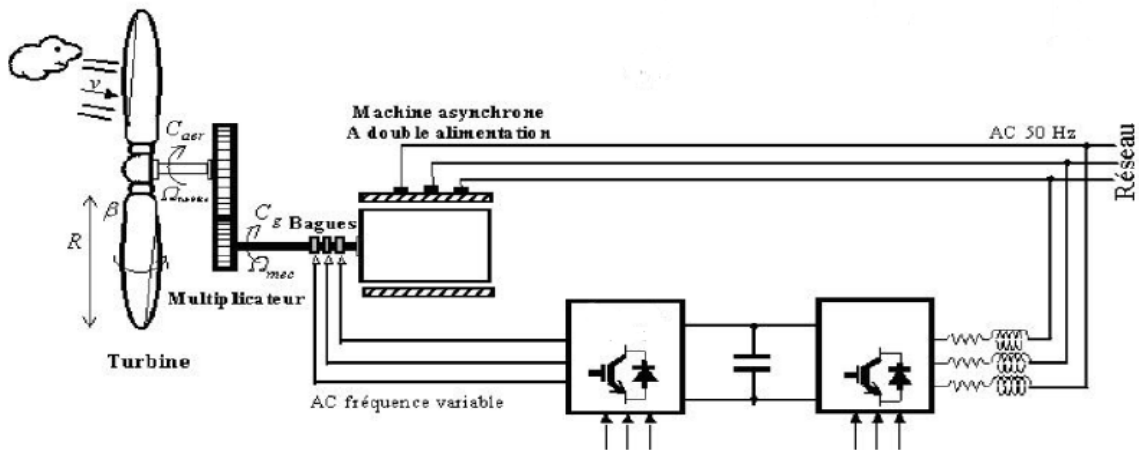


Figure I.10 : Structure d'une éolienne à base MADA [5]

I.9.2.2 Eolienne à base de machine synchrone à aimants permanents (MS)

Cette structure est basée sur une machine synchrone à aimants permanents interfacée par un dispositif d'électronique de puissance constitué d'un redresseur connecté au stator et un onduleur connecté au réseau. Cette structure permet de varier la vitesse de 0% à 100% de la vitesse nominale de rotation de la machine.

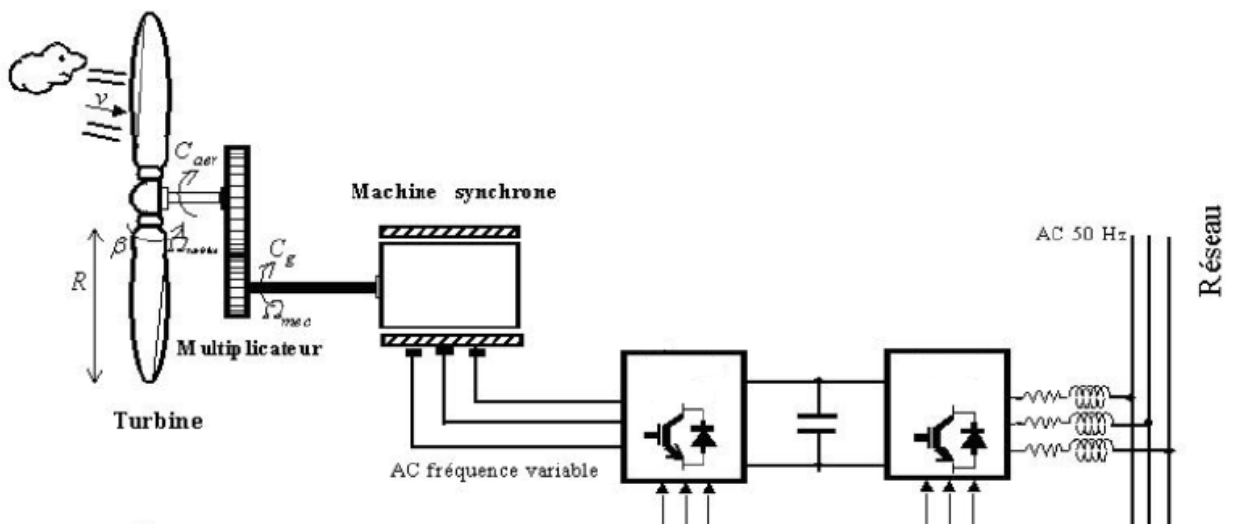


Figure I.11 : Structure d'une éolienne à base de MS à aiment permanents [5]

Le convertisseur connecté au stator de la machine contrôle le couple de la machine et celui connecté au réseau assure le transfert de puissance entre la génératrice et le réseau ainsi que l'échange de puissance réactive avec ce dernier. Comme pour l'interface de la MADA.

Cette technologie offre de nombreux avantages : souplesse de contrôle, découpage entre le réseau et génératrice, optimisation de la production grâce à une grande plage de vitesse.

I.10 Raccordement d'énergie renouvelable dans le réseau de distribution

I.10.1 Technique de raccordement

En fonction des pays, compte tenu des impacts que peuvent avoir les moyens de production sur les réseaux, des conditions techniques spécifiques de raccordement sont reconnus par grid code ou codes de distribution.

I.10.1.1 Connexion au réseau

L'éolienne connectée, de même que tous les périphériques connectés au réseau, a un impact plus ou moins important sur la qualité de l'énergie. De plus, les parcs éoliens sont situés dans un territoire où les vents sont favorables et où le réseau est peu développé. Néanmoins, les parcs éoliens doivent être connectés de plusieurs façons, par exemple. Néanmoins, les parcs éoliens doivent être connectés de plusieurs façons, par exemple:

- Parc éolien connecté à la ligne moyenne tension (HTA) existante qui répond aux demandes environnantes (puissance transmissible - de 2 à 5 MW).
- Si la ligne HTA est trop faible pour le parc éolien, elle peut être connectée au jeu de barres HTA de la sous-station HTB / HTA la plus proche par sa propre ligne (puissance transmissible de 10 à 40 MW).
- Parc éolien connecté au jeu de barres HTB dans la sous-station HTB / HTA la plus proche par une ligne propre avec son propre transformateur HTB / HTA (puissance transmissible - jusqu'à 100 MW).

Quelle que soit la méthode de connexion, l'éolienne introduit dans le réseau plus ou moins de variations de puissance. Généralement la solution la plus courante est la connexion en moyenne tension (HTA), qui génère la plupart des interférences [13].

I.10.1.2 Tension de raccordement

La tension au point de raccordement détermine la puissance maximale de l'insertion de production décentralisée. Le tableau (I.1) donne les niveaux de tension au point de raccordement en fonction de la puissance de l'installation appliqués en France [12].

Tableau I.1 : Niveaux de tension aux points de raccordement en fonction de la puissance installée [12]

Réseau	Limite de tension	Niveaux réels	Limites de puissance
BT	$U \leq 1 \text{ KV}$ (raccordement monophasé)	230 KV	$P \leq 18 \text{ KVA}$
	$U \leq 1 \text{ KV}$ (raccordement triphasé)	400 KV	$P \leq 250 \text{ KVA}$
HTA	$1 \text{ KV} < U \leq 50 \text{ KV}$	15 KV, 20KV, 33KV	$P \leq 17 \text{ MW}$
HTB	$50 \text{ kV} < U \leq 130 \text{ kV}$	63 kV, 90 kV	$P \leq 50 \text{ MW}$
	$130 \text{ kV} < U \leq 350 \text{ kV}$	150 KV, 225KV	$P \leq 250 \text{ MW}$
	$350 \text{ kV} < U \leq 500 \text{ kV}$	400 KV	$P > 250 \text{ MW}$

I.10.1.3 La capacité d'accueil des réseaux

La capacité d'accueil en un nœud donné d'un réseau est la puissance de raccordement maximale qui respecte à tout moment les contraintes de tension et de courant sur l'ensemble du réseau considéré. Cette capacité est très souvent limitée par les contraintes de tension haute, notamment dans les zones rurales et semi-urbaines où des producteurs de puissance élevée ($> 1 \text{ MW}$) demandent à être raccordés à l'espace disponible permettant d'y développer de tels projets.

La capacité d'accueil P_{raccmax} d'un départ de type rural ou semi-urbain, à la distance l du poste électrique, peut donc être estimée à partir d'un modèle analytique du plan de tension d'un départ à grandeurs supposées uniformément réparties : haute, notamment dans les zones rurales et semi-

urbaines où des producteurs de puissance élevée (> 1 MW) demandent à être raccordés à l'espace disponible permettant d'y développer de tels projets.

La capacité d'accueil $P_{raccmax}$ d'un départ de type rural ou semi-urbain, à la distance l du poste électrique, peut donc être estimée à partir d'un modèle analytique du plan de tension d'un départ à grandeurs supposées uniformément réparties :




Figure I.12 : Modèle d'un départ HTA « à grandeurs uniformément réparties » [14]

$$P_{raccmax} = \frac{U_{max}^2 - U_0^2 + (2\varepsilon - \varepsilon^2)(RP_{cmin} + XQ_{cmin})}{2\varepsilon(R + X \tan \varphi)} \quad (\text{I.20})$$

Avec $\varepsilon = l/L$

Où:

-L, R et X : la longueur, la résistance et la réactance totales du départ ;

- P_{cmin} et Q_{cmin} : les puissances active et réactive minimales consommées sur le départ ;

- $\tan(\varphi)$: de la production associée à $P_{raccmax}$ à la distance l ;

- U_0 : la tension au secondaire du transformateur amont ;

$-U_{\max}$: la tension maximale admissible à la distance l du poste électrique.

Si $L=0$, l'équation de la puissance de raccordement devienne :

$$S_{raccmax} = S_{source} = S_{cmin} \quad (\text{I.21})$$

I.10.1.4 Types de raccordement

L'énergie éolienne est comme toute production décentralisée a deux types de raccordement dans le réseau électrique:

- **Raccordement en départ mixte** : le raccordement à un départ existant auquel des consommateurs et éventuellement des producteurs sont déjà raccordés (**Figure I.13.a**).
- **Raccordement en départ direct** : le raccordement au poste source le plus proche via un départ nouvellement créé pour le nouvel utilisateur (**Figure I.13.b**).




Figure I.13 Illustration des configurations de raccordement (a) en départ mixte (b) en départ direct

[14]

I.11 Impacts de l'intégration d'un système éolien dans le réseau

Le raccordement un système électrique quelconque a un impact non négligeable qui dépend de la technologie utilisée, et aussi du type de réseau. En général on peut dire que plus le taux de pénétration est important plus l'impact de l'intégration des énergies renouvelable dans les réseaux est significatif. On peut distinguer des impacts locaux qui concernent tous les types de réseaux et les impacts globaux qui concernent en particulier les réseaux de transports interconnectés et les réseaux insulaires [15].

I.11.1 Impacts Locaux

Ce sont les impacts qui se produisent dans le point de raccordement de l'unité et. Les impacts locaux sont en général indépendants du taux de pénétration global des unités de production des énergies dans le système. Ils concernent deux principaux aspects : la capacité d'accueil du réseau et la qualité de tension :

I.11.1.1 Plan de tension

Les impacts sur la tension de telles productions vont être différents selon le type de réseaux auxquels elles sont connectées. Selon la nature du réseau, les caractéristiques du poste source, le point de raccordement et la puissance injectée par l'éolienne, la tension peut être élevée au point de raccordement, pouvant même dépasser la limite admissible. La gestion du plan de tension a pour objet de maîtriser les chutes de tension actives et réactives qui sont croissantes de l'amont vers l'aval tout en assurant le respect des obligations contractuelles ou réglementaires. L'intégration de l'énergie éolienne provoque les fluctuations suivantes :

- **de tension**
- **Flicker**
- **Harmonique**

I.11.1.2 Court-Circuit

L'impact sur le courant de court-circuit dû aux éoliennes qui suivant la technologie peuvent, en cas de défaut sur le réseau, alimenter et donc accroître le courant de court-circuit circulant dans le réseau. La contrainte ici est de ne dépasser ni les valeurs maximales admissibles pour les différents appareillages de réseaux et les conducteurs, ni le pouvoir de coupure des organes de protection. Chaque appareil de coupure possède un pouvoir de fermeture et un pouvoir de coupure sur défaut ; un dépassement des valeurs de dimensionnement de l'appareil de coupure a pour conséquence un risque de non coupure de l'arc ou de non fermeture du courant de défaut avec un fort risque de destruction de l'appareillage.

Les éoliennes à vitesse fixe, étant équipées de machines asynchrones classiques directement couplées au réseau, contribuent de façon significative aux courants de court-circuit.

Les éoliennes à vitesse variable équipées de machines asynchrones à double alimentation contribuent aussi aux courants de court-circuit. Cependant cette contribution diminue rapidement du fait de l'action des équipements d'électronique de puissance qui détectent et mesurent les défauts rapidement.

La contribution des éoliennes à vitesse variable équipées de machines synchrones est négligeable car la machine est entièrement découplée du réseau par l'interface à électronique de puissance.

I.11.1.3 Plan de protection

Le plan de protection est un système coordonné de protections visant à isoler très rapidement un ouvrage en défaut (ligne, transformateur, jeu de barres, etc.) afin de garantir la sécurité des biens et des personnes. Différents types de relais mesurant différentes grandeurs physiques sont utilisés.

Le raccordement de la production d'énergie renouvelable peut entraîner des variations du sens (réseau de production) ou de l'amplitude des courants en régime permanent, des variations des courants de court-circuit, des modifications de la tension, des variations des impédances mesurées, etc. Ces variations peuvent avoir une influence sur le bon fonctionnement du plan de protection avec notamment des aveuglements de protection ou des déclenchements intempestifs...

I.11.2 Impact globaux

A part les impacts locaux qui ont des effets dans le voisinage du point de raccordement, les unités de production des énergies renouvelables peuvent avoir des impacts plus globaux à l'échelle d'une région surtout si elles sont raccordées au réseau de transport ou dans les réseaux insulaires.

I.11.2.1 Impact sur le fonctionnement des systèmes

La problématique majeure liée à l'intégration des énergies renouvelables dans les réseaux est de deux ordres :

- La variabilité de la production d'énergie renouvelable du fait des variations de l'énergie primaire qui de plus est non contrôlable (fatale). Les gestionnaires de réseau doivent donc faire face à une production fatale variable. Des capacités de production de réserve contrôlables sont alors nécessaires pour pallier à ces variations, en particulier pour satisfaire la demande en période de pointe,

- L'incertitude sur les prévisions météorologiques induisant une incertitude sur la production. Cette problématique est plus marquée pour la production éolienne car les prévisions de vitesse de vent sont moins fiables que celles de l'ensoleillement.

Les deux aspects cités plus haut ont trait à des impacts liés surtout à la réalisation de l'équilibre production-consommation à divers horizons temporels. Outre ces préoccupations, restent celles liées à la sécurité du réseau du point de vue global.

I.11.2.2 Capacité de transport

L'impact de l'intégration des Energies renouvelables sur les capacités de transport dépend de la situation géographique de la production renouvelable par rapport à la demande, de la corrélation entre cette production et la demande et de la puissance du réseau initial. La production d'énergie renouvelable affecte le transit de puissance dans le réseau : elle peut changer le sens des flux, augmenter ou réduire les pertes. L'analyse des capacités de transport nécessite à la fois des études statiques (calcul de la répartition des flux de puissance) et dynamiques (analyse de stabilité).

I.11.2.3 Impacts sur le sens de transit de puissance

Les réseaux sont dimensionnés pour recevoir les flux d'énergie du réseau de transport vers la distribution. L'insertion d'une production décentralisée (l'énergie éolienne...) dans les niveaux de tension autres que le réseau de transport peut créer une injection de puissance dans le sens contraire, c'est-à-dire de la distribution vers le transport. Les équipements, notamment les protections doivent alors être bidirectionnelles. Ainsi, sachant que les réseaux au niveau de tension inférieure sont normalement surdimensionnés afin de faire face à l'accroissement de consommation, lorsque le taux de pénétration de PD augmentera, la modification du sens de transit de puissance pourra éventuellement provoquer des congestions locales.

I.11.2.4 Dispatching

Cet impact est dû à la variabilité et aux erreurs de prédiction de la production renouvelable. Les deux principaux aspects influencés sont : le dispatching, et l'exploitation (durée, charge partielle, arrêts/démarrages) du parc de production. Il est donc important de développer des méthodes pour analyser et intégrer l'impact des énergies renouvelables sur la gestion prévisionnelle du parc de production [16].

I.12 Conclusion

Nous avons traité dans ce chapitre l'aspect de la turbine éolienne, ces différents types, et le principe de conversion de l'énergie cinétique jusqu'à la production électrique. Ainsi, la structure de l'éolienne à axe horizontale et sa modélisation.

A la fin de ce chapitre nous avons cité les différents types technologiques d'aérogénérateurs et la spécification de chacune, et les avantages de l'une par rapport aux autres.

Et, on prend de point de vue général les contraintes imposées pour un bon fonctionnement du système électrique au cours de l'intégration d'une production décentralisée surtout l'énergie éolienne et ses impacts sur le réseau électrique.

Chapitre II : Pr vision de la production  olienne (PPE)

II.1 Introduction

Les prévisions de l'énergie éolienne jouent toujours un rôle clé pour relever les défis de l'exploitation de l'approvisionnement en électricité.

Récemment, plusieurs méthodes ont été utilisées pour la prévision de l'énergie éolienne. De nombreuses littératures ont été consacrées aux améliorations des approches de prévision de l'énergie éolienne par des chercheurs ayant une grande expérience des essais sur le terrain. Un certain nombre de méthodes de prévision de l'énergie éolienne ont été développées et lancées sur des sites éoliens. Les méthodes de prévision de l'énergie éolienne peuvent généralement être classées en six groupes, méthode de persistance, méthode physique, méthode statistique, méthode de corrélation spatiale, méthode d'intelligence artificielle [17].

Nous examinons dans ce chapitre la notion de prévision, ainsi les outils existants utilisés dans la prévision de la vitesse et de la puissance du vent sur échelles de temps.

II.2 Quesque qu'une prévision ?

Prévoir, c'est observer un ensemble de données qui permet d'envisager une situation future et d'entreprendre des actions pour y parer concrètement autrement dit c'est porter un jugement sur les événements ou évolutions possibles à venir en utilisant comme outils le passé et le présent.

Il en résulte que les prévisions sont toujours entachées d'erreur et qu'il est possible d'en établir plusieurs pour un même événement à venir (qui constitue l'objet de la prévision).

Des outils d'analyse doivent donc être développés afin de comparer et de hiérarchiser les prévisions pour discerner ce qui fait qu'on puisse, ou non, en qualité certaines de " bonnes "[1].

II.3 Ce qui caractérise un problème de prévision

La première approche de la prévision consiste à en mesurer les septicités. Pour envisager une typologie des problèmes de prévision en termes d'horizon, de type de produit ou de secteur, ou en termes de but opérationnel, il est utile de dégager quelques traits qui différencient fondamentalement :

- le secteur d'activité.
- l'utilisation opérationnelle.

- la (ou les) fonction(s) utilisatrice(s) de la prévision.
- l'horizon.

L'approche est très dépendante du secteur d'activité : on ne prévoit pas des livraisons de ciment par les mêmes méthodes que des ventes de savons. Les causalités économiques sous-jacentes sont différentes suivant que le secteur est plus ou moins en amont dans le circuit industriel donc plus ou moins proche de la demande finale, suivant que le produit est stockable ou non, qu'il donne lieu à un marché de renouvellement (télévision) ou non (acier), que le produit est standardisé ou non[1] .

II.4 Différentes échelles de temps de prévisions

Une autre classification des modèles de prévision peut être adoptée selon l'échelle du temps, à savoir :

1) Prévision à très court-terme, où l'échelle de temps varie de quelques secondes à 30 minutes. La prévision à très court terme s'utilise pour le contrôle de la turbine. Ces approches reposent généralement sur des modèles statistiques, notamment le RNA.

2) Prévision à court-terme, où l'échelle du temps peut varier entre de 30 min et 6 h, en fonction de la taille du système et du type d'unités conventionnelles disponibles (comme les groupes électrogènes diesel ou les turbines à gaz, dont l'autonomie peut être inférieure à 3 h). Seules quelques applications intègrent ce type d'application en temps réel. Ces dernières sont utilisées pour les systèmes électriques isolés ou de petite taille. Plusieurs outils ont été développés pour la prévision de l'énergie éolienne à court terme parmi lesquels WPPT, Predictor, Zephyr, Ewind, WPFS et AWPPS.

3) Prévision à moyen-terme, dont l'échelle de temps varie de 6 h à 24 h. Les prévisions à moyen terme sont exigées par différents utilisateurs (services publics, opérateurs de marché d'électricité, gestionnaires de transport, opérateurs du système, etc.) et ce, pour différentes applications telles que la répartition économique de la production, l'évaluation de la sécurité dynamique, la gestion du marché de l'électricité, etc.

4) Prévision à long-terme, avec une échelle de temps allant d'une journée à 7 jours ou plus. La prévision à long terme est utilisée pour l'établissement du planning de maintenance des

éoliennes, des décisions d'engagement des unités et des décisions relatives aux exigences de réserve (cela vise particulièrement la sécurité du système électrique) [18].

Des échelles de temps encore plus longues permettraient de prévoir le planning de maintenance de grandes centrales d'éoliennes ou des lignes de transmission. De bons résultats prévisionnels peuvent être obtenus par les approches statistiques pour différentes échelles de temps (à court, moyen et long terme). Mais l'utilisation des approches physiques devient nécessaire à court et à long terme en raison de l'impact des changements climatiques.

Tableau II.1 Classification temporelle pour la prévision du vent [19]

Échelle de temps	horizon	Applications
Très court terme	de quelques minutes à 1 heure d'avance	<ul style="list-style-type: none"> • Compensation du marché de l'électricité • Opérations de réseau en temps réel • Actions de régulation
Court terme	1 heure à plusieurs heures à l'avance	<ul style="list-style-type: none"> • Planification économique de la répartition des charges • Charger des décisions raisonnables • Sécurité opérationnelle sur le marché de l'électricité
Moyen terme plusieurs	plusieurs heures à 1 semaine à l'avance	<ul style="list-style-type: none"> • Décisions d'engagement d'unité. • Décisions sur les réserves obligatoires • Générateur de décisions en ligne / hors ligne
long terme	1 semaine à 1 an ou plus à l'avance	<ul style="list-style-type: none"> • Planification de la maintenance • Gestion d'opération • Coût d'exploitation optimal • Etude de faisabilité pour la conception du parc éolien

II.5 Les méthodes de prévisions

- **Méthodes extrapolatives**

Ces méthodes utilisent le passe de la variable elle-même.

Seul le passé de la variable est utilisé en vue de la prévoir sans apport d'information extérieure, nous citons à titre d'exemple : lissage par les moyennes mobiles, modélisation ARMA .

- **Méthodes explicatives**

Celles-ci utilisent les valeurs passées et présentes d'une ou de plusieurs variables pour prévoir y . L'ensemble d'information utilise comporte des facteurs extérieurs qui peuvent influencer le futur de y en plus du passé de la variable y elle-même.

Parmi ces méthodes on peut citer : la régression linéaire, modèle ARMAX [1].

II.6 Critères de validité de la méthode de prévision

La prévision des valeurs futures d'une variable y peut se faire en utilisant différentes méthodes. Les prévisions obtenues peuvent être comparées et appréciées selon plusieurs critères parmi lesquels :

L'erreur moyenne :
$$\bar{e} = \frac{1}{n} \sum_{t=1}^n e_t \quad (\text{II.1})$$

La carre moyenne des erreurs :
$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2 \quad (\text{II.2})$$

L'erreur quadratique moyenne:
$$RMSE = \sqrt{MSE} \quad (\text{II.3})$$

L'erreur relative moyenne absolue :

$$EMAP = \frac{100}{n} \sum_{t=1}^n \frac{|P_t - \hat{P}_t|}{P_t} \quad (\text{II.4})$$

\hat{P}_t : Production réalisée.

P_t : Production désirée.

e_t étant l'erreur de prévision pour un instant t (la différence entre la valeur observée et la valeur prévue par une méthode quelconque).

La meilleure méthode est celle qui fournit les valeurs les plus faibles pour ces critères [1].

II.7 Les modèles de prévision de l'énergie éolienne :

Les méthodes de prévision de production d'énergie éolienne peuvent être classiques comme suite :

II.7.1 Modèles physiques

Les modèles physiques ne sont pas précis pour les prévisions à court terme, étant donné leur temps de calcul très élevé. Néanmoins, plusieurs approches statistiques hybrides ont recours aux prévisions des PNTs comme paramètres d'entrée. Les prévisionnistes effectuant des prévisions à partir de modèles physiques reçoivent les résultats des modèles de prévision numérique du temps par courrier électronique ou par service FTP [5]. Ils sont couramment émis sous forme de grille grossière ayant une résolution de plusieurs kilomètres. Au Canada, le modèle disponible est le Système global de prévision déterministe (SGPD) du modèle GEM (Global Environmental Multiscale) d'Environnement Canada. Celui-ci possède une résolution effective d'environ 25 km, soit de $0,24^\circ \times 0,24^\circ$ [21]

(La **Figure II.1** illustre le concept, mais ne correspond pas à la résolution réelle du modèle).




Figure II.1 Exemple de grille. Image libre de droits [21].

La résolution spatiale de ces modèles a une influence majeure sur la précision des prévisions, ce qui est encore plus significatif dans le cas de terrains complexes. La combinaison de plusieurs méthodes (physiques et statistiques) est donc cruciale pour réduire l'erreur [22]. Pour le système global de prévision déterministe (SGPD), les prévisions sont générées toutes les 12 heures pour un horizon de 10 jours, avec un pas de temps de 3 h. Comme mentionné précédemment, les modèles physiques sont conçus et performant mieux pour les prévisions à long terme.

II.7.2 Modèles de régression

Une régression est basée sur l'idée qu'une variable dépendante est déterminée par une ou plusieurs variables indépendantes. En supposant qu'il existe une relation de causalité entre les deux variables, la valeur de la variable indépendante affecte la valeur de la variable dépendante. Par exemple, si vous voulez savoir comment vos investissements publicitaires influent sur vos ventes, une analyse de régression serait utilisée pour examiner la relation entre les investissements et les ventes. Si cette relation est clairement représentée, elle peut servir de prévision. Les analyses de régression ont deux objectifs centraux. Elles sont censées :

- quantifier les relations et les décrire à l'aide des valeurs mesurées et de leur représentation graphique.
- fournir des prévisions et des prédictions [23].

Types d'analyses de régression

- **Régression simple:** seulement une variable explicative est utilisée pour expliquer la variable dépendante.
- **Régression multiple:** plusieurs variables explicatives sont liées à une variable dépendante.
- **Régression linéaire :** il existe une relation linéaire entre plusieurs variables explicatives et plusieurs variables dépendantes. Le concept comprend également des paramètres linéaires et une structure.
- **Régression non-linéaire:** s'il n'existe pas de relation linéaire entre les variables dépendantes et indépendantes, vous obtenez une régression non-linéaire. Ces modèles

peuvent être très complexes, car les relations entre les variables ne peuvent pas être organisées et tracées en utilisant des méthodes mathématiques simples [23].

II.7.3 Modèles de corrélation spatiale

Plusieurs modèles de prévision basés sur une approche de corrélation spatiale ont été étudiés. Ces modèles sont plus complexes que les modèles de séries chronologiques ordinaires car ils exigent des données mesurées sur plusieurs sites.

Alexiadis et al. (1999) dans Réf. [24] ont développé un modèle de réseau neuronal artificiel basé sur la corrélation croisée sur les sites voisins pour prévoir la vitesse et la puissance du vent sortie jusqu'à 2 heures à l'avance. La méthode a été testée sur deux groupes de sites de 0,8 à 40 km à part en Grèce sur une période d'un an. Les résultats ont montré qu'ANN préformé 20- 40% mieux que le persistant sur la base des erreurs moyennes. Les auteurs ont conclu que la vitesse du vent mesurée sur des sites éloignés est toujours utile.

Alexiadis et al. dans Réf. [25] ont examiné un prédicteur de la vitesse du vent par corrélation spatiale prévisions des valeurs moyennes des 10 ou 1 heure à venir suivantes. Le modèle testé avec données recueillies sur sept ans sur trois sites distants de 52 à 105 km. Les auteurs ont constaté que la prévision de l'énergie éolienne à l'aide de données provenant d'autres sites s'est avérée satisfaisante et bien performé dans leur cas.

En réf. [26] Barbounis et Theocharis (2007), ont utilisé un neurone récurrent local réseau avec dynamique interne comme modèle de prévision basé sur l'utilisation de l'information spatiale à partir de stations de mesure à distance. Le réseau proposé a été testé sur des données réelles collectées sur trois sites distants de 39 km. Le modèle a été examiné pour les étapes multiples prévisions de vitesse du vent à venir de 15 min à 2 heures. Les résultats ont montré que le modèle a surpassé les autres modèles neuronaux et neuro-flous suggérés dans l'étude, et a montré une amélioration de 30 à 35,84% par rapport à la méthode persistante, tandis que les deux autres réseaux réalisés dans une fourchette comprise entre 20-25% et le modèle ARMA est d'environ 16% sur modèle persistant.

Damousis et al. (2004) dans Réf. [27] ont développé un modèle flou basé sur une méthode de corrélation pour prédire la vitesse du vent et la production d'électricité dans un parc éolien. Les entrées dans le modèle comprenaient des données sur la vitesse et la direction du vent mesurées sur les sites voisins jusqu'à 30 km de distance. Le modèle utilisé pour prévoir la vitesse du vent de 30 min à 2 h à venir. Les résultats ont montré que le modèle améliore la précision des prévisions par

rapport à la méthode persistante pour un terrain plat. Cependant, les performances des modèles étaient pires sur un complexe terrain. Les auteurs ont souligné que l'utilisation de l'approche de corrélation spatiale a aidé à améliorer la précision de prédiction de 10 à 25% par rapport au modèle persistant plus que les approches basé uniquement sur les données de séries chronologiques locales.

Bilgili et al. dans Réf. [28] ont développé un modèle basé sur des réseaux de neurones artificiels (ANNs) et corrélation spatiale pour la prédiction de la vitesse moyenne mensuelle du vent cible en utilisant des stations de mesure voisines. Le modèle évalué en utilisant horaire données sur le vent recueilli dans huit stations de mesure au cours de la période 1992-2001. Les résultats des prévisions ont été comparés aux données réelles en utilisant le pourcentage absolu moyen erreur (MAPE), et il s'est avéré qu'il variait de 4,49% à 14,13%. Il a été conclu que la méthode ANN basée sur la vitesse du vent des stations voisines pourrait prédire la disparition donnée de vent des stations cibles sans aucun détail topographique ou autres données météorologiques et la précision de la prédiction en fonction de la corrélation spatiale entre ces stations.

II.7.4 Modèles statistiques

Les modèles statistiques, quant à eux, sont orientés vers les prévisions à très court et court terme [29] : ce seront donc ceux-ci qui sont étudiés dans le cadre du projet. Ils s'entraînent généralement sur des données d'observations historiques, en se basant sur les vitesses de vent prédites et réelles pour ajuster les paramètres du modèle (voir la **Figure II.2**). Certains utilisent les données brutes des modèles de PNT, d'autres non. Comparativement aux approches physiques, l'approche statistique est beaucoup moins exigeante en termes de temps de calcul et de ressources. En effet, comme les processus météorologiques ne sont pas explicitement représentés par des modèles mathématiques complexes, la prévision est plutôt basée sur la reconnaissance de motifs dans le temps [30]. Les deux approches les plus répandues actuellement sont les méthodes conventionnelles basées sur des séries temporelles, ainsi que les méthodes d'apprentissage (machine learning).

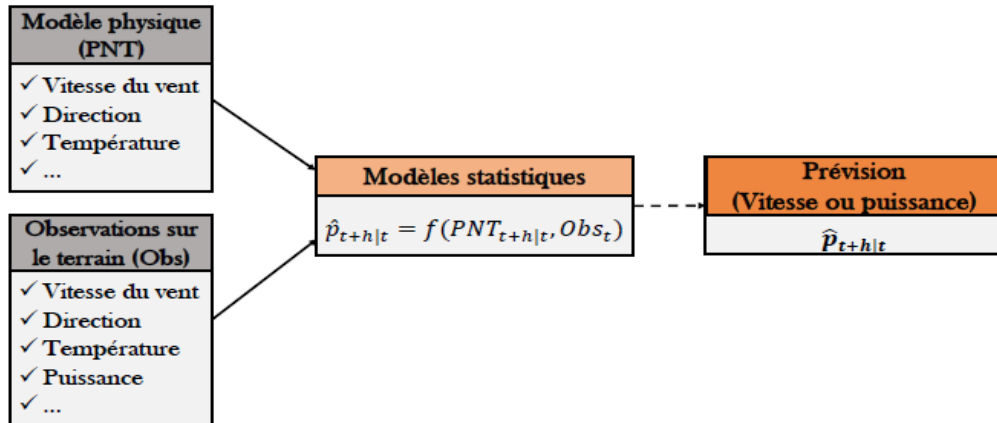


Figure II.2 Utilisation des méthodes statistiques [30]

II.7.4.1 Séries temporelles

Ce type de technique nécessite un ensemble de données historiques en ordre chronologique représentant l'évolution des vitesses de vent dans le temps. Ces informations servent à entraîner les modèles avant de les appliquer. Parmi les plus populaires, on retrouve le modèle Autoregressive Moving Average (ARMA) et ses dérivées. La méthode de la persistance, est considérée comme l'approche la plus simple par série temporelle. Cette approche est purement statistique, c'est-à-dire que l'entraînement est effectué seulement sur des données observées historiques, et aucune information provenant de modèles physiques n'est considérée. La méthode Box-Jenkins propose d'appliquer les modèles Autoregressive (AR), Moving Average (MA), Autoregressive Moving Average ou Autoregressive Integrated Moving Average (ARIMA) afin de déterminer les paramètres correspondant le mieux aux données historiques d'une série temporelle. Le modèle typique ARMA(p, q) d'ordre p (partie autorégressive) et q (partie moyenne mobile) est de la forme suivante :

$$x_t = \sum_{i=1}^p \varphi_i x_{t-i} + \sum_{j=1}^q \theta_j \alpha_{t-j} + \alpha_t \tag{II.5}$$

Où x_t la vitesse du vent prédite au temps t, 'i' est le paramètre autorégressif (AR), j le paramètre de moyenne mobile (MA), et t le bruit blanc normal [31]. Il est possible de retrouver facilement les modèles AR et MA en posant respectivement les paramètres de moyenne mobile (q) et autorégressif (p) égaux à zéro. Si la série temporelle n'est pas stationnaire, la forme ARIMA (p,

d, q), quant à elle, peut être obtenue en différenciant la forme ARMA, d fois, jusqu'à ce que la stationnarité soit atteinte [32].

Milligan et Schwartz ont testé différents modèles ARMA pour un horizon de 6 h sur deux parcs éoliens aux États-Unis. Ils ont testé environ 175 configurations du modèle (différents p et q) et en ont conclu que les résultats sont très dépendants des paramètres du modèle ainsi que de la période d'entraînement. Par exemple pour une période d'entraînement d'un mois en mars, ils n'ont pas obtenu d'amélioration significative par rapport à la persistance pour le mois suivant, alors que pour un entraînement en avril, ils ont pu réduire le RMSE par rapport à la persistance de 11% au mois de mai, pour 6 heures d'horizon. Ils en déduisent qu'une période d'entraînement trop courte pourrait omettre certaines informations importantes pour la précision du modèle : idéalement, elle devrait couvrir au moins une année entière afin de capter les motifs et variations à différents moments de l'année [33]. Torres et coll. ont aussi étudié le modèle ARMA pour 5 sites en Espagne, en déterminant des paramètres spécifiques à chaque site et pour chaque mois de l'année. Ils sont parvenus à réduire le RMSE par rapport à la persistance de 12% à 20% pour un horizon de 10 heures [34].

Les modèles ARMA ont aussi été couplés à d'autres modèles statistiques pour tenter d'améliorer leur précision. Dans [35], une technique utilisant le Improved Time Series Method (ITSM) basé sur un modèle ARIMA a été étudiée. En bref, les modèles sont entraînés sur des séries temporelles qui ont été divisées en sous-séries par décomposition en ondelettes (wavelet decomposition) afin de considérer la non-stationnarité des séries. Une fois les prévisions effectuées pour chaque sous-série, elles sont agrégées afin de calculer la prévision finale. L'étude montre que les prévisions jusqu'à 10 h d'horizon peuvent être améliorées comparativement aux modèles statistiques classiques sans décomposition. D'autres modèles combinant ARIMA et Autoregressive Conditionally Heteroscedastic (ARCH) ont été étudiés, pour prévoir les vitesses de vent, avec et sans décomposition par ondelettes. Dans les deux cas, l'erreur a pu être réduite comparativement au modèle ARIMA traditionnel [36, 37].

En somme, les méthodes de prévisions statistiques classiques sont basées sur le modèle ARMA et ses dérivées. La méthode Box-Jenkins est utilisée pour identifier les meilleurs modèles (p et q) et estimer les paramètres de l'équation **II.4**. Ce sont des outils assez faciles à utiliser, mais qui nécessitent une grande quantité de données pour atteindre une précision raisonnable. Une période d'au moins un an de données est nécessaire pour entraîner les modèles.

Aujourd'hui, avec l'amélioration continue de la précision de la prévision, ces types de modèles sont fréquemment utilisés comme modèle de référence [38].

II.7.4.2 Approches par apprentissage

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

1. Réseaux de neurones artificiels

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

Les RNAs sont parmi les modèles les plus fréquemment utilisés pour la prévision des vitesses de vent et de la puissance [38]. Ils sont entraînés en utilisant une grande quantité de données historiques ainsi que les prévisions brutes issues des PNTs. L'objectif est d'apprendre la relation entre les données brutes du modèle de PNT en entrée (vitesse, direction du vent, température, etc.) et les vitesses de vent ou les puissances mesurées en sortie.

Les réseaux de neurones artificiels sont constitués de plusieurs couches de neurones : une couche en entrée, une couche de sortie, et une ou plusieurs couches cachées (voir la **Figure II.3**).




Figure II.3 Structure d'un réseau de neurones artificiels [38]

Chaque couche peut contenir plusieurs neurones qui sont connectés avec les neurones de couches précédentes, alors que celles qui se trouvent dans la même couche sont indépendantes entre elles. Chacun des neurones possède son propre poids et une fonction de transfert [31].

En général, les réseaux neuronaux performant mieux que les méthodes par séries temporelles [39, 31]. Il existe plusieurs types de RNAs : les Multi-Layer Perceptron (MLP) et les Recurrent Neural Network (RNN) sont parmi les plus couramment étudiés [40].

Au début des années 2000, les études sur les réseaux de neurones artificiels étaient plutôt centrées sur des modèles simples et la comparaison des RNAs aux modèles existants à ce moment. Panteri et coll. ont évalué la performance d'un Radial Basis Function Network (RBfN) à 9 neurones comparativement à la persistance et à un modèle Autoregressive with Exogenous Input (ARX). Ils sont parvenus à des NRMSE (RMSE normalisé sur la puissance nominale du parc) de 5% et 14% pour le RBfN pour des horizons entre de 1 h et 6 h respectivement. Leurs résultats démontrent que les RNAs performant mieux que le modèle ARX, et sont aussi plus précis que la persistance pour des horizons 4 heures et plus [41].

Également, Catalão et coll. ont proposé une approche utilisant un RNA entraîné par la méthode de Levenberg-Marquardt pour la prévision de la puissance au Portugal. Pour un horizon de 24 h, le Mean Absolute Percentage Error (MAPE) moyen sur la puissance est de 19,05% pour la persistance, de 10,34% pour ARIMA, alors que les RNAs surpassent les deux autres modèles avec une moyenne de 7,26%. [42]. Dans [43], un MLP testé sur un site éolien en Espagne a permis de déterminer que l'ajout de la direction comme paramètre d'entrée diminuait le RMSE sur la vitesse de 30% comparativement au modèle non directionnel. Welch et coll. ont comparé plusieurs structures différentes de RNA, soient les MLP, les RNN et les Simultaneous Recurrent Neural Network (SRN). Les modèles récurrents ont montré les meilleures performances, bien que leur plus grande précision implique un temps d'exécution plus élevé que les autres méthodes (soit 55 heures), ce qui peut limiter leur application [44].

Vers la fin des années 2000, des RNAs plus complexes ou combinés à d'autres méthodes ont été davantage étudiés. Dans [45] par exemple, un RNA est combiné à une transformée par ondelettes, ou Wavelet Transform (WT) en anglais. Pour un horizon d'une heure, ils sont parvenus à réduire le MAPE de 32% par rapport à la méthode ARIMA et de 3,6% par rapport au RNA sans WT. De façon similaire, un modèle de RNA combiné à une technique de décomposition des séries temporelles en sous-séries, le Empirical Mode Decomposition (EMD), a permis une amélioration de 35% par rapport à ARIMA, et de 12% comparativement au RNA traditionnel [46].

Dans [47], une combinaison de réseaux RBfN et MLP bonifiés par un Enhanced Particle Swarm Optimization (EPSO) pour l'entraînement a été testée. Un NRMSE de 7,5% a pu être atteint pour un horizon d'une heure, soit une amélioration de 37% par rapport à la persistance. Une autre technique d'optimisation originale, le Chaotic Shark Smell Optimization (CSSO) a permis d'obtenir un RMSE sur la vitesse réduit de 13% par rapport à la méthode ARIMA pour un horizon d'une heure [48].

2. RNA et logique floue

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

Le modèle Adaptive-Network-Based Fuzzy Inference System (ANFIS) proposé en 1993 dans [49] est un modèle ANN-Fuzzy utilisant un Feed-Forward Neural Network à six couches. Il a été étudié à quelques reprises pour des applications de prévision du vent [50, 51]. Dans [51], le NMAE sur la puissance a pu être réduit (en moyenne sur une année) de 68% et de 57% par rapport à la persistance et au modèle ARIMA respectivement, pour un horizon de 3 h. Un modèle ANN-Fuzzy a aussi été développé dans [52], permettant de réduire le NRMSE de 40% par rapport à la persistance pour un horizon de 10 h.

3. Autres modèles

Certains modèles ont été développés de façon plus indépendante. Par exemple, un Grey Predictor (GP) étudié dans [53] utilise les 4 dernières heures de données historiques pour générer des prévisions. Les résultats se montrent encourageants, cependant ils n'ont pas été comparés avec aucune autre méthode existante et peu d'information numérique sur la performance est disponible, ce qui rend difficile leur évaluation. Des approches basées sur des processus gaussiens ont permis de réduire le MAE sur la vitesse du vent entre 12% et 27% par rapport à des modèles de RNA pour des horizons d'une heure [54, 55]. Un Support Sector Machine (SVM) a été étudié dans [56], et a atteint des performances supérieures comparativement au MLP. Plus de 5 ans de données étaient nécessaires pour entraîner le modèle. Finalement, dans [57], 5 approches de data mining ont été comparées : le Support Vector Machine regression (SVMreg), le MLP, le M5P tree, le Reduced

Error Pruning (REP) et le bagging tree algorithm. Au final, il a été conclu que l'approche par RNA (MLP) surpassait toutes les autres. Une nouvelle approche combinant des RNAs ou des SVMs à un système de Lorenz afin de tenir compte des perturbations atmosphériques [58, 59, 60]. Cette approche est prometteuse et permet de réduire significativement l'erreur de prévision comparativement aux RNAs et aux SVMs seuls, cependant les résultats obtenus à ce jour proviennent tous d'un seul et même parc éolien : plus de résultats seraient nécessaires pour démontrer son efficacité.

5. Filtre de Kalman

Le filtre de Kalman a été développé en 1960 par Rudolf E. Kalman, un ingénieur d'origine hongroise naturalisé américain. Il possède plusieurs applications aujourd'hui dans le domaine de l'aérospatiale pour le contrôle et la navigation de véhicules, ainsi qu'en traitement de signal par exemple [61]. En 2006, un premier article fut publié par Galanis et coll. à propos de l'application d'un filtre de Kalman aux prévisions de vent [62]. Ce dernier est conçu pour filtrer les erreurs systématiques des modèles de prévision numérique du temps. Ce sont des algorithmes récursifs qui permettent d'estimer les états d'un système dans le futur en tenant compte d'observations récentes. Ce type de prévisions à court terme se basant sur des données d'observation obtenues en temps quasi réel sont souvent appelées techniques de prévision immédiate, ou nowcasting en anglais. L'avantage du filtre de Kalman est qu'il est adaptatif et nécessite très peu de données historiques pour la calibration initiale.

Dans [63], le filtre de Kalman a été implémenté pour modéliser le biais des PNT comme un polynôme d'ordre 3. Pour un horizon de 24 h, le biais moyen pour la vitesse de vent a pu être réduit de plus de 90% par rapport aux prévisions du modèle physique utilisé. Au niveau de la puissance, les données filtrées présentaient un biais moyen de moins de 20% de la puissance nominale, alors qu'il dépassait 50% pour les prévisions brutes du modèle de PNT. Le filtrage de Kalman a aussi conduit à des améliorations au niveau du RMSE. Les auteurs ont également comparé les résultats obtenus par filtre de Kalman (FK) à des modèles numériques à plus petite échelle. Ils ont pu constater que les données filtrées à partir des modèles numériques à plus grande échelle (12 km) étaient de précision égale ou meilleure aux modèles numériques à haute résolution, qui eux sont très coûteux en termes de ressources informatiques. Dans un autre article, le FK a été testé pour le long terme, avec une actualisation du filtre à toutes les 12 heures. L'erreur absolue a pu être considérablement réduite, alors que l'impact sur le RMSE est plus faible [64].

Un FK a été appliqué sur deux sites en Italie pour un horizon plus court, soit 6 h. L'erreur systématique a pu être éliminée des données de PNT, et le MAE a pu être réduit de 37% par rapport aux prévisions brutes de vitesse du vent du modèle physique. Les résultats montrent à nouveau que la performance des modèles est très dépendante des sites et de la complexité des terrains. Les auteurs suggèrent d'ajuster la procédure de filtrage de façon individualisée pour chacun des sites étudiés [19]. Finalement, dans [65], un FK a été implémenté pour un parc éolien en Chine. Le RMSE sur la vitesse a pu être réduit de 23% comparativement au modèle numérique une fois le filtrage effectué pour un horizon de 24 h.

II.7.4.3 Sommaire des méthodes de prévision statistiques

Le tableau II.2 regroupe les principales caractéristiques des méthodes de prévisions du vent à court terme qui ont été passées en revue dans cette section.

Tableau II.2 Résumé des méthodes statistiques [66]

Catégorie	Méthode	PNT	Particularités
Séries temporelles	Persistence	NON	-Méthode la plus simple, généralement surpassée par les autres méthodes - Souvent utilisée comme référence
	Type ARMA	NON	- 1 an ou plus de données historiques - Moins performante que les méthodes récentes - Facile à implémenter
	Grey Predictor	NON	- Nécessite seulement les dernières 4 heures de données historiques - Moins performante que les méthodes récentes
	Filtre Kalman	OUI	-Nécessite des observations en temps réel - Est adaptatif - Temps de calcul très court - Pas de données historiques nécessaires - Performances similaires aux RNAs - Seule la vitesse du vent est utilisée comme paramètre d'entrée
Apprentissage	RNA, RNA-Fuzzy	OUI	-1 à 5 ans de données historiques - Méthode la plus répandue - Bonnes performances - Considère plusieurs variables météorologiques - Temps de calcul très élevé pour l'entraînement
	SVM	NON	- Performance inférieure aux RNAs
Autres	Corrélation spatiale	NON	- Ne s'applique pas si des données de sites avoisinants ne sont pas disponibles en temps réel

II.7.5 Filtre de Kalman sur la puissance

Une deuxième approche pour corriger les valeurs de puissance pourrait être d'appliquer un filtre de Kalman sur la puissance directement, c'est-à-dire de corriger le biais entre la puissance observée et la puissance prédite à partir des vitesses de vent brutes du modèle de PNT.

Jusqu'à très récemment, l'application d'un filtre de Kalman sur la puissance n'avait pas été explorée. En 2016, dans [67], un filtre de Kalman a été testé selon plusieurs configurations différentes dans le but de prédire la production de puissance : seulement sur la vitesse, seulement sur la puissance, et finalement sur la vitesse et la puissance. Le FK sur la puissance a permis d'améliorer de 23% de RMSE par rapport aux prévisions numériques. Il est à noter que les auteurs ont aussi montré que le filtre utilisé sur la vitesse seulement avait une meilleure performance que celui appliqué sur la puissance seulement. Le filtre appliqué aux deux variables donnait les meilleurs résultats, soit une amélioration de 8% comparativement à celui appliqué sur la vitesse seulement. Somme toute, cet article suggère non seulement que l'ajout d'un deuxième filtre sur la puissance pourrait permettre de réduire les incertitudes introduites par les modèles de courbes de puissance, mais aussi que la correction par FK directement sur la puissance (pour les sites où la donnée de vent n'est pas disponible) donne de bons résultats. Le filtre appliqué dans cette étude corrige le biais comme une constante, et non comme un polynôme, comme il est fait dans [63] pour corriger la vitesse. Il serait donc intéressant d'étudier, pour la prévision de la puissance, les performances de biais modélisés par des polynômes d'ordres plus élevés, en plus d'introduire la direction du vent comme paramètre d'entrée.

II.8 Conclusion

Ce chapitre a présenté la prévision de la vitesse et de la puissance du vent à différentes échelles de temps. Des catégories des méthodes de prévision, qui ont leurs propres caractéristiques, ont été discutées. La diversité des méthodes de prévision et les échelles de temps des méthodes de prévision. Certaines de ces méthodes ont de bonnes performances en matière de prédiction à court terme tandis que d'autres obtiennent de meilleurs résultats dans des prévisions à différentes échelles de temps. Il est difficile d'évaluer les performances de diverses méthodes, car les applications existantes étaient échelle de temps et manière différente. Mais diverses méthodes de prévision du vent sont disponibles dans le système électrique, qui aider les propriétaires de parcs éoliens à identifier leur méthode de prévision du vent selon leurs besoins. Basé sur le développement histoire

de la vitesse et de la puissance du vent, les futures directions de développement de la vitesse et de la puissance du vent des prévisions sont finalement proposées.

Chapitre III : Modèles appliqués sur la prévision de la production éolienne (PPE)

III.1 Introduction

Comme vu à travers la synthèse bibliographique concernant la prévision de production à court terme, parmi les méthodes classiques développées nous avons cité les techniques de régression linéaires simples et multiples.

De plus, nous citons l'une des nouvelles techniques de prévision sont apparues après les années 90, pour être appliquées dans divers domaines. Cette technique appelée : la méthode des réseaux de neurones artificiels, ont montré de très bonnes aptitudes à leur application au problème de prévision de production à courte terme [68].

III.2 Méthode de régression

Parmi les techniques classiques traitées dans le domaine de la prévision en général et dans le problème de la prévision de production dans un réseau électrique à court terme qui nous intéresse, la méthode de régression. La régression est une technique statistique permettant de construire un lien entre une variable explicative (indépendante) et une variable expliquée (dépendante). Le but est soit de prédire la variable expliquée lorsqu'on connaît la variable explicative ou d'établir s'il y a un effet d'une des variables sur l'autre. La méthode de régression sert à déterminer la relation liée la production électrique avec ses facteurs impactant le profil de production d'électricité, tels que la température, humidité ...etc. Il y a des méthodes de régression simple et multiple en terme de variables et des méthodes de régression linéaire et non linéaire en terme de relation entre la production et les variables influençant la courbe de production. Dans ce travail, nous ne nous intéressons qu'aux méthodes de régression linéaires simples et multiples [69].

III.2.1 Méthode de régression linéaire simple

La régression linéaire simple fait intervenir une seule variable explicative pour la variable expliquée et la relation est supposée linéaire. Le modèle de base déterministe pour un ensemble de n observations est donné par l'équation :

$$Y_i = b_0 + b_1 X_i + e_i \quad i = 1, 2 \dots n \quad \text{(III.1)}$$

Y_i : Variable dépendante (expliquée)

X_i : Variable indépendante (explicative)

b_0 : Estimateur standard

b_1 : Estimateur de variable indépendante

e_i : Erreur de la prévision

III.2.1.1 Estimation des paramètres

Dans un premier temps, on cherche à obtenir les paramètres de droite de l'équation (III.1), c'est-à-dire les valeurs des estimateurs b_0 et b_1 . Pour obtenir ces valeurs, la méthode des moindres carrés est utilisée. Le principe est de déterminer les paramètres qui minimisent les écarts entre la droite et les points,

$$S(b_0, b_1) = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (Y_i - b_0 - b_1 X_i)^2 \quad (\text{III.2})$$

La relation (III.2) est strictement convexe. Elle admet donc un minimum unique au (b_0, b_1) , lequel est déterminé en annulant les dérivées partielles de S . On obtient les équations normales :

$$\begin{cases} \frac{\partial S}{\partial b_0} = -2 \sum_{i=1}^n (Y_i - b_0 - b_1 X_i) = 0 \\ \frac{\partial S}{\partial b_1} = -2 \sum_{i=1}^n X_i (Y_i - b_0 - b_1 X_i) = 0 \end{cases} \quad (\text{III.3})$$

La première équation donne :

$$b_0 n + b_1 \sum_{i=1}^n X_i = \sum_{i=1}^n Y_i \quad (\text{III.4})$$

D'où l'on déduit immédiatement :

$$b_0 = \bar{Y} - b_1 \bar{X} \quad (\text{III.5})$$

Où \bar{X} et \bar{Y} sont habituellement les moyennes empiriques des X_i et des Y_i . La seconde équation donne :

$$b_0 \sum_{i=1}^n X_i + b_1 \sum_{i=1}^n X_i^2 = \sum_{i=1}^n X_i Y_i \quad (\text{III.6})$$

Et en remplaçant b_0 par son expression (III.5), nous obtenons :

$$b_1 = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2} \quad (\text{III.7})$$

Un des buts de la régression est de faire de la prévision, c'est-à-dire de prévoir la variable à expliquer y en présence d'une nouvelle valeur de la variable explicative x . Soit donc X_{n+1} une nouvelle valeur de la variable x . Le modèle étant toujours le même, la prédiction de Y_{n+1} est donnée par :

$$Y_{n+1} = b_0 + b_1 X_{n+1} + e_{n+1} \quad (\text{III.8})$$

III.2.1.2 Coefficient de corrélation

La force d'association entre les deux variables est estimée par le coefficient de corrélation (r). Ce coefficient peut aller de -1 à +1. S'il est compris entre 0,8 et 1 (en valeur absolue), la force d'association entre les deux variables est **importante**, entre 0,5 et 0,8 elle est **modérée**, entre 0,2 et 0,5 elle est **faible**, et très faible en dessous. Un signe positif traduit une association positive : la valeur moyenne de y croît avec x . Une association négative traduit l'opposé : la valeur moyenne de y décroît lorsque x croît. On définit alors le coefficient de corrélation noté r comme suite [68]:

$$r = \frac{\sum_{i=1}^n x_i y_i - \frac{1}{n} (\sum_{i=1}^n x_i) (\sum_{i=1}^n y_i)}{\sqrt{\left[\sum_{i=1}^n x_i^2 - \frac{1}{n} (\sum_{i=1}^n x_i)^2 \right] \left[\sum_{i=1}^n y_i^2 - \frac{1}{n} (\sum_{i=1}^n y_i)^2 \right]}} \quad (\text{III.9})$$

III.2.2 Méthode de régression linéaire multiple

La régression multiple est une généralisation de la régression linéaire simple, la différence est qu'il y a plus de variables pour expliquer la variable dépendante. Ainsi pour k variables, le modèle s'écrit :

$$\hat{y} = b_0 + b_1 x_1 + b_2 x_2 + \dots + b_k x_k \quad (\text{III.10})$$

Où Y est un vecteur des valeurs de y et X est une matrice des variables indépendantes x :

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} \text{ et } X = \begin{bmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1k} \\ 1 & x_{21} & x_{22} & \cdots & x_{2k} \\ \vdots & \vdots & & & \vdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{nk} \end{bmatrix} \quad (\text{III.11})$$

Les estimateurs B sont calculés par la matrice :

$$B = [b_0 \quad b_1 \quad b_2 \cdots b_k]^T = (X^T X)^{-1} X^T Y \quad (\text{III.12})$$

Après ce rappel mathématique, on peut appliquer la méthode de régression pour le problème de la prévision de production à court terme. D'abord on utilise la régression linéaire simple en vérifiant l'auto corrélation entre la variable indépendante et celle dépendante, ensuite on va résoudre un problème de prévision multi variables avec la régression linéaire multiple [68].

III.3 Réseaux de Neurones Artificiels

Les réseaux de neurones, conçus de structures cellulaires artificielles, constituent une approche permettant d'aborder sous des angles nouveaux les problèmes de perception, de mémoire, d'apprentissage et de raisonnement. Ils s'avèrent aussi des alternatives très prometteuses pour contourner certaines des limitations des ordinateurs classiques. Grâce à leur traitement parallèle de l'information et à leurs mécanismes inspirés des cellules nerveuses (neurones), ils infèrent des propriétés émergentes permettant de solutionner des problèmes jadis qualifiés de complexes. Nous aborderons dans ce chapitre les principales architectures de réseaux de neurones que l'on retrouve dans la littérature. Il ne s'agit pas de les étudier toutes, car elles sont trop nombreuses, mais plutôt d'en comprendre les mécanismes internes fondamentaux. En ce sens, nous mettrons autant l'emphase sur l'analyse mathématique de ces réseaux que sur la façon de les utiliser dans la pratique pour résoudre des problèmes concrets comme la prévision de production [68].

III.3.1 Objectifs des Réseaux de Neurones

Le cerveau humain contient environ 100 milliards de neurones. Ces neurones nous permettent, entre autre, de lire ce texte tout en maintenant une respiration régulière permettant d'oxygéner notre sang, en actionnant notre cœur qui assure une circulation efficace de ce sang pour nourrir nos cellules, etc. Ils nous permettent même, nous l'espérons, de comprendre les idées que nous tentons de transmettre dans ce mémoire !

Chacun de ces neurones est par ailleurs fort complexe. Essentiellement, il s'agit de tissu vivant et de chimie. Les spécialistes des neurones biologiques (ceux qui œuvrent en neurophysiologie) commencent à peiner à comprendre quelques-uns de leurs mécanismes internes. On croit en général que leurs différentes fonctions neuronales, y compris celle de la mémoire, sont stockées au niveau des connexions (synapses) entre les neurones. C'est ce genre de théorie qui a inspiré la plupart des architectures de réseaux de neurones artificiels. L'apprentissage consiste alors soit à établir de nouvelles connexions, soit à en modifier des existantes. Ceci nous amène à poser une question fondamentale : en se basant sur nos connaissances actuelles, peut-on construire des modèles approximatifs de neurones et les entraîner pour, éventuellement, réaliser des tâches utiles? Eh bien, la réponse courte est «oui», même si les réseaux que nous allons développer ne possèdent qu'une **infime fraction** de la puissance du cerveau humain. Mais avant d'y arriver, faisons un peu d'histoire [68].

III.3.2 Histoire des réseaux de neurones

De nombreux ouvrages ont permis de documenter l'histoire des recherches en réseaux de neurones. En particulier, le livre intitulé «Neurocomputing : Foundations of Research» écrit par John Anderson et Edward Rosenfeld est une compilation de 43 articles qui ont marqué le domaine sur le plan historique. Chacun d'entre eux est d'ailleurs précédé d'une introduction qui permet de situer l'article dans son contexte. Deux ingrédients sont à la base de tout avancement des connaissances. Premièrement, il importe de posséder un nouveau concept, ou un nouveau point de vue à propos d'un sujet, qui vient jeter une lumière là où il n'y avait qu'obscurité. Par exemple, considérons le cœur humain. A différentes époques on le considérait comme le centre de l'âme ou encore comme une source de chaleur. Quelque part au 17^e siècle, les médecins ont commencé à le considérer comme une pompe et ont donc conçu des expériences pour tenter de comprendre son fonctionnement, ce qui a éventuellement permis une compréhension du système sanguin, etc. Sans le concept de pompe, une compréhension du cœur et du système sanguin en général était simplement hors d'atteinte.

Deuxièmement, il importe aussi de posséder des outils technologiques permettant de construire des systèmes concrets. Par exemple, on connaissait les théories physiques permettant d'envisager la conception d'une bombe atomique bien avant d'être capable de réaliser une telle bombe. On savait aussi mathématiquement reconstruire des images de radiographie en coupe (tomographie) bien avant de posséder les ordinateurs et les algorithmes capables d'effectuer efficacement les calculs requis dans un temps raisonnable. L'histoire des réseaux de neurones est

donc tissée à travers des découvertes conceptuelles et des développements technologiques survenus à diverses époques, Brièvement, les premières recherches remontent à la fin du 19e et au début du 20e siècle. Ils consistent en des travaux multidisciplinaires en physique, en psychologie et en neurophysiologie par des scientifiques tels Hermann Von Helmholtz, Ernst Mach et Ivan Pavlov. A cette époque, il s'agissait de théories plutôt générales sans modèle mathématique précis d'un neurone. On s'entend pour dire que la naissance du domaine des réseaux de neurones artificiels remonte aux années 1940 avec les travaux de Warren McCulloch et Walter Pitts qui ont montré qu'avec de tels réseaux, on pouvait, en principe, calculer n'importe quelle fonction arithmétique ou logique. Vers la fin des années 1940, Donald Hebb a ensuite proposé une théorie fondamentale pour l'apprentissage. Nous y reviendrons d'ailleurs à plusieurs reprises dans la suite du mémoire [70].

III.3.3 Applications

Les réseaux de neurones servent aujourd'hui à toutes sortes d'applications dans divers domaines. Par exemple, on a développé un autopilote pour avion, un système de guidage pour automobile, des systèmes de lecture automatique de chèques bancaires et d'adresses postales, des systèmes de traitement du signal pour différentes applications militaires, un système pour la synthèse de la parole, des réseaux pour bâtir des systèmes de vision par ordinateur, des systèmes pour faire des **prévisions** sur les marches monétaires, pour évaluer le risque financier ou en assurance, pour différents processus manufacturiers, pour le diagnostic médical, pour l'exploration pétrolière ou gazière, en robotique, en télécommunications, et j'en passe! Bref, les réseaux de neurones ont aujourd'hui un impact considérable et, il y a fort à parier, que leur importance ira grandissant dans le futur. La première application concrète des réseaux de neurones artificiels est survenue vers la fin des années 1950 avec l'invention du réseau dit «perceptron» par un dénommé Frank Rosenblatt. Rosenblatt et ses collègues ont construit un réseau et démontré ses habilités à reconnaître des formes. Malheureusement, il a été démontré par la suite que ce perceptron simple ne pouvait résoudre qu'une classe limitée de problèmes. A peu près au même moment, Bernard Widrow et Ted Hoff ont proposé un nouvel algorithme d'apprentissage pour entraîner un réseau adaptatif de neurones linéaires, dont la structure et les capacités sont similaires au perceptron.

Vers la fin des années 1960, un livre publié par Marvin Minsky et Seymour Papert est venu jeter beaucoup d'ombre sur le domaine des réseaux de neurones. Entre autres choses, ces deux auteurs ont démontré les limitations des réseaux développés par Rosenblatt et Widrow-Hoff. Beaucoup de gens ont été influencés par cette démonstration qu'ils ont généralement mal interprétée. Heureusement, certains chercheurs ont persévéré en développant de nouvelles

architectures et de nouveaux algorithmes plus puissants. En 1972, Teuvo Kohonen et James Anderson ont développé indépendamment et simultanément de nouveaux réseaux pouvant servir de mémoires associatives.

Dans les années 1980, une pierre d'achoppement a été levée par l'invention de l'algorithme de rétro-propagation des erreurs. Cet algorithme est la réponse aux critiques de Minsky et Papert formulées à la fin des années 1960. C'est ce nouveau développement, généralement attribué à David Rumelhart et James McClelland, mais aussi découvert plus ou moins en même temps par Paul Werbos et Yann Le Cun, qui a littéralement ressuscité le domaine des réseaux de neurones. Depuis ce temps, c'est un domaine où bouillonnent constamment de nouvelles théories, de nouvelles structures et de nouveaux algorithmes [68].

III.4 Modèle d'un neurone

Le modèle mathématique d'un neurone artificiel est illustré à la figure III.1.

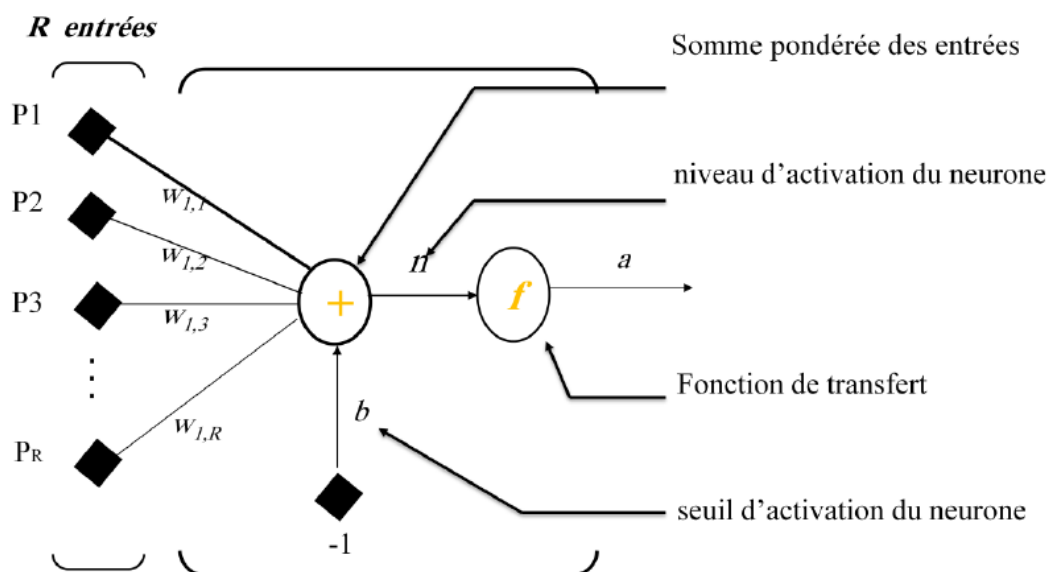


Figure III.1 Modèle d'un neurone artificiel [68]

Un neurone est essentiellement constitué d'un intégrateur qui effectue la somme pondérée de ses entrées. Le résultat n de cette somme est ensuite transformé par une fonction de transfert f qui produit la sortie a du neurone. Les R entrées des neurones correspondent au vecteur

$P = [p_1, p_2, \dots, p_R]^T$, alors que $W = [w_{1,1}, w_{1,2}, \dots, w_{1,R}]^T$ représente le vecteur des poids du neurone. La sortie n de l'intégrateur est donnée par l'équation suivante :

$$n = \sum_{j=1}^R w_{1,j} p_j - b \quad (\text{III.13})$$

Que l'on peut aussi écrire sous forme matricielle :

$$n = W^T p - b \quad (\text{III.14})$$

Cette sortie correspond à une somme pondérée des poids et des entrées moins ce qu'on nomme le biais b du neurone. Le résultat n de la somme pondérée s'appelle le niveau d'activation du neurone. Le biais b s'appelle aussi le seuil d'activation du neurone. Lorsque le niveau d'activation atteint ou dépasse le seuil b , alors l'argument de f devient positif (ou nul). Sinon, il est négatif. On peut faire un parallèle entre ce modèle mathématique et certaines informations que l'on connaît (ou que l'on croit connaître) à propos du neurone biologique. Ce dernier possède trois principales composantes : les dendrites, le corps cellulaire et l'axone (voir figure III.2). Les dendrites forment un maillage de récepteurs nerveux qui permettent d'acheminer vers le corps du neurone des signaux électriques en provenance d'autres neurones. Celui-ci agit comme une espèce d'intégrateur en accumulant des charges électriques. Lorsque le neurone devient suffisamment excité (lorsque la charge accumulée dépasse un certain seuil), par un processus électrochimique,




Figure III.2 Le neurone biologique [68]

On peut distinguer trois parties différentes dans le neurone biologique. La première est le soma, qui contient le noyau de la cellule. La deuxième partie est les dendrites, les prolongements qui reçoivent les signaux en provenance d'autres cellules. La troisième est l'axone, un prolongement unique, qui diffuse le signal émis par le neurone. Ceci est montré dans la figure III.1.

On pourra résumer cette modélisation par le tableau **III.1**, qui nous permet de voir clairement la transition entre le neurone biologique et le neurone formel.

Tableau III.1 Modélisation d'un réseau de neurone biologique [68]

RNB	RNA
Cops cellulaire	Neurone
Dendrite	Entrée (Input)
Axone	Sortie (Output)
Synapse	Poids

RNB: Réseau de Neurone Biologique

RNA: Réseau de Neurone Artificiel




Figure III.3 Représentation matricielle du modèle d'un neurone artificiel [68]

Un autre facteur limitatif dans le modèle que nous nous sommes donnés concerne son caractère discret. En effet, pour pouvoir simuler un réseau de neurones, nous allons rendre le temps discret dans nos équations. Autrement dit, nous allons supposer que tous les neurones sont synchrones, c'est-à-dire qu'à chaque temps t , ils vont simultanément calculer leur somme pondérée

et produire une sortie $a(t) = f(n(t))$. Dans les réseaux biologiques, tous les neurones sont en fait asynchrones. Revenons donc à notre modèle tel que formulé par l'équation (III.14) et ajoutons la fonction d'activation f pour obtenir la sortie du neurone :

$$a = f(n) = f(W^T p - b) \tag{III.15}$$








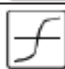
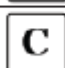
En remplaçant W^T par une matrice $W = W^T$ d'une seule ligne, on obtient une forme générale:

$$a = f(Wp - b) \tag{III.16}$$

III.5 Fonctions de transfert

Jusqu'à présent, nous n'avons pas spécifié la nature de la fonction d'activation de notre modèle. Il se trouve que plusieurs possibilités existent. Différentes fonctions de transfert pouvant être utilisées comme fonction d'activation du neurone sont énumérées au tableau III.2. Les trois les plus utilisées sont les fonctions «seuil» (en anglais «hard limit»), «linéaire» et «sigmoïde». Comme son nom l'indique, la fonction seuil applique un seuil sur son entrée. Les autres fonctions d'activation sont représentées dans le tableau III.2

Tableau III.2 Fonctions de transfert $a = f(n)$ [68]

Nom de la fonction	Relation d'entrée/sortie	Icône	Nom Matlab
seuil	$a = 0$ si $n < 0$ $a = 1$ si $n \geq 0$		hardlim
seuil symétrique	$a = -1$ si $n < 0$ $a = 1$ si $n \geq 0$		hardlims
linéaire	$a = n$		purelin
linéaire saturée	$a = 0$ si $n < 0$ $a = n$ si $0 \leq n \leq 1$ $a = 1$ si $n > 1$		satlin
linéaire saturée symétrique	$a = -1$ si $n < -1$ $a = n$ si $-1 \leq n \leq 1$ $a = 1$ si $n > 1$		satlins
linéaire positive	$a = 0$ si $n < 0$ $a = n$ si $n \geq 0$		poslin
sigmoïde	$a = \frac{1}{1 + \exp^{-n}}$		logsig
tangente hyperbolique	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$		tansig
compétitive	$a = 1$ si n maximum $a = 0$ autrement		compet

Il existe plusieurs types et architectures des réseaux de neurone, on ne s'intéresse que les perceptrons simples, perceptron multicouches et réseau à fonction de base radiale.

III.6 Perceptron simple

Le perceptron simple est illustré par la figure III.4. Il s'agit d'une seule couche de S neurones totalement connectés sur un vecteur p de R entrées. La matrice W de dimension $(S \times R)$ représente l'ensemble des poids de la couche. Le vecteur b de dimensions $(S \times 1)$ désigne l'ensemble des S biais de la couche. Les niveaux d'activation n des neurones de la couche servent d'argument à la fonction d'activation.

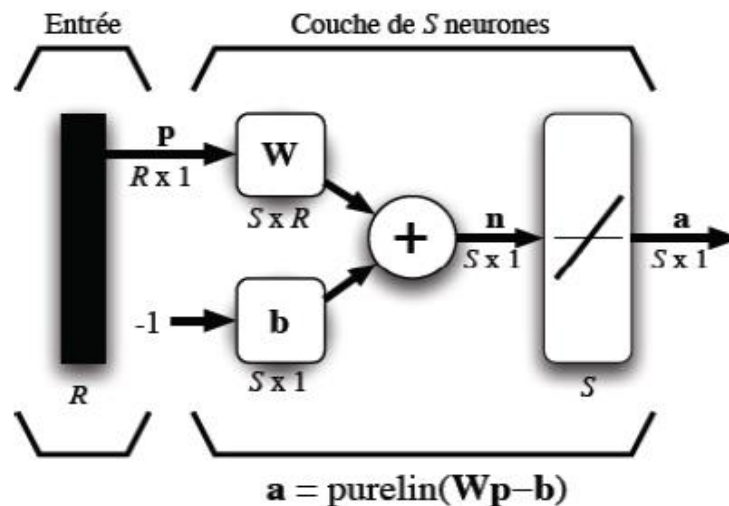


Figure III.4 Perceptron simple ou Réseau ADALINE [68]

III.7 Réseau multicouche

Jusqu'à présent, nous n'avons traité que des réseaux à une seule couche de neurones. Ces réseaux ne pouvaient résoudre que des problèmes de classification linéairement séparables. Les réseaux multicouches permettent de lever cette limitation. On peut même démontrer qu'avec un réseau de trois couches (deux couches cachées + une couche de sortie), comme indiqué par la figure III.5, on peut construire des frontières de décision de complexité quelconque, ouvertes ou fermées, concaves ou convexes, à condition d'employer une fonction de transfert non linéaire et de disposer de suffisamment de neurones sur les couches cachées. Un réseau multicouche n'est rien d'autre qu'un assemblage de couches concaténées les unes aux autres, de la gauche vers la droite, en prenant les sorties d'une couche et en les injectant comme entrées de la couche suivante. Une chose que l'on peut déjà remarquer est qu'il ne sert à rien d'assembler plusieurs couches ADALINE car la

combinaison de plusieurs couches linéaires peut toujours se ramener à une seule couche linéaire équivalente. C'est pourquoi, pour être utile, un réseau multicouche doit toujours posséder des neurones avec fonctions de transfert non-linéaires sur ses couches cachées [68].

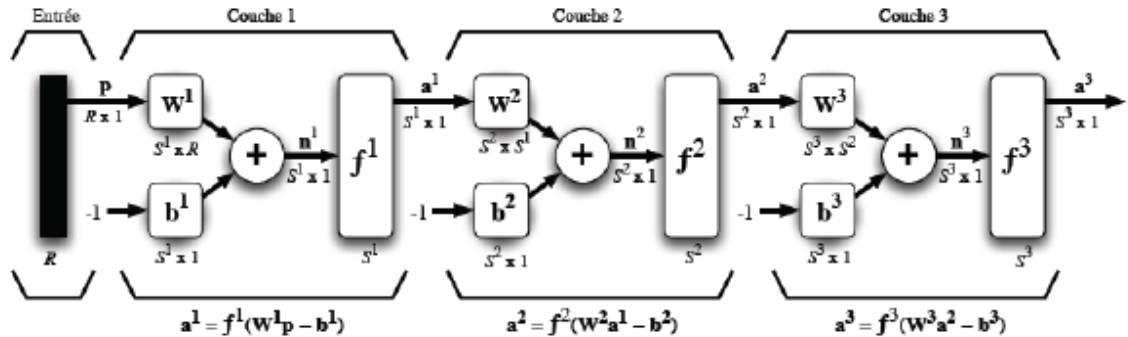


Figure III.5 Représentation matricielle d'un réseau de trois couches [68]

III.7.1 Apprentissage des réseaux de neurones

L'apprentissage est la propriété la plus intéressante des réseaux neuronaux. Durant cette phase, le comportement du réseau est modifié à travers les poids en fonction d'un jeu de données présentées en entrée, jusqu'à l'obtention du comportement désiré. L'apprentissage peut être supervisé ou non supervisé selon la présence ou l'absence de la réponse désirée $d(n)$ comme illustré sur la figure III.6.

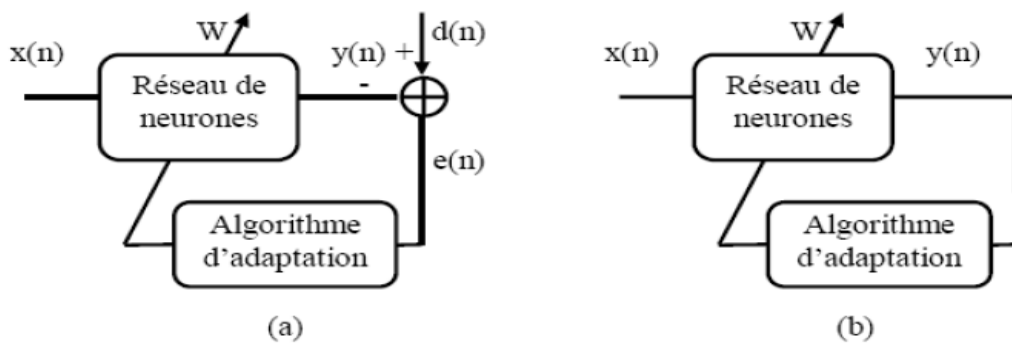


Figure III.6 Mode d'apprentissage des réseaux de neurones (a) supervisé, (b) non supervisé [68]

-Apprentissage supervisé

L'apprentissage est dit supervisé lorsque le réseau est forcé à converger vers un état final précis, ce qui nécessite la connaissance a priori de la réponse désirée $d(n)$. La méthode la plus utilisée est la rétro-propagation du gradient. Elle consiste à présenter des exemples au réseau,

calculer sa sortie, ajuster les poids de façon à réduire l'écart entre cette sortie et la réponse désirée pour satisfaire un certain critère de performance.

- Apprentissage non supervisé

Non supervisé, seules les valeurs d'entrée sont disponibles et le réseau est laissé libre de converger vers n'importe quel état final. La connaissance à priori de la sortie désirée n'est pas nécessaire, la procédure d'apprentissage est basée uniquement sur les valeurs d'entrées. Le réseau s'auto-organise de façon à optimiser une certaine fonction de coût [68].

III.7.2 Rétro-propagation du gradient

Les méthodes de rétro-propagation du gradient firent l'objet de communications dès 1975 (Werbos), puis 1985 (Parker et Cun), mais ce sont les travaux de Rumelhart, Hinton & Williams en 1986 qui suscitèrent le véritable début de l'engouement pour cette méthode. La technique de rétro-propagation du gradient (Back propagation en anglais) est une méthode qui permet de calculer le gradient de l'erreur pour chaque neurone du réseau, de la dernière couche vers la première. De façon abusive, on appelle souvent technique de rétro-propagation du gradient l'algorithme classique de correction des erreurs basé sur le calcul du gradient grâce à la rétro-propagation. En vérité, la correction des erreurs peut se faire selon d'autres méthodes, en particulier le calcul de la dérivée seconde. Cette technique consiste à corriger les erreurs selon l'importance des éléments qui ont justement participé à la réalisation de ces erreurs. Dans le cas des réseaux de neurones, les poids synaptiques qui contribuent à engendrer une erreur importante se verront modifiés de manière plus significative que les poids qui ont engendré une erreur marginale. Ce principe fonde les méthodes de type descente de gradient, qui sont efficacement utilisées dans des réseaux de neurones multicouches comme les perceptrons multicouches. Les descentes de gradient ont pour but de converger de manière itérative vers une configuration optimisée des poids synaptiques. Cet état peut être un minimum local de la fonction à optimiser et idéalement, un minimum global de cette fonction (dite fonction de coût). L'objectif de la méthode de la rétro-propagation est d'adapter les poids de façon à minimiser une fonction de coût donné par [71]:

$$\begin{aligned}
 E(W) &= \sum_{p=1}^T E_p(W) \\
 E_p(W) &= \frac{1}{2} \sum_{i=1}^m [y_i^d(k) - y_i(k)]^2
 \end{aligned}
 \tag{III.17}$$

Où y^d est le vecteur de sortie désiré, $y(k)$ le vecteur de sortie de réseau et T le nombre d'exemples ou longueur de l'ensemble d'entraînement.

$$a_j = \sum_i w_{ji} i_i, z_j = g(a_j) \tag{III.18}$$

La dérivée de la fonction du coût par rapport au poids est donnée par :

$$\frac{\partial E_p}{\partial w_{ji}} = \frac{\partial E_p}{\partial a_j} \frac{\partial a_j}{\partial w_{ji}} = \delta \frac{\partial a_j}{\partial w_{ji}} = \delta z_i, \delta = \frac{\partial E_p}{\partial a_j} \tag{III.19}$$

Pour la couche de sortie :

$$\delta_k = \frac{\partial E_p}{\partial a_k} = \frac{\partial E_p}{\partial y_k} g'(a_k) \tag{III.20}$$

Pour les couches cachées :

$$\delta = \frac{\partial E_p}{\partial a_j} = \sum_k \delta_k \frac{\partial a_k}{\partial a_j} \tag{III.21}$$

Donc l'expression de rétro-propagation d'erreur s'écrit sous la forme :

$$\delta_j = g'(a_j) \sum_k w_{kj} \delta_k \tag{III.22}$$




Figure III.7 Retro-propagation de l'erreur

L'adaptation des poids se fait par la méthode du gradient basée sur la formule itérative suivante :

$$w_{ji}^{(k+1)} = w_{ji}^{(k)} - \eta \frac{\partial E}{\partial w_{jt}} \tag{III.23}$$

Où k : représente le numéro d'itération.

η : est une constante appelée le taux ou le pas d'apprentissage. La vitesse de convergence dépend de la constante η , sa valeur est généralement choisie expérimentalement.

III.8 Le réseau à fonction de base radiale RBF

Le réseau RBF est un réseau de neurones supervisé. Il s'agit d'une spécialisation d'un réseau multicouches ou Perceptron Multi Couches (PMC). Un RBF est constitué uniquement de 3 couches:

- La couche d'entrée : elle retransmet les inputs sans distorsion.
- La couche RBF : couche cachée qui contient les neurones RBF.
- La couche de sortie : simple couche qui contient une fonction linéaire.

La couche cachée, constituée des noyaux (ou neurones) RBF effectue une transformation non linéaire de l'espace d'entrée. La couche de sortie calcule une combinaison linéaire des sorties de la couche cachée. Chaque noyau élémentaire calcule la distance entre l'entrée et son centre qu'il passe ensuite dans une non linéarité concrétisée par une fonction d'activation $\phi(\cdot)$ qui est généralement de type gaussienne [47]. La valeur que prend la sortie du noyau gaussien est d'autant plus importante que l'entrée est plus proche de son centre et tend vers zéro, lorsque la distance entrée centre devient importante. La sortie du réseau RBF est donnée par :

$$y_i = \sum_{k=1}^{N1} w_{kj} \phi_k(\|x - c_k\|) \quad (\text{III.24})$$

$$\phi(e) = \exp\left(-\frac{e^2}{2\alpha^2}\right)$$

$\|\cdot\|$ dénote la norme euclidienne, x le vecteur d'entrée, c_k est le centre associé au noyau k . $N1$ le nombre de noyaux de la couche cachée et w_{kj} les poids associés à la couche de sortie. Le paramètre α permet de contrôler la vitesse de décroissance de la fonction ϕ [68].




Figure III.8 Réseau RBF avec fonctions radiales gaussiennes [68]

III.9 Conclusion

Dans ce chapitre, nous avons donné en détail les méthodes de prévisions comme la méthode classique qui représenté par la méthode de régression simple, multiple et la technique des réseau des neurones artificiels pour l'appliquer dans le prochaine chapitre qui contient la simulation de ces méthodes et l'analyse des résultats.

Chapitre IV : Simulations et Analyses des Résultats

IV.1 Introduction

Nous allons présenter dans ce chapitre les résultats d'étude prévisionnelle de la production d'électricité de la centrale éolienne de Kabertène à Adrar, par la méthode de régression simple, multiple et la technique des réseaux des neurones artificiels sous l'environnement du logiciel MATLAB et en citant les interprétation à la fin de ce chapitre.

IV.2 Centrale éolienne D'Adrar

Dans notre cas d'étude sur cette centrale, nous allons étudier leur situation, potentiel,

IV.2.1 Situation

La ville d'Adrar se trouve au Sud - Ouest de l'Algérie, à environ 1540 km d'Alger. La région est caractérisée par sa topographie relativement plate, ainsi que par une géomorphologie désertique. Adrar et ses alentours sont caractérisés par un fort potentiel de vent venant du Nord Est. Les données de vent de la région d'Adrar classent cette dernière comme celle présentant le meilleur potentiel de vent en Algérie [72].

IV.2.2 Potentiel éolien à Adrar

L'étude du potentiel éolien de la région d'Adrar est basée sur les vitesses horaires de vent de la période 2003-2008 mesurées par l'ONM. La station de mesure est placée à l'aéroport d'Adrar, ses coordonnées géographiques sont 27,82°N et -0,18°E; l'anémomètre est placé à une hauteur de 10 m. Les mesures disponibles sont des mesures horaires effectuées sur une période de six (6) années (2003 - 2008). Elles ont permis de tracer les variations journalière, mesuelle et annuelle de la vitesse moyenne du vent.



Figure IV.1 Carte d'Algérie [72]

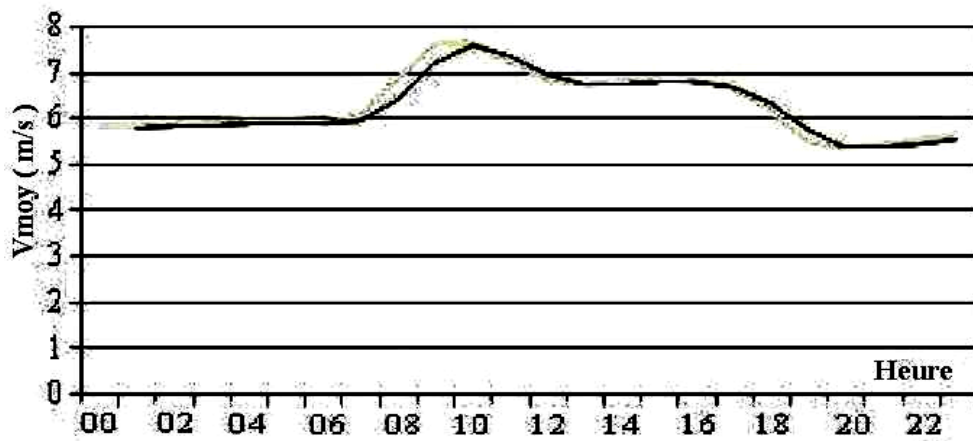


Figure IV.2 Variation journalière de la vitesse moyenne du vent [72]

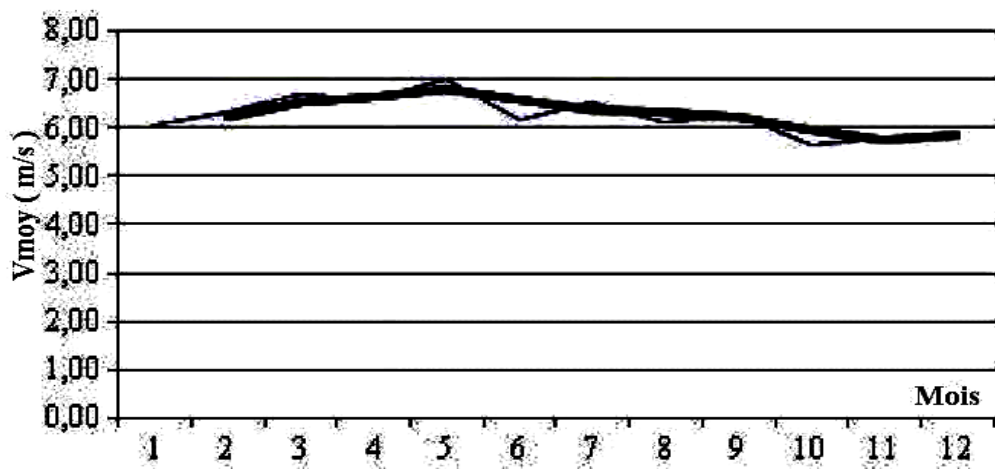


Figure IV.3 Variation mensuelle de la vitesse moyenne du vent [72]




Figure IV.1 Variation annuelle de la vitesse moyenne du vent [72]




Figure IV.5 Situation du site de Kabertène [72]

Ce site se trouve à environ 73 km au Nord de la ville d'Adrar à proximité d'un poste électrique de Sonelgaz. Il se trouve à une altitude d'environ 260 m et ses coordonnées géographiques sont 28°27' 7.28" N 0°02' 59.08" W.

IV.2.3 Etude prévisionnelle de la centrale éolienne de Kaberten

En étudie la dépendance de la production d'électricité de type éolienne sur la variable décrit la vitesse de vent et la température. La base de données sur l'évolution de la production d'électricité en termes de vitesse du vent et de température figurant dans **Tableau IV.1** représente un échantillon de la période du 15/01/2016 au 31/12/2016 avec un pas de temps de 01 heure.

Tableau IV.1: un échantillon de la base des données

Date	HEURE	Puissance Total (kW)	Temp. amb. °C	Vit. moy. Du vent (m/s)
15/01/2016	01:00	442	14	8
15/01/2016	02:00	309	12	7
15/01/2016	03:00	408	11	8
15/01/2016	04:00	363	12	7
-	-	-	-	-
-	-	-	-	-
16/01/2016	03:00	1	18	3
16/01/2016	04:00	100	15	5
16/01/2016	05:00	286	13	7
16/01/2016	06:00	484	15	8
16/01/2016	07:00	746	13	10
16/01/2016	08:00	455	11	8
-	-	-	-	-
-	-	-	-	-

IV.3 Outil de simulation

Nous allons modéliser la méthode de régression simple, multiple et la technique des réseaux des neurones artificiels sous l'environnement du logiciel MATLAB.

La simulation à l'aide de MATLAB est tout à fait justifiable en raison de ses divers avantages uniques comme la facilité et l'efficacité de programmation élevées, l'interface graphique élégante et son architecture nouvelle permettant l'adaptation à un grand nombre de cas.

IV.4 Application de la régression linéaire simple dans la PPCT :

Nous avons expliqué précédemment l'intérêt d'application de la régression simple dans les problèmes de prévision, ainsi dans notre domaine de prévision de production à court terme. On va étudier la corrélation entre la production (variable dépendante) et la température (la variable indépendante), puis on va produire des prévisions suivant une base d'observation.

IV.4.1 Prévision de production par régression simple à base des données des températures

Puisque la production électrique sensible à des variations sur les températures, la prévision de production à court terme dépende de valeurs de températures, dans ce cas la température est la variable explicative, alors on vérifie l'association entre la production d'électricité et la variation des valeurs de températures par le coefficient de corrélation définie dans l'équation **(III.9)**. La figure **IV.6** illustre le degré de corrélation entre la production et la température.




Figure IV.6 Corrélation entre la production et la température

L'équation qui modélise la relation entre la production et la température, s'écrit :

$$P_i = 495.7730 - 6.4746 T_i + e_i \quad (\text{IV.1})$$

On remarque que la droite de régression passe dans le centre de gravité de nuage qui représente la relation entre la production électrique et la température, également on note que les points d'observations sont éloignés de la droite de régression traduit par le coefficient de corrélation $r = - 0.1855$, cette valeur signifie que La force d'association entre la production d'électricité et la température est **faible** et le signe (-) indique que l'association est négative traduit l'opposé: la valeur moyenne de la production d'électricité augmente lorsque la température diminue, évidemment cette valeur impacte directement l'écart de prévision traduit dans la figure **IV.6**




Figure IV.7 Courbe de production en utilisant la température comme une variable indépendante

Suivant cette figure, on constate que le coefficient de corrélation a un effet directe sur l'erreur de prévision malgré que la température est une variable explicative, par conséquent la température n'est pas le seul facteur qui impacte le comportement de production, mais il y'a d'autre facteurs.

IV.4.2 Prévision de production par régression simple à base des données des vitesses des vents

Puisque la production électrique sensible à des variations sur des vitesses des vents, la prévision de production à court terme dépende de valeurs des vitesses des vents, dans ce cas c'est la variable explicative. Donc au lieu d'utiliser la température comme une variable indépendante on va introduire les valeurs des vitesses, ensuite on va utiliser le coefficient de corrélation pour avoir une information sur la force d'association entre la production et les vitesses des vents.

La figure IV.8 représente la droite de régression et la corrélation entre la production d'électricité actuelle et celle d'heure précédente.




Figure IV.8 Corrélation entre la production et la vitesse de vent

L'équation qui modélise la relation entre la production et la vitesse, s'écrit :

$$P_i = -354.7299 + 91.5752 V_i + e_i \quad (\text{IV.2})$$

La force de corrélation entre la production d'électricité et la température est faible, par contre la force d'association entre la production électrique et la vitesse de vent est **très forte**, ce qui est montré dans la figure **IV.8**. On remarque que le nuage qui représente la relation entre la production et la vitesse s'accumule autour de la droite de régression, le coefficient de corrélation $r = 0.9147$ explique l'intensité de corrélation et le signe positif de cette valeur exprime la relation proportionnelle de la production avec la vitesse de vent. Ça veut dire que lorsque la vitesse augmente la production augmente. Nécessairement le coefficient de corrélation fort va améliorer l'erreur relative moyenne absolue de prévision. La figure **IV.9** montre la production journalière réalisée et la vitesse de vent.




Figure IV.9 Courbe de production en utilisant la vitesse de vent comme variable indépendante

On peut dire que le comportement de la production électrique suit les variations sur les températures durant la journée par opposition avec un coefficient de corrélation faible, cependant la production d'électricité suit les variations sur la vitesse des vents avec un coefficient de corrélation très fort et avec une relation proportionnelle.

On a étudié seulement une variable explicative soit la température soit la vitesse des vents traitées par la méthode de régression linéaire simple, mais si on veut introduire les deux variables à la fois, on est obligé d'utiliser la méthode de régression linéaire multiple.

IV.5 Application de la régression linéaire multiple dans la PPCT

Comme la méthode de régression linéaire simple est une technique qui modélise la relation entre la variable expliquée et la variable explicative, la méthode de régression linéaire multiple est juste une généralisation de cette dernière pour plusieurs variables explicatives, dans le problème de la prévision de production à court terme la variable dépendante est la vitesse des vents, et les variables explicatives sont la température, humidité, ...etc.

- **Régression multiple de la vitesse des vents et de la température**

On a modélisé la relation entre la production électrique et la température par une régression linéaire simple, ainsi que le modèle de corrélation de la production et la vitesse des vents. Par la régression linéaire multiple, on peut modéliser à la fois la relation entre la production d'électricité et ses variables indépendantes, de température et de la vitesse des vents, l'équation s'écrit :

$$P_i = b_0 + b_1 V_i + b_2 T_i + e_i \quad (\text{IV.1})$$

Ou :

P_i : Production d'électricité.

V_i : Vitesse moyen des vents

T_i : Température

e_i : Erreur entre la production réalisée et celle désirée

b_0, b_1, b_2 : Estimateurs.

Ensuite on calcule les estimateurs des variables indépendants b_0, b_1, b_2 suivant l'équation :

$$P_i = 249.2713 + 90.6271 V_i - 3.4260 T_i + e_i \quad (\text{IV.3})$$

Après de la détermination de ce modèle de régression linéaire multiple, on peut tracer le graphe de la production journalière réalisée et celle observée dans la figure **IV.10**




Figure IV.10 Production réalisée par la régression multiple en introduisant la température et la vitesse du vent.

D'après la figure IV.10 et les valeurs d'erreur relative moyenne absolue, on note que l'écart entre la production prévue et la production réalisée est acceptable, mais l'erreur obtenue par la méthode de régression simple en utilisant seulement la vitesse des vents est mieux que l'erreur obtenue par la méthode de régression multiple.

IV.6 Prédiction de production à court terme en utilisant les réseaux de neurones

L'une des applications des techniques des réseaux de neurones est le problème de la prédiction de production, puisque ces techniques n'exigent pas de modèle mathématique. Nous utiliserons une base de données comportant des entrées comme la vitesse du vent, le type de jour et heure et des sorties comme production désirées. Nous appliquerons l'architecture de réseaux de neurones nommé : perceptron simple.

IV.6.1 Prédiction de production avec le perceptron simple

Nous utilisons différentes échantillons de la base de données pour les appliquer par l'architecture perceptron simple et nous exposons les résultats de prédiction journalière de production pour chaque période.

- **Echantillons de 2566 heures (points d'observation)**




Figure IV.11 prévision d'échantillons de 2566 heures

- **Echantillons de 3066 heures (points d'observation)**




Figure IV.12 Prévision d'échantillons de 3066 heures

- **Echantillons de 2160 heures (points d'observation)**




Figure IV.13 Prévission d'échantillons de 2160 heures

IV.6.2 Erreur de prévission pour déférentes échantillons

Nous citons dans le **tableau IV.2** Erreur de prévission pour déférentes période.

Tableau IV.2 Erreur de prévission par perceptron simple pour déférente période.

Nbr des Obs (hr)	EMAP(%)
2165	1.0870
2566	0.4431
3066	0.4610

Nous avons remarquées que l'erreur relative moyenne absolue de prévission est faible pour déférente période de la base de données qui montre l'efficacité de la prévission de la production électrique éolienne par la méthode du perceptron simple.

IV.7 Comparaison des résultats des méthodes

En comparant les résultats obtenus dans ce chapitre, nous constatons que la prévision de la production de l'électricité éolienne à l'aide de la technique des réseaux de neurones artificiels est mieux que la prévision par la méthode de régression linéaire.

IV.8 Conclusion

Dans ce chapitre, nous avons utilisées la méthode classique représentée par la méthode de régression, et une autre technique basées sur l'intelligence artificielle comme la technique des réseaux des neurones, pour résoudre le problème de la prévision de production à court terme.

La méthode de régression, se base sur la modélisation de la relation liant la production à des variables indépendantes comme la vitesse des vents et la température. Deux méthodes de régression ont été étudiées, la régression linéaire simple et la régression linéaire multiple.

Concernant la régression linéaire simple, nous avons proposé deux modèles. Le premier comporte la température comme variable explicative ou indépendante, et avant de prévoir la production, nous avons déterminé le facteur de corrélation qui donne une information sur la force d'association entre la variable dépendante (production) et celle indépendante (température). La valeur de cette force de corrélation est faible, il n'y a aucun impact sur l'erreur moyenne de prévision. Le deuxième modèle contient la vitesse des vents comme variable indépendante au lieu de la température et la force de corrélation entre la production et la vitesse étant très forte, l'erreur de prévision est un peu petite.

La méthode de régression linéaire multiple, à la différence de la régression simple, peut modéliser une relation entre la production et plusieurs variables indépendantes comme la température et la vitesse des vents en réalisant une erreur de prévision acceptable et un peu plus grand par rapport à l'erreur de la régression simple qui comporte une variable explicative (vitesse).

Nous aurions pu obtenir des valeurs de l'erreur moyenne de prévision, plus petites que celles que nous avons obtenues, si la base de données avait été précise, mais en raison de la présence de lacunes dans cette dernière, où il y a un nombre important des données de la température, la vitesse du vent et la production qui n'ont pas été enregistré, ce qui a influencé sur la précision des résultats de prévision.

La prévision de production éolienne à courte terme par la technique des réseaux de neurones comme le perceptron simple donne des bons résultats par rapport les résultats du prévision de la régression linéaire.

Conclusion générale

La transition énergétique est devenue incontournable pour répondre aux besoins croissants en énergie, atténuer les risques liés à la volatilité des prix du pétrole et la tendance à la baisse des réserves des énergies fossiles qui affectent les marchés. Les énergies renouvelables contribuent à répondre aux besoins énergétiques actuels pour soutenir une croissance durable.

Dans notre étude, nous avons utilisé les données journalières par une heure de la production d'électricité des éoliennes et des variables climatiques : la vitesse moyenne du vent et la température de la centrale éolienne de Kaberten d' Adrar pour tester des modèles de prévision de cette production.

Au cours de ce travail, nous avons traité le problème de prévision de la production électrique d'énergies éolienne à court terme par la méthode classique et la technique d'intelligence artificielles à court terme.

La méthode classique appliquée à la prévision de production est méthode de régression, on a étudié. Deux méthodes de régression sont appliquées : la régression linéaire simple et multiple, la régression simple ne prend qu'une seule variable indépendante comme la vitesse du vent.

Afin d'appliquer la prévision par la régression multiple, nous avons introduit la température et la vitesse du vent à la fois, mais l'erreur de prévision par la régression simple est mieux que celle de régression multiple, cependant les méthodes classiques ne peuvent pas prévoir la production des jours anomaux, ce qui fait que l'on a besoin des techniques d'intelligence artificielle qui n'exige le modèle mathématique comme la technique de réseau de neurone.

La prévision de production à court terme par la technique de réseau de neurone pour une journée en utilisant différentes échantillons de la base de données donnent des bons résultats de prévision, où l'erreur est faible.

Perspectives :

- Autre facteurs influencent la courbe de production peuvent être pris en considération tels que l'humidité, la pression et la direction du vent.
- Proposition d'autres architectures de réseau de neurones pour la prévision.
- Prévision par la technique de logique flou.

BIBLIOGRAPHIE

[1] **Hammoudi Meriem et Kouihal Fatima** « *Prévision de la production d'électricité de type Energies Renouvelables Cas : éolienne et photovoltaïque* », Mémoire Master, Université M'hamed Bougara Boumerdes 2016.

[2] **BELFEDAL Chiekh**, "*Commande d'une machine asynchrone à double alimentation en vue de son application dans le domaine de l'énergie éolienne*", Thèse de Doctorat, Université des sciences et Technologies d'Oran, 2007.

[3] **KHALED FERKOUS** « *ETUDE D'UNE CHAINE DE CONVERSION D'ENERGIE EOLIENNE* », Mémoire MAGISTER EN PHYSIQUE, UNIVERSITE MENTOURI CONSTANTINE, 2009

[4] **Historique des éoliennes**

<http://www.lei.ucl.ac.be/multimedia/eLEE/FR/realisations/EnergiesRenouvelables/index.htm>

[5] **EL AIMANI Salma**, "*Modélisation des différentes technologies d'éoliennes intégrées dans un réseau de moyenne tension*", Thèse doctorat, école centrale de Lille 2014.

[6] "*les exploiters de l'énergie, l'énergie éolienne*",

<http://www.explorateurs-energie.com/index.php/les-energies/eolienne>.

[7] "*Installation d'éolienne*",

<https://www.quelleenergie.fr/questions/difference-eolienne-verticale-horizontale>

[8] "*Les différents types d'éoliennes*", <https://eolienne.ooreka.fr/comprendre/>

[9] **ZERARI Naziha**, "*Modélisation et optimisation multi objectifs d'une éolienne à axe horizontal d'un système de production éolien isolé de petite taille*", Thèse doctorat, Université Badji Mokhtar-Annaba, 2015.

[10] "*Composantes d'une éolienne*",

<https://www.connaissancedesenergies.org/quels-sont-les-constituants-d-une-eolienne-130125>.

[11] “Centre de développement des énergies renouvelables, l'énergie éolienne”

<https://www.cder.dz/>

[12] **NOUREDINE Hadjsaïd**, “Les réseaux électriques de distribution de la production décentralisée aux Smart Grids”, Edition: Lavoisier, 2010.

[13] “Grid connexion”,

http://www.i15.p.lodz.pl/strony/EIC/res/Grid_connection_wind_power.html

[14] **HELOÏSE Dutrieux**, “Méthodes pour la planification pluriannuelle des réseaux de distribution. Application à l'analyse technico-économique des solutions d'intégration des énergies renouvelables intermittentes”, Thèse de doctorat, école centrale de Lille, 2015.

[15] **Herman Bayem**, “Apport des méthodes probabilistes aux études d'intégrations des énergies renouvelables aux systèmes électriques”, Thèse de doctorat, Ecole Doctorale des Sciences et Technologies de l'information, des Télécommunications et des systèmes d'Orsay ,2009.

[16] **NAWA Hacenna** « Intégration des énergies éoliennes dans le réseau électrique », Mémoire Master, Université Guelma 2019

[17] *A Literature Review of Wind Forecasting Methods*

https://www.scirp.org/pdf/JPEE_2014041616192284.pdf

[18] **MAKHLOUFI Saida**, « Prévission de la ressource éolienne », Division Energie Eolienne - CDER

[19] **Soman, S.S., Zareipour, H., Malik, O. and Mandal, P.** (2010) *A Review of Wind Power and Wind Speed Forecasting Methods with Different Time Horizons*. Proceedings of the 2010 North American Power Symposium, Arlington, 26-28 September 2010, 1-8. <http://dx.doi.org/10.1109/NAPS.2010.5619586>

[20] **L. Landberg, G. Giebel, H. A. Nielsen, T. Nielsen, et H. Madsen**, “Short-term prediction - An overview”, Wind Energy, vol. 6, no. 3, pp. 273–280, 2003. DOI : 10.1002/we.96

[21] “Données numériques haute résolution - Ensemble SPENA- Format GRIB2”, https://meteo.gc.ca/grib/grib2_glb_25km_f.html, Avr. 2013.

- [22] **G. Kariniotakis, J. Halliday, R. Brownsword, I. Marti, A. Palomares, I. Cruz, H. Madsen, T. Nielsen, H. Nielsen, U. Focken, M. Lange, G. Kallos, P. Louka, N. Hatzargyriou, P. Frayssinet, H.-P. I. Waldl, F. Dierich, G. Giebel, R. Barthelmie, et D. Garrett**, *Next Generation Short-Term Forecasting of Wind Power – Overview of the ANEMOS Project.*, Fév. 2006, vol. 3.
- [23] *Analyse de régression*
- https://fr.ryte.com/wiki/Analyse_de_régression
- [24] **M. C. Alexiadis, P. S. Dokopoulos and H. S. Sahsamanoglou**, "Wind speed and power forecasting based on spatial correlation models," *IEEE Trans, on Energy Conversion*, vol. 14, no. 3, pp. 836-842, 1999.
- [25] **M. C. Alexiadis, P. S. Dokopoulos, H. S. Sahsamanoglou and I. M. Manousaridis**, "Short-term forecasting of wind speed and related electrical power," *Solar Energy*, Elsevier Science Ltd., vol. 63, no. 1, pp. 61-68, Jul. 1998.
- [26] **T. G. Barbounis and J. B. Theocharis**, "Locally recurrent neural networks for wind speed prediction using spatial correlation," *Inf. Set*, Elsevier Science Inc., vol. 177, no. 24, pp. 5775-5797, Dec. 2007.
- [27] **I. G. Damousis, M. C. Alexiadis, J. B. Theocharis and P. S. Dokopoulos**, "A fuzzy model for wind speed prediction and power generation in wind parks using spatial correlation," *IEEE Trans, on Energy Conversion*, vol. 19, no. 2, pp. 352-361, 2004.
- [28] **M. Bilgili, B. Sahin and A. Yasar**, "Application of artificial neural networks for the wind speed prediction of target station using reference stations data," *Renewable Energy*, Elsevier Science Inc., vol. 32, no. 14, pp. 2350-2360, Nov. 2007.
- [29] **M. Negnevitsky et C. W. Potter**, "Very Short-Term Wind Forecasting for Tasmanian Power Generation", vol. 21, no. October, pp. 965–972, Mai 2006. DOI : 10.1109/TPWRS.2006.873421

- [30] **A. Tascikaraoglu et M. Uzunoglu**, “*A review of combined approaches for prediction of short-term wind speed and power*”, *Renewable and Sustainable Energy Reviews*, vol. 34, pp. 243–254, 2014. DOI : 10.1016/j.rser.2014.03.033
- [31] **M. Lei, L. Shiyan, J. Chuanwen, L. Hongling, et Z. Yan**, “*A review on the forecasting of wind speed and generated power*”, *Renewable and Sustainable Energy Reviews*, vol. 13, no. 4, pp. 915–920, 2009. DOI : 10.1016/j.rser.2008.02.002
- [32] **A. Sfetsos**, “*A comparison of various forecasting techniques applied to mean hourly wind speed time series*”, *Renewable Energy*, vol. 21, no. 1, pp. 23–35, 2000. DOI : 10.1016/S0960-1481(99)00125-1
- [33] **M. Milligan, M. Schwatz, et Y. Wan**, “*Statistical Wind Power Forecasting Models : Statistical Wind Power Forecasting Models : Results for U . S . Wind Farms*”, National Renewable Energy Laboratory, no. January 2003, 2003.
- [34] **J. L. Torres, A. García, M. De Blas, et A. De Francisco**, “*Forecast of hourly average wind speed with ARMA models in Navarre (Spain)*”, *Solar Energy*, vol. 79, no. 1, pp. 65–77, 2005. DOI : 10.1016/j.solener.2004.09.013
- [35] **H. Liu, H.-Q. Tian, C. Chen, et Y.-f. Li**, “*A hybrid statistical method to predict wind speed and wind power*”, *Renewable Energy*, vol. 35, no. 8, pp. 1857–1861, Août 2010. DOI : 10.1016/j.renene.2009.12.011
- [36] **P. Lv et L. Yue**, “*Short-term wind speed forecasting based on non-stationary time series analysis and ARCH model*”, dans 2011 International Conference on Multimedia Technology, Juil. 2011, pp. 2549–2553. DOI : 10.1109/ICMT.2011.6002447
- [37] **M.-D. Wang, Q.-R. Qiu, et B.-W. Cui**, “*Short-term wind speed forecasting combined time series method and arch model*”, dans 2012 International Conference on Machine Learning and Cybernetics, vol. 3, Juil. 2012, pp. 924–927. DOI : 10.1109/ICMLC.2012.6359477
- [38] **Jung et R. P. Broadwater**, “*Current status and future advances for wind speed and power forecasting*”, *Renewable and Sustainable Energy Reviews*, vol. 31, pp. 762–777, Mars 2014. DOI : 10.1016/j.rser.2013.12.054

- [39] **S. S. Soman, H. Zareipour, O. Malik, et P. Mandal**, “A review of wind power and wind speed forecasting methods with different time horizons”, North American Power Symposium (NAPS), pp. 1–8, 2010. DOI : 10.1109/NAPS.2010.5619586
- [40] **A. M. Foley, P. G. Leahy, A. Marvuglia, et E. J. McKeogh**, “Current methods and advances in forecasting of wind power generation”, Renewable Energy, vol. 37, no. 1, pp. 1–8, 2012. DOI : 10.1016/j.renene.2011.05.033
- [41] **E. Panteri et S. Papathanassiou**, “Evaluation of two simple wind power forecasting models”, ResearchGate, Jan. 2008.
- [42] **J. P. S. Catalão, H. M. I. Pousinho, et V. M. F. Mendes**, “An Artificial Neural Network Approach for Short-Term Wind Power Forecasting in Portugal”, dans 2009 15th International Conference on Intelligent System Applications to Power Systems, Nov. 2009, pp. 1–5. DOI : 10.1109/ISAP.2009.5352853
- [43] **P. López, R. Velo, et F. Maseda**, “Effect of direction on wind speed estimation in complex terrain using neural networks”, Renewable Energy, vol. 33, no. 10, pp. 2266–2272, 2008. DOI : 10.1016/j.renene.2007.12.020
- [44] **R. L. Welch, S. M. Ruffing, et G. K. Venayagamoorthy**, “Comparison of feedforward and feedback neural network architectures for short term wind speed prediction”. IEEE, Juin 2009, pp. 3335–3340. DOI : 10.1109/IJCNN.2009.5179034
- [45] “Short-term wind power forecasting in Portugal by neural networks and wavelet transform”, Renewable Energy, vol. 36, no. 4, pp. 1245–1251, 2011. DOI : 10.1016/j.renene.2010.09.016
- [46] **H. Liu, C. Chen, H.-q. Tian, et Y.-f. Li**, “A hybrid model for wind speed prediction using empirical mode decomposition and artificial neural networks”, Renewable Energy, vol. 48, pp. 545–556, Déc. 2012. DOI : 10.1016/j.renene.2012.06.012
- [47] **N. Amjady, F. Keynia, et H. Zareipour**, “Wind Power Prediction by a New Forecast Engine Composed of Modified Hybrid Neural Network and Enhanced Particle Swarm Optimization”, IEEE Transactions on Sustainable Energy, vol. 2, no. 3, pp. 265–276, Juil. 2011. DOI : 10.1109/TSTE.2011.2114680
- [48] **O. Abedinia et N. Amjady**, “Short-term wind power prediction based on Hybrid Neural Network and chaotic shark smell optimization”, International Journal of Precision Engineering and

Manufacturing-Green Technology, vol. 2, no. 3, pp. 245–254, 2015. DOI : 10.1007/s40684-015-0029-4

[49] **J. S. R. Jang**, “ANFIS : Adaptive-network-based fuzzy inference system”, IEEE Transactions on Systems, Man, and Cybernetics, vol. 23, no. 3, pp. 665–685, Mai 1993. DOI : 10.1109/21.256541

[50] **C.W. Potter et M. Negnevitsky**, “Very short-term wind forecasting for Tasmanian power generation”, IEEE Transactions on Power Systems, vol. 21, no. 2, pp. 965–972, Mai 2006. DOI : 10.1109/TPWRS.2006.873421

[51] “Hybrid Wavelet-PSO-ANFIS Approach for Short-Term Wind Power Forecasting in Portugal”, IEEE Transactions on Sustainable Energy, vol. 2, no. 1, pp. 50–59, Jan. 2011. DOI : 10.1109/TSTE.2010.2076359

[52] **G. Sideratos et N. D. Hatziargyriou**, “An Advanced Statistical Method for Wind Power Forecasting”, IEEE Transactions on Power Systems, vol. 22, no. 1, pp. 258–265, Fév. 2007. DOI : 10.1109/TPWRS.2006.889078

[53] **C.-Y. Huang, Y.-W. Liu, W.-C. Tzeng, et P.-Y. Wang**, “Short Term Wind Speed Predictions by Using the Grey Prediction Model Based Forecast Method”, 2011 IEEE Green Technologies Conference (IEEE-Green), pp. 1–5, 2011. DOI : 10.1109/GREEN.2011.5754856

[54] **H. Mori et E. Kurata**, “Application of Gaussian Process to wind speed forecasting for wind power generation”, dans 2008 IEEE International Conference on Sustainable Energy Technologies, Nov. 2008, pp. 956–959. DOI : 10.1109/ICSET.2008.4747145

[55] **P. Kou et F. Gao**, “Sparse heteroscedastic Gaussian process for shortterm wind speed forecasting”, dans The 2012 International Joint Conference on Neural Networks (IJCNN), Juin 2012, pp. 1–8. DOI : 10.1109/IJCNN.2012.6252407

[56] **M. A. Mohandes, T. O. Halawani, S. Rehman, et A. A. Hussain**, “Support vector machines for wind speed prediction”, Renewable Energy, vol. 29, no. 6, pp. 939–947, Mai 2004. DOI : 10.1016/j.renene.2003.11.009

[57] **A. Kusiak, H. Zheng, et Z. Song**, “Wind farm power prediction : A data-mining approach”, Wind Energy, vol. 12, no. 3, pp. 275–293, Avr. 2009. DOI : 10.1002/we.295

- [58] **Y. Zhang, J. Yang, K. Wang, Z. Zhao, J. Liu, et Y. Wang**, “*New Progress in Wind Prediction Based on Nonlinear Amendment*”, dans 2014 IEEE Fourth International Conference on Big Data and Cloud Computing, Déc. 2014, pp. 599–603. DOI : 10.1109/BDCloud.2014.13
- [59] **Y. Zhang, P. Wang, C. Zhang, et S. Lei**, “*Wind energy prediction with LS-SVM based on Lorenz perturbation*”, The Journal of Engineering, vol. 2017, no. 13, pp. 1724–1727, 2017. DOI : 10.1049/joe.2017.0626
- [60] **Y. Zhang, J. Yang, K. Wang, Z. Wang, et Y. Wang**, “*Improved wind prediction based on the Lorenz system*”, Renewable Energy, vol. 81, pp. 219–226, Sep. 2015. DOI : 10.1016/j.renene.2015.03.039
- [61] **P. Zarchan et H. Musoff**, *Fundamentals of Kalman Filtering : A Practical Approach*. American Institute of Aeronautics and Astronautics, Incorporated, 2000.
- [62] **G. Galanis, P. Louka, P. Katsafados, I. Pytharoulis, et G. Kallos**, “*Applications of Kalman filters based on non-linear functions to numerical weather predictions*”, Annales Geophysicae, vol. 24, pp. 2451–2460, 2006. DOI : 10.5194/angeo-24-2451-2006
- [63] **P. Louka, G. Galanis, N. Siebert, G. Kariniotakis, P. Katsafados, I. Pytharoulis, et G. Kallos**, “*Improvements in wind speed forecasts for wind power prediction purposes using Kalman filtering*”, Journal of Wind Engineering and Industrial Aerodynamics, vol. 96, no. 12, pp. 2348–2362, 2008. DOI : 10.1016/j.jweia.2008.03.013
- [64] **C. Strathopoulos, A. Kaperoni, G. Galanis, et G. Kallos**, “*Wind power prediction based on numerical and statistical models*”, Jnl. of Wind Engineering and Industrial Aerodynamics, vol. 112, no. C, pp. 25–38, 2013. DOI : 10.1016/j.jweia.2012.09.004
- [65] **P. Zhao, J. Wang, J. Xia, Y. Dai, Y. Sheng, et J. Yue**, “*Performance evaluation and accuracy enhancement of a day-ahead wind power forecasting system in China*”, Renewable Energy, vol. 43, pp. 234–241, Juil. 2012. DOI : 10.1016/j.renene.2011.11.051
- [66] **BEAUREGARD-HARVEY Olivia** « *AMÉLIORATION DES PRÉVISIONS IMMÉDIATES DU VENT ET DE LA PRODUCTION ÉOLIENNE* », Maîtrise ès sciences appliquées, ÉCOLE POLYTECHNIQUE DE MONTRÉAL 2018.
- [67] **Y. Che, X. Peng, L. Delle Monache, T. Kawaguchi, et F. Xiao**, “*A wind power forecasting system based on the weather research and forecasting model and Kalman filtering over a wind-*

farm in Japan”, "Journal of Renewable and Sustainable Energy, vol. 8, no. 1, p. 013302, Jan. 2016.
DOI : 10.1063/1.4940208.

[68] **HAMID OUDJANA Samir** « *Etude de la Prévission de Charge dans un Réseau Electrique*»,
Mémoire Magister, Université Amar Telidji LAGHOUAT 2010.

[69] **Arnaud Guyader**, "*Régression linéaire*," Université Rennes 2, Master de Statistique, 2010.

[70] **Marc Parizeau**, "*Réseaux de neurones*," Université Laval, 2004

[71] **Zhanshou Yu**, "*Feed-Forward Neural Networks and Their Applications in Forecasting*,"
Thèse de Magister, University of Houston, 2000.

[72] **Fatiha Sebaa-Ben Miloud et R. Aïssaoui**, « *Etude du potentiel éolien d’Adrar sélection de sites pour la ferme éolienne de 10 MW* », *Revue des Energies Renouvelables SMEE’10 Bou Ismail Tipaza (2010)* 295 – 300

ملخص

يشكل التنبؤ بالإنتاج الكهربائي للطاقات المتجددة وخاصة محطات التوليد المعتمدة على طاقة الرياح عاملاً مهماً جداً في مساهمة هذه المحطات في تزويد الشبكات الكهربائية بالطاقة ، وبذلك يساهم في خفض تشغيل محطات الطاقة الكهربائية التقليدية ، مما يؤدي إلى تقليل تكلفة إنتاج الكهرباء وكذا المحافظة على البيئة كونها طاقة نظيفة ومتجددة.

في هذا العمل قمنا بتطوير برامج لحساب أخطاء التنبؤ على المدى القصير باستخدام الأساليب الإحصائية الكلاسيكية مثل الانحدار الخطي وطرق الذكاء الاصطناعي القائمة على الشبكات العصبية. تعتمد الطرق الكلاسيكية على النموذج الرياضي، لكن أساليب الشبكة العصبية تعتمد فقط على البيانات التاريخية مع التنبؤ الدقيق، مع العلم أن إنتاج الكهرباء يعتمد على سرعة الرياح وفصول السنة.

الكلمة المفتاحية: التنبؤ بتوليد الكهرباء، طاقة الرياح ، الانحدار الخطي ، الشبكات العصبية الاصطناعية.

Résumé

La prévision de la production électrique des énergies renouvelable notamment l'énergie éolienne constitue une partie très importante dans l'intégration aux réseaux électriques, ce faisant, il contribue à réduire le fonctionnement des centrales électriques conventionnelles, ce qui conduit à réduire le coût de production électrique et préserver l'environnement car il s'agit d'une énergie propre, gratuit et renouvelable.

Dans ce travail nous avons développé des programmes qui calculent l'erreur de prévision à court terme en utilisant les méthodes statistiques classiques telles que la régression, et des méthodes d'intelligence artificielle basées sur les réseaux de neurones. Les méthodes classiques dépendent du modèle mathématique, mais les méthodes de réseaux de neurones ne dépendent que des données historiques avec une prévision précise, sachant que la production électrique dépend du vitesse du vent, de la saisonnalité.

Mot clé : Prévision de production, énergie éolienne, régression linéaire, réseaux neurones artificiel.

Abstract

The forecast of the electricity production of renewable energies in particular of wind energy constitutes a very important part in the integration into the electricity grids, in doing so, it contributes to reduce the operation of the conventional plants, which leads to reducing the cost of production. electricity and preserve the environment because it is clean, free and renewable energy.

In this work we have developed some programs that calculate the short-term electrical production forecasting error using classical statistical methods such as regression and artificial intelligence techniques such as neural networks. Conventional methods depend on the mathematical model where neural network methods depends only on historical data with good forecasting accuracy, knowing that the electrical production depends on wind speed and seasonality.

Key word: Production forecasting, wind energy, linear regression, artificial neural networks.