

UNIVERSITÉ DU QUÉBEC

MÉMOIRE PRÉSENTÉ À
L'UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

COMME EXIGENCE PARTIELLE
DE LA MAÎTRISE EN GÉNIE ÉLECTRIQUE

PAR
BOUBACAR DOUCOURÉ

PROPOSITION, INTÉGRATION DANS UN SYSTÈME DE GESTION DE RÉSEAU
INTELLIGENT ET VALIDATION EXPÉRIMENTALE D'UNE MÉTHODE DE
PRÉDICTION POUR UN SYSTÈME D'ÉNERGIES RENOUVELABLES

SEPTEMBRE 2015

Université du Québec à Trois-Rivières

Service de la bibliothèque

Avertissement

L'auteur de ce mémoire ou de cette thèse a autorisé l'Université du Québec à Trois-Rivières à diffuser, à des fins non lucratives, une copie de son mémoire ou de sa thèse.

Cette diffusion n'entraîne pas une renonciation de la part de l'auteur à ses droits de propriété intellectuelle, incluant le droit d'auteur, sur ce mémoire ou cette thèse. Notamment, la reproduction ou la publication de la totalité ou d'une partie importante de ce mémoire ou de cette thèse requiert son autorisation.

Résumé

À cause du réchauffement climatique et de la quantité limitée des stocks des énergies fossiles dans le monde. Il est urgent de trouver des solutions alternatives à ces sources d'énergies. L'augmentation de la pénétration des énergies renouvelables peut contribuer à cela. Pour que les énergies renouvelables soient une alternative crédible à l'énergie fossile il faut d'une part que leurs coûts de production soit concurrentielle et d'autre part que leur intégration aux grands réseaux à grande échelle, ainsi qu'aux réseaux décentralisés soient viables, c'est-à-dire que les gestionnaires des réseaux soient capables d'équilibrer l'offre et la demande de l'énergie. Toutefois les périodes de production et de consommation d'énergie ne sont pas toujours les mêmes. Il devient important de trouver des systèmes de gestion et de stockage d'énergie. La connaissance de la prévision des sources d'énergies renouvelables est plus pertinente, à cause de leurs intermittences. Cette prévision devrait aider les systèmes de gestions des réseaux électriques à augmenter l'intégration des sources d'énergies renouvelables dans les réseaux.

Ce travail consiste à développer un système de prédiction des sources d'énergie renouvelable dans le but de l'intégrer à un système de gestion intelligente d'un micro réseau électrique (en développement à l'IRH) afin de favoriser la pénétration des énergies renouvelables dans les grands réseaux électriques et ceux isolés. La prédictibilité des données en détail est analysée afin d'évaluer la pertinence de garder les composantes qui ont un faible potentiel de prédictibilité. Cette démarche a pour but de déterminer les composants des

données qui ont un apport négligeable ou négatif à la précision de la production pour permettre d'économiser des ressources de calcul.

L'application et l'intégration de la prédiction des sources d'énergies renouvelables aux réseaux électriques intelligents (Smart Grid) permettront d'optimiser la gestion des réseaux intégrant les sources d'énergies renouvelables.

Remerciements

Je remercie mon directeur de recherche, le Professeur Kodjo Agbossou, pour m'avoir donné l'opportunité de travaillé sur ce projet, et aussi pour son soutien et encouragé pendant le travail de recherche. Mes remerciements vont aussi à l'endroit d'Alben Cardenas, Phd en génie électrique pour son encadrement, ses précieuses contributions et son soutien pendant ce projet. Je remercie également Nilson Henao pour son soutien précieux pendant mon mémoire. Bref je remercie toutes les personnes qui m'ont aidé de près ou de loin pendant mes travaux. En fin je remercie très chaleureusement mes amis et ma famille qui ont été d'un soutien moral inestimable.

Je dédie ce mémoire à mes deux garçons Cheick et Khalif, mes parents ainsi que mes frères et sœurs.

Table des matières

Résumé.....	ii
Remerciements.....	iv
Table des matières.....	v
Liste des tableaux.....	x
Liste des figures	xi
Liste des symboles	1
Chapitre 1 - Introduction.....	2
1.1 Contexte général du projet de recherche	5
1.2 Problématique	6
1.3 Objectifs.....	7
1.4 Méthodologie.....	7
1.5 Organisation du Mémoire	9
Chapitre 2 - Méthodes de prédiction.....	11
2.1 Introduction à la prédiction de séries temporelles.....	12
2.1.1 Définition de série temporelle.....	12
2.1.2 Les horizons de prédiction.....	13

2.1.3	Méthodes classiques de prédiction	14
2.1.4	Méthodes d'intelligence artificielle	17
2.1.5	Forme d'apprentissage	18
2.1.6	Performance des modèles	18
2.1.7	Évaluation comparative	20
2.2	<i>Les réseaux d'ondelettes</i>	24
2.3	<i>Estimation de paramètres</i>	24
2.4	<i>Conclusion</i>	25
Chapitre 3 - Transformée en Ondelettes et Analyse Multi-résolution		26
3.1	<i>Introduction</i>	26
3.2	<i>Définition d'une ondelette</i>	27
3.3	<i>Théorie de l'analyse multi-résolution</i>	27
3.3.1	La transformée continue en ondelettes (TCO).....	27
3.3.2	Transformée d'ondelette discrète (TOD).....	28
3.3.3	Principe de base de l'analyse multi-résolution (AMR)	29
3.3.4	Sous-espaces contenant le détail (AMR).	32
3.3.5	Ondelette père	33
3.3.6	Ondelette mère	34
3.3.7	Les bases orthonormées d'ondelettes	35

3.3.8	Décomposition et reconstruction	36
3.3.9	Banc de filtres	38
3.3.10	Relation entre l'ondelette et les coefficients des filtres	39
3.3.11	Détermination des coefficients de décomposition : Ondelette de Daubechies.....	39
3.4	<i>Les réseaux d'ondelettes:</i>	40
3.4.1	Une ondelette multidimensionnelle	41
3.5	<i>Conclusion</i>	42
Chapitre 4 - Système de prédiction		45
4.1	<i>Étude de la prédictibilité des données</i>	45
4.2	<i>Modèle de prédiction</i>	47
4.3	<i>Décomposition</i>	48
	Principe de fonctionnement de la décomposition :	48
4.4	<i>Prédiction</i>	49
4.4.1	Architecture du réseau d'ondelette	49
4.4.2	Optimisation des paramètres.....	52
4.4.3	Algorithme d'entraînement.....	54
4.5	<i>Reconstruction</i>	58
4.6	<i>Méthode de décomposition reconstruction utilisant MODWT</i>	59
4.7	<i>Conclusion</i>	60

Chapitre 5 - Analyses des résultats	61
5.1 Banc d'essais des énergies renouvelables - Institut de Recherche sur l'Hydrogène	62
5.2 Acquisition et stockage des données	63
5.3 Objectifs de simulation	67
5.4 Scenario de test	68
5.4.1 Évaluation de la prédictibilité des séries temporelles	68
5.5 Données de test	72
5.6 Résultats prédiction AWNN (DWT)	73
5.6.1 Résultats Décomposition	74
5.6.2 Entraînement	75
5.6.3 Reconstruction	76
5.6.4 Erreur de prédiction de la méthode AWNN (DWT)	78
5.7 Résultats prédiction AWNN(MODWT)	79
5.7.1 Décomposition	79
5.7.2 Prédiction	81
5.7.3 Calcul d'erreurs	83
5.7.4 Analyse des résultats :	85
5.8 Conclusions	86
Chapitre 6 - Conclusion	88

Bibliographie (ou Références)	91
Index	96
Annexe A – Titre de l'annexe A	97
Le neurone formel	97
6.1.1 Fonction d'activation	97

Liste des tableaux

Tableau 2-1 Comparaison de quelques méthodes de prédiction [8]	20
Tableau 2-2 Comparaison de la méthode PER, NR, AWNN [23].....	23
Tableau 2-3 Comparaison des erreurs de prédiction [20].....	24
Tableau 5-1 Erreur de prédiction des séries par l’algorithme proposé.	72
Tableau 5-2 Erreur de prédiction de la méthode AWNN (DWT).....	79
Tableau 5-3 Erreur de prédiction données complètes AWNN(MODWT)	84
Tableau 5-4 Erreur de prédiction sans D_5 et D_4 AWNN(MODWT)	84
Tableau 5-5 Erreur de prédiction de la méthode (AR).....	85

Liste des figures

Figure 1-1 Estimée de la production et l'investissement dans les ÉR [1].....	3
Figure 1-2 Capacité électrique du solaire et de l'éolienne Canada [3].	4
Figure 2-1 Schéma simplifié d'un système de gestion d'énergie	14
Figure 3-1 Cartographie des espaces vectoriels	30
Figure 3-2 Disposition des sous espaces V_i	31
Figure 3-3 Configuration des espaces vectoriels dans AMR [27]	33
Figure 3-4 Dilatation et translation d'ondelette	35
Figure 3-5. Algorithme décomposition analyse de Mallat [33]	37
Figure 3-6 Algorithme de reconstruction de Mallat [33]	38
Figure 3-7 Banc de filtres	39
Figure 3-8 Ondelette de « chapeau mexicain ».....	41
Figure 3-9 Réseau d'ondelettes [15].	42
Figure 3-10 Structure de la couche cachée.	42
Figure 4-1 Structure générale du système de prédiction.....	48
Figure 4-2 Décomposition des données d'entrée.....	49
Figure 4-3 Réseau d'ondelette [40].....	51
Figure 4-4 Algorithme d'entraînement	56
Figure 4-5 Structure de l'entraînement	57
Figure 4-6 Principe de la prédiction.....	57
Figure 4-7 Décomposition prédiction et reconstruction	59
Figure 4-8 Structure de la décomposition MODWT	60

Figure 5-1 Banc d'essai.	62
Figure 5-2 Chaîne de conversion de l'éolienne [44].	63
Figure 5-3 Système de mesure de l'interface intelligent [44].	64
Figure 5-4 Image de l'éolienne de l'IRH.	66
Figure 5-5 Image des panneaux solaires de l'IRH.	67
Figure 5-6 Test de prédiction avec Série de Mackey-Glass.	70
Figure 5-7 Série à marche aléatoire test de prédiction.	71
Figure 5-8 Série aléatoire test de prédiction.	72
Figure 5-9 Données de vitesse du vent prises de site web : https://www.simeb.ca	73
Figure 5-10 Schéma Simulink de la décomposition.	74
Figure 5-11 Résultats de la décomposition AWNN(DWT).	75
Figure 5-12 Schéma Simulink de l'entraînement.	76
Figure 5-13 Schéma Simulink de la reconstruction.	76
Figure 5-14 Schéma Simulink prédiction.	77
Figure 5-15 Résultat de la prédiction du vent (Horizon 1 heure) avec DWT.	78
Figure 5-16 Décomposition de données du vent (300 échantillons).	80
Figure 5-17 Exposant de Hurst de la décomposition.	81
Figure 5-18 Résultat de la prédiction du vent (Horizon 1 heure) avec MODWT.	82
Figure 5-19 Résultat de la prédiction du vent (Horizon 5 heure) avec MODWT.	82
Figure 6-1 Neurone formel [7].	98

Liste des symboles

ADALINE	Adaptive linear neuron
AMR	Analyse multirésolution
ANFIS	Adaptive network-based fuzzy inference system
AR	Auto régressive
ARIMA	Autoregressive integrated moving average
ARMA	Processus mix
ANN	Adaptative neural network
ARX	Autoregressive exogenous
AWNN	Adaptative wavelet neural network
DWT	Discrete wavelet transform
MA	Moyenne mobile
MAE	Mean Absolute Error
MAPE	Mean Absolute Percent Error
MODWT	Maximum Over-lap Discrete wavelet Transform
NWP	Numerical weather prediction
RMSE	Root Mean Square Error
SIMEB	Simulation énergétique des bâtiments
SMAPE	Symmetric Mean Absolute Percent Error
SVM	Support vector machine

Chapitre 1 - Introduction

Depuis quelques années, on remarque un intérêt de plus en plus grandissant pour les énergies renouvelables (ÉR) dans le monde. Les gouvernements adoptent des politiques pour favoriser la diminution du coût de nombreuses technologies d'ÉR. L'augmentation des prix des énergies fossiles, la hausse de la demande d'énergie et d'autres facteurs (réchauffement climatique, développement durable etc.) ont favorisé l'émergence des ER [4]. De la fin 2006 à la fin 2011, on constate une croissance très rapide des énergies renouvelables dont le photovoltaïque avec une capacité opérationnelle en augmentation moyenne de 58% par an et l'énergie éolienne de 26 % par an. Ce qui se traduit par une très forte croissance des investissements dans le domaine des énergies renouvelables. De 2004 à 2011 l'investissement dans le monde est passé de 39 Milliards US à 257 Milliards US [1]. Cet investissement a été motivé principalement par la croissance des gaz à effets de serre dans l'atmosphère et aussi par l'épuisement, dans un avenir proche des stocks d'énergies fossiles dans le monde [1], [2]. Cette évolution est représentée à la figure 1-1.

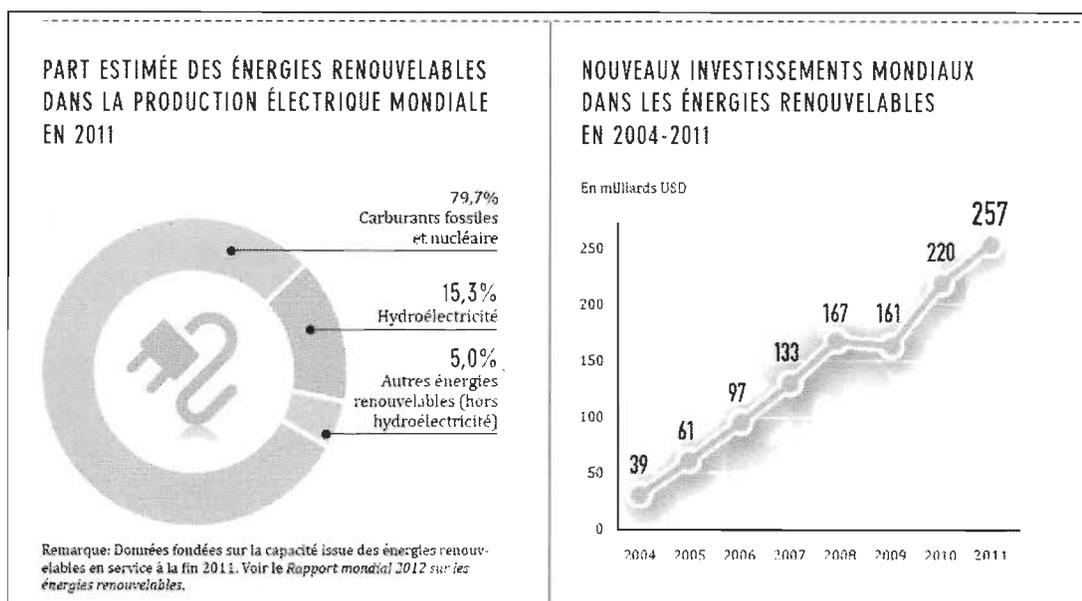


Figure 1-1 Estimée de la production et l'investissement dans les ÉR [1]

Le Canada est un chef de file dans le domaine des énergies renouvelables. La part des énergies renouvelables dans l'approvisionnement nationale du Canada en énergie primaire total est de 17%. Dans le secteur de l'électricité au Canada, l'hydroélectricité représente 60% de la production totale. Les autres sources comme l'éolienne, la marémotrice, la biomasse et le solaire représentent 3% [3].

Malgré le faible pourcentage de l'éolienne et du solaire dans la part nationale de la production d'électricité. Ils ont eu une croissance soutenue au cours des dix dernières années. La capacité des éoliennes s'est multipliée par trente pour atteindre 6201MW en 2012 ce qui équivaut à 5% de la capacité canadienne en énergie. L'énergie solaire a eu aussi une forte croissance au cours de la dernière décennie, elle était de 10MW en 2002 atteint 765MW en 2012. Cette évolution du solaire et de l'éolienne est illustrée sur la figure 1-2 [3].

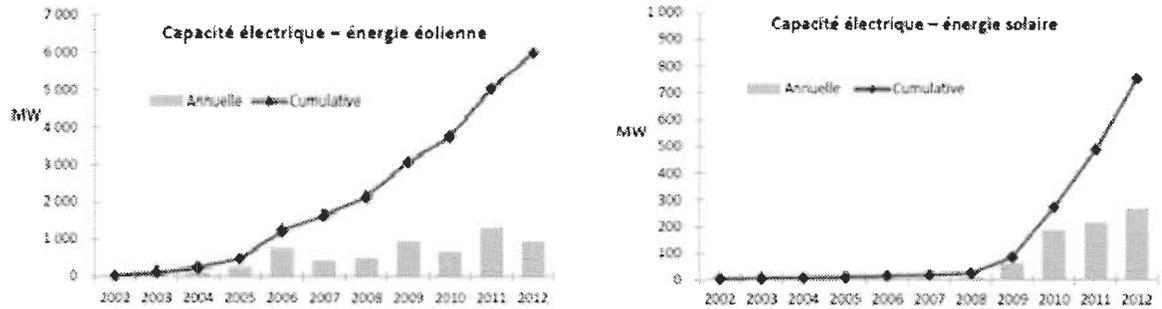


Figure 1-2 Capacité électrique du solaire et de l'éolienne Canada [3].

Étant donné que les énergies renouvelables, tels que l'éolienne et le solaire, sont des sources intermittentes dont la production est influencée par les conditions météorologiques, leurs intégrations aux réseaux électriques et à grande échelle est un défi considérable à cause de leur caractère intermittent.

Pour que les énergies renouvelables soient une alternative crédible à l'énergie fossile il faut que leurs intégrations aux grands réseaux et à ceux décentralisés prennent une place importante dans la fourniture de l'électricité dans le monde. Le défi principal des gestionnaires des réseaux électriques est d'être capable d'équilibrer l'offre et la demande de l'énergie du réseau. L'intermittence des sources comme l'éolienne et le solaire rend la gestion de cet équilibre plus ardu, lorsqu'ils représentent une part important dans les réseaux. D'où la pertinence de la prédiction des sources d'énergies renouvelables (l'éolienne et le solaire) et de la consommation de la charge. Il est aussi important dans la gestion de ces réseaux de considérer l'aspect du stockage de l'énergie à cause de la dynamique de charge et de décharge des moyens de stockage.

À cause de l'intermittent des sources d'énergie renouvelable, l'application et l'intégration des techniques de prédiction aux réseaux intelligents peut être un outil très puissant pour

optimiser la gestion des réseaux intégrant les sources d'énergies renouvelables intermittents [4].

1.1 Contexte général du projet de recherche

De façon générale à l'Institut de Recherche sur l'Hydrogène (IRH) la prédiction est utilisée pour diverses applications dans plusieurs domaines de recherche. Il y a plusieurs travaux qui ont été réalisés à l'IRH sur la prédiction. Par exemple la prédiction sur la durée de vie des batteries, pile à combustible, ainsi que la prédiction des charges, et des sources d'énergies renouvelables intermittentes. Il y a certains travaux qui ont fait l'objet de publication; par exemple la publication intitulée «*Nonlinear Model Identification of Wind Turbine with a Neural Network* » porte sur la prédiction de la puissance moyenne du vent utilisant des réseaux de neurones artificiels [5].

Plus spécifiquement nous avons une équipe à l'IRH qui traite des problématiques liées aux énergies renouvelables. C'est dans cette optique qu'il a été décidé au sein l'équipe de réaliser un micro réseau intelligent dont les sources d'énergies principales sont renouvelables. Afin de traiter les problématiques liées à ce type de réseau électrique qui pourrait être une solution viable pour les régions éloignées.

Ce projet de recherche se situe dans le contexte de la prédiction des énergies renouvelables afin de faciliter leur intégration au micro réseau. À cause de l'intermittence des sources, la prédiction est un maillon important pour la réalisation du micro réseau, et aussi pour l'intégration des sources d'énergie renouvelables dans des réseaux électriques de façon générale.

1.2 *Problématique*

Un réseau électrique alimenté essentiellement par des sources ÉR intermittentes, nécessite la prédiction de ces sources dans la gestion du réseau afin d'assurer son équilibre [6]. Puisque dans un réseau électrique il est essentiel d'équilibrer l'offre et la demande de la puissance électrique [7]. L'idée est de déterminer et de réaliser une méthode de prédiction qui cadre le mieux dans la gestion du micro réseau intégrant des sources d'énergies renouvelables. Ainsi ce travail consiste à développer une méthode de prédiction des sources d'énergie (éolienne et solaire) pour un micro réseau intelligent.

Dans la littérature nous constatons qu'il existe plusieurs méthodes de prédiction pour différents horizons de prédiction et ces différentes méthodes ont des forces et des faiblesses très diverses et changent selon les contextes ou l'environnement de la prédiction [8], [9]. C'est pourquoi, il est important d'identifier une méthode de prédiction qui cadre le mieux au projet. Les horizons de prédiction se présentent comme suit : la prédiction à long terme, à moyen terme, à court terme et à très court terme.

Cependant, dans cette application nous désirons faire la prédiction des sources énergie renouvelable (éolienne et photovoltaïque) dans un contexte de gestion de réseaux décentralisés. Pour ce type de gestion, il est important de bien choisir l'horizon de prédiction qui est essentiel pour la gestion du réseau. Le temps d'acquisition des informations de prédiction est essentiel pour la gestion afin prendre des décisions appropriées pour des solutions alternatives. Nous devons également étudier les données à prédire, elles ne sont pas toujours prédictibles donc il est important de déterminer à quel niveau les données sont prédictibles.

1.3 Objectifs

L'objectif principal de ce travail est de déterminer une méthode de prédiction des sources énergies renouvelables et la réaliser, afin de permettre la gestion d'un micro réseau électrique intelligent.

Pour la gestion de ce système nous devons déterminer un horizon de prédiction des sources d'énergie renouvelable du réseau.

Les objectifs spécifiques:

1. Faire une étude de prédictibilité des données de la vitesse du vent et du soleil afin de définir les attentes de prédiction.
2. Développer une méthode de prédiction des sources d'énergie renouvelables. Cette étape, est la partie essentielle du travail. Elle consiste, à réaliser une méthode de prédiction des sources d'énergies renouvelables, répondant aux besoins de la gestion du micro réseau électrique intelligent.
3. Acquisition et stockage des données de la vitesse du vent sur le banc d'essai afin de tester la prédiction avec les données réelles du système. Valider par simulation et comparer les résultats de la méthode de prédiction adoptée aux résultats de méthodes de prédictions classiques.

1.4 Méthodologie

La stratégie adoptée dans ce projet de mémoire est élaborée en six étapes :

1. *Étude de sensibilité du système de gestion.* Pour réaliser un algorithme pour un système de gestion de réseau intelligent, il est important de savoir quels sont les délais critiques du système gestion, afin de prendre des décisions pour mettre en

marche telle ou telles sources d'énergie, ou de savoir quelles sont les sources qui sont disponibles, dans combien de temps et pour combien de temps.

2. *Acquisition et stockage des données.* Dans cette partie, une stratégie pour collecter les données de vent et soleil à l'IRH par le bief des installations (des panneaux solaires et d'éolienne) ou doit être définie. Les données de test pourraient être recueillir des bases de données pour valider les résultats.
3. *Étude de la prédictibilité des données (série temporelle).* Cette étape consiste à faire une étude de la possibilité de prédire les données de vent et de soleil; et à classifier les données en fonction de leurs potentiels de prédictibilité. Cette étude a permis de connaître la précision qu'on peut atteindre selon les types de série temporelle.
4. *Choix d'une méthode de prédiction :* Pour réaliser un système de prédiction approprié pour un micro réseau électrique, nous avons fait le parcours de la littérature pour identifier les méthodes de prédiction adéquates pour ce type d'application. Pour ce faire nous avons regardé le principe de base des potentielles méthodes de prédiction, nous avons fait ressortir leurs forces et leurs faiblesses. Ensuite nous avons procédé au choix de la méthode en fonction des besoins du micro réseau et des possibilités matérielles.
5. *Développement de la méthode choisie :* Après une étude de l'état de l'art nous avons choisi une méthode de prédiction basée sur les réseaux d'ondelettes et l'analyse multi résolution. Le développement de cette méthode est constitué de trois étapes :

Première étape (décomposition), le signal d'entrée est décomposé en plusieurs bandes de fréquence, ce qui permet de regrouper les différentes tendances du signal d'entrée. Le traitement est fait de façon séparée, ce qui permet de bien cerner les

différentes caractéristiques du signal dès le départ. Cette décomposition est faite en base d'ondelettes. Les transformées des ondelettes donnent une analyse des structures locales de l'information d'entrée et un zoom qui est lié à l'échelle considérée [12].

Deuxième étape (prédiction et entraînement) les signaux décomposés sont individuellement l'entrée de l'algorithme de prédiction et d'entraînement. L'algorithme utilisé pour la prédiction est un réseau d'ondelette.

Troisième étape (reconstruction), on récupère les sorties des réseaux d'ondelette et l'algorithme de reconstruction fait le calcul inverse de la décomposition afin de reconstruire le signal.

Pour valider la fiabilité de notre système de prédiction, nous avons fait une comparaison entre le système développé et une méthode classique de prédiction. Ce processus nous a permis de savoir si notre algorithme offre des meilleures performances par rapport aux méthodes classiques.

1.5 Organisation du Mémoire

Ce mémoire est organisé en six chapitres incluant l'introduction et la conclusion générale. Le deuxième chapitre est basé sur la recherche bibliographique, ce qui nous permet d'avoir une bonne lisibilité des méthodes de prédiction existantes et voir leurs avantages et leurs désavantages. Ce chapitre parle également des horizons de prédiction et des contextes dans lesquels ils sont utilisés. Dans le troisième chapitre, la théorie liée au système de prédiction proposé sera abordée afin de faire ressortir les avantages par rapport aux différentes méthodes de prédiction. Dans le quatrième chapitre, la théorie de l'analyse multi-résolution est étudiée afin de montrer les algorithmes de décomposition

et reconstruction à l'aide d'ondelettes. Les aspects de base de la théorie des réseaux des ondelettes seront aussi analysés. Le cinquième chapitre est consacré à la description du système proposé et à l'analyse des résultats de prédiction. Enfin ce dernier chapitre nous permettra de faire une conclusion générale, faire une synthèse des résultats et présenter les perspectives.

Chapitre 2 - Méthodes de prédiction

Dans la littérature nous constatons qu'il existe plusieurs méthodes de prédiction pour différents horizons de prédiction et ces différentes méthodes ont des forces et des faiblesses très diverses et changent selon les contextes ou l'environnement de la prédiction. C'est pourquoi il est souvent difficile d'identifier une méthode de prédiction qui se démarque largement des autres.

Les horizons de prédiction se présentent comme suit : la prédiction à long terme, moyen terme, court terme et très court terme. Cependant, pour notre application nous désirons faire la prédiction des sources d'énergie renouvelable (éolienne et photovoltaïque) dans un contexte de gestion des micro-réseaux. Pour ce type de gestion nous estimons que la prédiction à court et à très court terme serait pertinente.

Par conséquent, nous allons nous consacrer sur les méthodes de prédiction de court et de très court terme afin de dégager une méthode appropriée pour notre application. Pour cela nous allons faire le parcours de la littérature et trouver la ou les méthodes nous permettant d'assurer une bonne gestion du micro réseau.

2.1 Introduction à la prédiction de séries temporelles

Une série temporelle est une suite de nombres numériques correspondant à l'évolution d'une quantité donnée dans le temps. Ces variables aléatoires peuvent être faire l'objet d'analyser mathématique afin de comprendre son évolution passée et pour en prévoir le comportement futur. Les données de la vitesse du vent sont considérées comme des séries temporelles.

2.1.1 Définition de série temporelle

Définition: Pour l'utilisation du concept de séries temporelles, il est important de définir quelques variables dont t qui est la valeur courante de la chronologie x , t représente le temps et est compris entre 1 et n . Donc t est l'indice de x . Soit h l'indice de x correspondant aux nombres de points entre le présent et le futur. Il est généralement appelé horizon de prédiction. Connaissant le passé d'un événement future x_1, \dots, \dots, x_p où p correspond au temps présent.

Définition algébrique: Une série temporelle, ou série chronologique, est une suite de valeurs numériques représentant l'évolution d'une quantité spécifique au cours du temps [10].

Soit $f: R^N$ vers R

N est la dimension des données d'entrée.

$$x(t + d) = f[x(t), x(t - 1), x(t - 2), \dots, x(t - N + 1)].$$

2.1.2 Les horizons de prédiction

Les horizons de prédiction se présentent comme suit: la prédiction à long terme de 1 jour à une semaine; le moyen terme de 6 heures à un jour; le court terme de 30 minutes à 6 heures et de très court terme de quelques secondes à 30 minutes [8].

- **Long terme:** La prédiction à long terme permet de prédire l'indisponibilité (ou la disponibilité) de l'énergie pour des périodes allant de 1 jour à une semaine. Cette forme de prédiction permet d'anticiper une plage dans le temps pendant laquelle il n'y a pas une grande production d'énergie afin de pouvoir faire l'entretien du système. Elle permet également de faire la gestion du stockage d'énergie etc.
- **Moyen terme:** La prédiction à moyen terme permet de faire la gestion journalière du réseau dans le cadre des pics de demande journalière par exemple. Elle permet d'anticiper la production d'énergie journalière, lorsqu'elle est combinée à la prédiction à court terme, elle peut être un outil pour un gestionnaire de réseau.
- **Court terme:** La prédiction à court terme est souvent utilisée pour la gestion d'un réseau dans un temps assez court. Afin de pouvoir prendre des décisions pour la gestion en temps-réel d'un réseau électrique qui intègre des sources à énergies renouvelables.
- **Très court terme:** La prédiction à très court terme est aussi utilisée pour la gestion d'un réseau dans un temps très court pour anticiper des fluctuations dans un intervalle de temps de quelques secondes à 30 minutes. Les prédictions à court et très court terme peuvent être complémentaires à cause du caractère aléatoire du vent.

Pour la gestion d'un réseau électrique, il est essentiel de connaître la consommation des charges ainsi que la production des sources d'énergie alimentant le réseau car la stabilité d'un réseau électrique est strictement liée à l'équilibre de l'offre et de la demande de la puissance

électrique. L'horizon de prédiction est donc défini en fonction des besoins du programme de gestion élaboré. L'horizon de prédiction envisagé pour le système de gestion du micro réseau électrique est à court. La figure 2-1 est un schéma simplifié d'un système de gestion d'un réseau électrique.

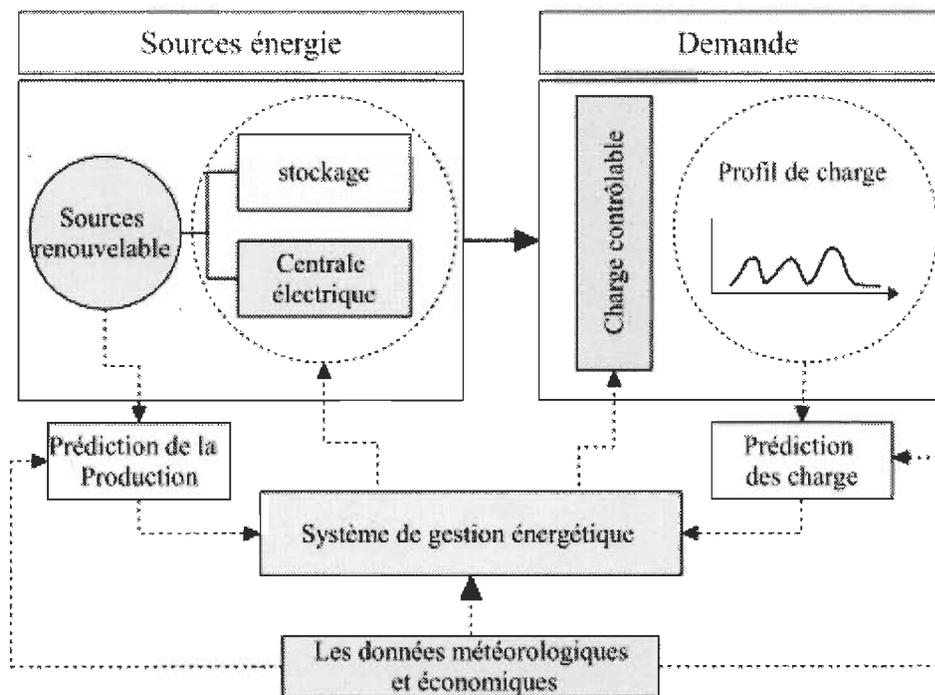


Figure 2-1 Schéma simplifié d'un système de gestion d'énergie

2.1.3 Méthodes classiques de prédiction

Dans cette section, les différents principes de base de quelques méthodes susceptibles de donner des résultats acceptables pour un réseau intelligent seront présentés. Les méthodes analysées sont : systèmes autorégressifs (ARMA pour *Autoregressive-moving-average*), réseaux neurones artificiels (ANN pour *Artificial neural networks*), support vector machine (SVM), ainsi que les réseaux d'ondelettes (WNN pour *Wavelet Neural Network*).

2.1.3.1 Les processus autorégressifs (AR)

Le modèle AR est un processus autorégressif se basant sur la régression des séries temporelles c'est-à-dire l'observation à un instant t d'une donnée est liée aux données des instants immédiatement précédents plus un bruit à l'instant t . Par exemple la population mondiale à un instant t dépend de l'évolution de cette même population dans le passé plus une marge d'erreur de la population mondiale à instant t . l'équation 2.1 est une représentations algébrique du modèle AR.

$$X_t = c + \sum_{i=1}^p \varphi_i X_{t-i} + \varepsilon_t \quad (2.1)$$

$\varphi_1, \dots, \varphi_p$ sont Les paramètres du modèle, ε_t (bruit blanc) est bien souvent omise dans la littérature [10][11].

2.1.3.2 Processus moyenne mobile MA

On appelle processus moyenne mobile (MA: pour Moving Average) d'ordre q un processus de la forme

$$X_t = \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (2.2)$$

Où les $\theta_1, \dots, \theta_q$ sont les paramètres du modèle et ε_t et ε_{t-i} sont des termes d'erreur [10][11].

2.1.3.3 Les processus mixtes ARMA

Les modèles ARMA qui sont des modèles autorégressifs et de moyenne mobile, sont des modèles de séries temporelles. Ils comportent deux parties : une partie autorégressive (AR) et une partie de moyenne mobile (MA). Il est souvent noté ARMA (p, q), où p est l'ordre de la partie AR et q est l'ordre de la partie MA.

Étant donné une série temporelle X_t , le modèle ARMA permet de comprendre et de prédire les valeurs futures de la série [4]. Le modèle ARMA (p, q) contient à la fois les modèles AR(p) et MA(q).

$$X_t = \varepsilon_t + \sum_{i=1}^p \varphi_i X_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (2.3)$$

2.1.3.4 Lissage exponentiel (Exponential Smoothing).

Les méthodes de lissage composent l'ensemble des techniques empiriques de prévision qui donnent plus ou moins d'importance aux valeurs du passé d'une série temporelle.

Nous présentons ici le lissage exponentiel simple (simple exponential smoothing). Le concept est simpliste mais la méthode fonctionne bien. Il consiste à calculer la prévision pour le temps $t+1$, par le calcul de la moyenne pondérée des dernières observations disponibles et de la dernière prévision calculée, par le biais de l'équation 2.4 qui est une relation de récurrence.

$$F_{t+1} = \alpha y_t + (1 - \alpha)F_t \quad (2.4)$$

α est appelé constante de lissage et varie de 0 et 1, $\alpha = 1$ correspondant à la méthode de prévision naïve [12], [13].

2.1.4 Méthodes d'intelligence artificielle

Les méthodes d'intelligence artificielle sont des procédés de calcul qui visent à doter les systèmes informatiques d'un comportement qui tend vers la capacité d'intelligence des êtres humains. Ces procédés de calcul sont inspirés des méthodes de calcul du cerveau humain. [14]

2.1.4.1 Réseaux de neurones

Les réseaux de neurones artificiels sont des algorithmes, utilisés dans plusieurs domaines dont l'optimisation, qui sont directement inspirés du fonctionnement des neurones biologiques. Comme la plus part des algorithmes d'optimisation, ils ont besoin de méthodes d'apprentissage pour ajuster les poids de l'algorithme. Les méthodes d'apprentissage utilisés pour les réseaux de neurones artificielles est généralement de type probabiliste, en particulier le type bayésien. Ils sont considérés de la famille des applications statistiques. Mais plus spécifiquement ils sont de la famille des méthodes de l'intelligence artificielle [15], [16].

2.1.4.2 Réseaux d'ondelettes.

Comme les réseaux de neurones, les réseaux d'ondelettes calculent une combinaison linéaire en fonction des paramètres ajustables, de fonctions non-linéaires dont la forme dérive de paramètres ajustables (translations, dilatations pour les paramètres des ondelettes dans les couches cachées et les poids du réseau). Cependant les particularités par rapport aux réseaux de neurones est que les ondelettes ont une décroissance rapide et tendent vers zéro contrairement aux fonctions dorsales des réseaux de neurones, aussi la forme des ondelettes est lié à deux paramètres structurels [17].

2.1.4.3 Support vector machines(SVM)

Un «support vector machine » (SVM) est un algorithme d'apprentissage qui est souvent appelé séparateur à vaste marge. Les SVM sont originellement définis pour la discrimination. Les SVM ont de bonnes propriétés de généralisation [18].

2.1.5 Forme d'apprentissage

Dans la littérature on trouve plusieurs formes d'apprentissage pour les algorithmes d'optimisation pour ajuster leurs paramètres. Le choix de la méthode d'apprentissage dépend de l'application, de la nature des données et des ressources dont on dispose pour l'implantation du système [16].

2.1.5.1 Apprentissage supervisé

L'apprentissage d'un algorithme d'optimisation est surveillé, pendant l'entraînement des paramètres de l'algorithme, lorsqu'on le force à converger vers un état final en même temps qu'il reçoit des données. Dans cette approche, l'ajustement des paramètres se fait pendant que l'algorithme roule [16].

2.1.5.2 Apprentissage non-supervisé

Contrairement à l'apprentissage supervisé, l'algorithme d'optimisation est laissé libre c'est-à-dire que si l'erreur s'éloigne de zéro, les paramètres ne seront pas automatiquement ajustés pendant que l'algorithme roule [16].

2.1.6 Performance des modèles

Il existe plusieurs modèles de prédiction dans la littérature. Nous avons la méthode de persistance, l'approche physique, statistique, hybride etc.

Pour la prédiction à court et très court terme l'approche statistique est celle que nous trouvons la plus appropriée, si on se fie à la littérature [19], [20]. Les réseaux de neurones sont des méthodes parmi les plus utilisées (Feed- Forecasting, Reccurent, Perceptron ADALINE, etc.), ainsi que les séries temporelles (ARX, ARMA, ARIMA, Grey Predictors, Smoothing etc.), les réseaux d'ondelettes, et les Support Vector Machines SVM [8]. Les méthodes hybrides donnent aussi de bons résultats pour ce qui est de la prédiction à court et à très court terme. Mais ces méthodes sont en général plus complexes et couteuses à réaliser. Quelques exemples de méthodes hybrides sont NWP (Numerical weather prediction)+NN(neural networks), ANN (artificial neural networks) + adaptive network-based fuzzy inference system (ANFIS) etc [8]. Le tableau 2-1 donne un aperçu des différentes méthodes de prédiction.

Tableau 2-1 Comparaison de quelques méthodes de prédiction [8]

Méthode prédiction	Sous-classe	Exemples	Remarque
Persistance méthode/ prédiction naïve	-	$P(t + k) = P(t)$	Approche Benchmark-très précise pour le court et très court terme.
Approche physique	Numeric weather Predictors (NWP)	Global Forecasting System- MM5 - Predictor - HIRLAM	-Utilisé pour les données météorologiques (vitesse et la direction du vent, pression, température humidité). -Précise pour le long terme.
Approche statistique	Artificial Neural Network (ANN)	- Feed-forward - Recurrent -Multilayer Perceptron -Radial Basis Function - ADALINE.	- Précise pour le court terme -Leurs structures hybrides utiles pour les moyennes et les prévisions à long terme -Habituellement, surpasser les modèles chronologiques
	Modèle de série temporelle	- ARX - ARMA - ARIMA - Grey Predictors -Linear Predictions -Exponential Smoothing.	- Précise pour le court terme - Quelques très bons modèles de séries chronologiques remplacent les structures NN
Quelques nouvelles techniques	--	-Spatial Correlation - Fuzzy Logic - Wavelet Transform -Ensemble Predictions - Entropy based training.	- La corrélation spatiale est bonne pour le court terme. - L'entropie de formation basée sur le modèle améliore les performances. - Compte tenu de la non-Gaussienne d'erreur améliore la précision.
Structure Hybride	--	NWP+NN - ANN + Fuzzy logic = ANFIS - Spatial Correlation + NN	ANFIS est très bon pour la prévision à très court terme. - NWP + NN structures sont très précises pour les prévisions à moyen et à long terme.

2.1.7 Évaluation comparative

Pour la prédiction à court terme il y a une large variété de méthodes disponibles dans la littérature. Il n'est pas facile de dégager clairement la meilleure méthode mais il y a plusieurs d'entre elles qui donnent de bons résultats en termes de précision.

Les modèles de séries temporelles qui sont fonction ARMA donnent de bonnes performances dans un horizon à court et à très court terme. Ils sont souvent concurrencés par d'autres techniques de série temporelle comme les réseaux neurones, d'ondelettes et aussi des approches hybrides. Dans la littérature les méthodes hybrides ont de très bonnes précisions [8].

On remarque que les réseaux de neurones ont un avantage classique [8], [21], [9]. Cette avantage n'est pas toujours vrai, puis qu'il existe des cas où les modèles ARMA donnent de meilleurs résultats [20].

Bien qu'il n'y ait pas de gagnant clair, les réseaux de neurones et d'ondelettes ou les neurones hybrides donnent de bons résultats globaux pour la prévision à court terme.

Nous trouvons particulièrement intéressant les réseaux d'ondelettes combinés à l'analyse multi résolution (AMR). À cause de la non-linéarité des ondelettes et aussi de l'apport de l'AMR, qui permet la séparation de l'information contenue dans les données d'entrée selon leur nature (par exemple: la saisonnalité, la périodicité, le contenu fréquentiel, et le bruit etc.). Ce qui, théoriquement va faciliter la prédiction, puisque cette opération nous permettra d'identifier selon le résultat de la décomposition les contenus qui ont de fort potentiel de prédictibilité et ceux qui en ont moins. Comme les données de vitesse du vent ont une prédictibilité basse à cause de son caractère stochastique, il est important d'identifier leur contenu prédictible.

Les ondelettes ont des particularités intéressantes par rapport aux fonctions d'activation utilisées dans les réseaux de neurones classiques. Elles ont deux paramètres internes ajustables de dilation et de translation qui sont intéressants dans le suivi de la variation des données. Cette caractéristique des ondelettes dans la couche cachée du réseau d'ondelettes,

est attirante puisqu'elle permet d'identifier des particularités dans les données et aide à prédire ce genre d'information [22], [23].

On va illustrer quelques résultats d'articles sur les modèles statistiques pour la prédiction à court terme en comparant les méthodes classiques, les réseaux de neurones et d'ondelettes.

Exemple 1 : Ici on compare les méthodes « de Persistence (PER)», «New Reference (NR)» et «Adaptive Wavelet Neural Network (AWNN)», cette dernière est une méthode de prédiction utilisant un réseau d'ondelettes [23]. Selon les résultats de comparaison, on remarque que l'AWNN est nettement plus précise que les deux autres méthodes (PER et NR) en relation aux erreurs MAE (Mean Absolute Error) et RMSE (Root Mean Square Error). Ce qui est illustré par le tableau 2.2 tiré de [23].

Exemple 2: Les résultats de simulation du tableau 2-3 sont déterminés pour une vitesse de vent variant de 4m/s à 25 m/s. Cette limitation de vitesse du vent est due aux limites physiques des éoliennes. La vitesse moyenne est de 15m/s [20].

Tableau 2-2 Comparaison de la méthode PER, NR, AWNN [23]

Horizon prédiction en heure	PER		NR		AWNN	
	MAE	RMSE	MAE	RMSE	MAE	RMSE
1	5.707	8.622	5.707	8.622	1.926	2.849
2	9.413	13.740	9.347	13.518	2.506	3.827
3	12.210	17.374	12.020	16.665	2.625	3.984
4	14.210	20.348	14.191	19.024	3.797	5.710
5	16.708	22.819	15.971	20.780	3.914	5.872
6	18.481	24.928	17.325	22.114	3.936	5.912
7	20.007	26.722	18.381	23.111	4.379	6.549
8	21.426	28.327	19.264	23.895	5.000	7.368
9	22.693	29.703	19.926	24.476	5.585	8.129
10	23.750	30.875	20.425	24.904	5.864	8.478
Moyenne	16,461	22,346	15,256	19,711	3,953	5,868
MAE et RMSE sont normalisées d'un parc éolien de 174MW						

Selon les résultats des erreurs MAE et le RMSE de la prédiction utilisant les méthodes ARMA et le ANN pour 1 heure avant, on remarque dans ce cas que la méthode ARMA permet d'obtenir des résultats légèrement plus précis que la méthode ANN. Dans le tableau 2-3 Simul a1 et b1 représente deux simulations différentes avec des paramètres différents du model ARMA. Simul 2a, 2b, 2c correspondent à trois simulation différentes avec des nombres de nœuds des couches caches du model ANN différentes.

Tableau 2-3 Comparaison des erreurs de prédiction [20]

Modèle	MAE [m/s]	RMSE [m ² /s ²]	MRE	Temps de traitement (s)
Persistance	0.6815	1.0005	0.0815	-
ARMA (simul. 1a)	0.5129	0.80998	0.0626	17367
ARMA (simul. 1b)	0.4996	0.7755	0.0597	590
ANN (simul. 2a)	0.5417	0.8058	0.0647	2772
ANN (simul. 2b)	0.5300	0.7750	0.0647	1993
ANN (simul. 2c)	0.5367	0.7857	0.653	1680

2.2 Les réseaux d'ondelettes

Les fonctions des ondelettes trouvent leur origine dans des travaux de mathématiciens des années 1930. L'idée au début était de construire une transformation, pour l'étude des signaux, plus intéressante que la transformation de Fourier. Les fonctions des ondelettes ont subi une évolution au cours des années. Les systèmes des ondelettes qui sont utilisés actuellement sont plus complexes que leurs prédécesseurs, et ont des caractéristiques intéressantes pour l'approximation des fonctions. En particulier, ils possèdent la propriété d'approximation universelle, ce qui suggère leur utilisation pour la construction de modèles de "boîte noire" [17].

2.3 Estimation de paramètres

L'estimation des paramètres est une composante essentielle dans les méthodes adaptatives d'estimation ou de prédiction de façon générale. La question est de trouver les paramètres pour que le modèle reproduise d'une manière optimale les observations ou la prédiction selon le cas.

La méthode de gradient est souvent utilisée pour l'ajustement des paramètres des algorithmes d'estimation ou de prédiction. Cependant, il existe d'autres méthodes d'optimisation comme la méthode des gradients conjugués de Newton, et celle d'optimisation unidimensionnelle [24], [22].

2.4 Conclusion

Nous avons constaté qu'il est très difficile de faire un choix clair parmi les méthodes de prédiction existantes dans la littérature. Cependant, concernant l'horizon de prédiction à court terme et très court terme, nous avons quelques méthodes de prédiction qui donnent de très bons résultats. Nous pouvons citer : les séries temporelles ARX, ARMA, ARIMA, Grey Predictors, Smoothing et les réseaux de neurones Feed-Forward, Recurrent, Perceptron, ADALINE, les méthodes hybrides et réseaux d'ondelettes.

Les chapitres à venir portent sur les concepts et sur l'application des réseaux d'ondelettes pour la prédiction étant donné leur performance.

Chapitre 3 - Transformée en Ondelettes et Analyse Multi-résolution

3.1 Introduction

Avant l'apparition (au XIX^e siècle) des ondelettes dans les traitements des signaux, l'analyse de Fourier était la technique utilisée pour la décomposition et la reconstruction d'un signal sans perte d'information. La méthode de Fourier a montré ses limites parce qu'elle permet une analyse en fréquence mais ne donne pas une localisation temporelle lorsque le comportement du signal varie brutalement. D'où l'intérêt des mathématiciens de trouver une autre forme d'analyse qui prendra en charge le comportement temporel du signal. Au XX^e siècle des solutions à ce problème commencent à se dégager. En 1909, Alfred Haar introduit l'ondelette de Haar, qui est supposée être la première ondelette [25]. C'est une fonction composée d'une impulsion négative et d'une impulsion positive. En 1946, le mathématicien Dennis Gabor invente une transformation de fonction qui est similaire à celle de Fourier, mais appliquée sur une fenêtre temporelle exprimée par une gaussienne. Et enfin le nom ondelette fut introduit dans le jargon des mathématiciens par Jean Morlet et Alex Grossmann en 1984 [26]. Yves Meyer, est un des fondateurs de la théorie des ondelettes, en 1986, il s'inspire des méthodes précédentes et définit les ondelettes orthogonales [26]. Stéphane Mallat fit le lien entre les ondelettes et l'analyse multi-résolution dans la même année. Par la suite en 1987, Ingrid Daubechies met en place des ondelettes orthogonales ou encore appelées ondelettes de Daubechies [27].

Dans ce chapitre les concepts de l'analyse multi-résolution des transformées d'ondelettes ainsi que des réseaux d'ondelettes seront introduits.

3.2 Définition d'une ondelette

Une ondelette est une représentation d'une fonction ou d'un signal. Elle est définie comme étant une somme pondérée des petites ondes translatées et ou dilatées. Elle permet un suivi fréquentiel et temporel simultané. Cette dernière propriété fait une différence entre l'analyse des signaux par les ondelettes et celle de Fourier. Parce que celle de Fourier permet uniquement un suivi fréquentiel [25].

Les différentes façons de représenter un signal sont :

- Les séries de Fourier;
- Les transformations de Fourier avec fenêtre mobile;
- Les transformées d'ondelettes.

3.3 Théorie de l'analyse multi-résolution

Une analyse multi-résolution (MRA) ou multi-échelle est pratiquement la méthode de conception de la plupart des transformées en ondelettes discrètes.

3.3.1 La transformée continue en ondelettes (TCO)

Soit $x(t)$ une fonction de variable réelle, TCO de x s'écrit comme suit, pour a différent de zéro.

$$g(a, b) = \frac{1}{\sqrt{a}} \int_{t=-\infty}^{t=+\infty} x(t) \psi_{a,b}(t) dt \quad (3.1)$$

$\psi_{a,b}(t)$ est une fonction obtenue par la translation et la dilatation d'une fonction appelée ondelette mère. Dans l'expression a correspond à l'échelle et b la position. Dans le cas d'un signal, a détermine la fréquence et b le temps.

$$\psi_{a,b}(t) = \psi\left(\frac{t-b}{a}\right) \quad (3.2)$$

Soit la fonction $x(t)$, elle peut être reconstruite par la fonction $g(a, b)$ tel que:

$$x(t) = \frac{1}{C_\psi} \int_{a=-\infty}^{a=+\infty} \frac{g(a, b)}{a^2} \psi_{a,b}(t) da db \quad (3.3)$$

où $\psi_{a,b}(t)$ est l'ondelette mère et C_ψ est une constante indépendante de l'ondelette mère.

Donc il suffit de connaître la fonction $g(a, b)$ en un nombre dénombrable de valeurs pour reconstruire $x(t)$ [27].

3.3.2 Transformée d'ondelette discrète (TOD)

La TOD de $g(n)$ une fonction, utilisant la fonction ondelette $\psi_{j,k}(n)$ et la fonction d'échelle $\varphi_{j_0,k}(n)$. Elle peut s'exprimer par les équations (3.4) et (3.5). Les fonctions $g, \psi_{j,k}, \varphi_{j_0,k}$ sont des fonctions discrètes de n et varie de $0, 1, 2, \dots, M-1$ avec $j_0 < j$.

$$W_\varphi(j_0, k) = \frac{1}{\sqrt{M}} \sum_n g(n) \varphi_{j_0,k}(n) \quad (3.4)$$

$$W_{\psi}(j, k) = \frac{1}{\sqrt{M}} \sum_n g(n) \psi_{j,k}(n) \quad (3.5)$$

Afin de simplifier la transformée inverse, on considère la valeur de M comme une puissance de deux ($M = 2^j$). Pour base orthonormée, la transformée inverse $g(n)$ s'écrit [28] :

$$g(n) = \frac{1}{\sqrt{M}} \sum_{k=0}^{2^{j_0}-1} W_{\varphi}(j_0, k) \varphi_{j_0,k}(n) + \frac{1}{\sqrt{M}} \sum_{j=j_0}^{j-1} \sum_{k=0}^{2^j-1} W_{\psi}(j, k) \psi_{j,k}(n) \quad (3.6)$$

3.3.3 Principe de base de l'analyse multi-résolution (AMR)

L'analyse multi-résolution ressemble à une cartographie. Pour chaque étape, le signal est remplacé par l'estimation la plus appropriée. En partant des échelles les plus brutes vers les plus raffinées. Ce qui donne des reproductions de plus en plus proches du signal donné. L'analyse se fait en évaluant la différence entre une échelle à une autre échelle. Ceux-ci permettent, de corriger une approximation assez grossière et accéder à une représentation d'une qualité meilleure. Le changement d'échelle, d'un sous espace à d'autres, inclus dans le premier sous espace est représenté par la figure 3-1.

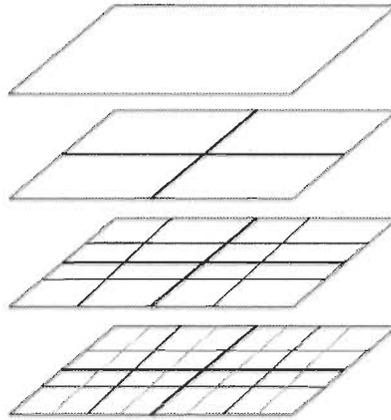


Figure 3-1 Cartographie des espaces vectoriels

Les ondelettes correspondent à des degrés de résolution: elles sont définies par la différence entre deux fonctions à échelles consécutives. Elles permettent de représenter les détails gagnés lors du passage d'une échelle à l'échelle plus petite suivante. Le principe de décomposition-reconstruction de S. Mallat est basé sur la décomposition d'une séquence discrète en différents niveaux correspondant à différentes bandes de fréquences spatiales. Pour sa réalisation, nous allons utiliser la théorie multi-résolution [29], [30].

L'analyse multi-résolution est construite à l'aide des sous espaces V_i emboîtés les uns dans les autres en emboitant de manière que le passage d'un à l'autre se fasse à l'aide d'un changement d'échelle [17], [31].

Soit V_i un sous espace de $L^2(\mathbb{R})$. L'ensemble des V_i tel que $i \in \mathbb{Z}$ forme une analyse multi-résolution si les sous espaces V_i vérifient les propriétés suivantes :

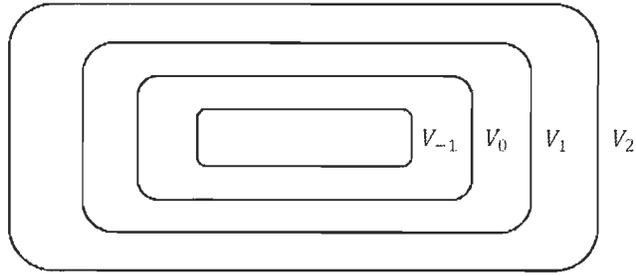


Figure 3-2 Disposition des sous espaces V_i

La figure 3-2 est une illustration de la propriété 1.

1. Croissance : les sous espaces V_i sont inclus les uns dans les autres comme illustré à la figure

$$\dots V_{-3} \subset V_{-2} \subset V_{-1} \subset V_0 \subset V_1 \subset V_2 \subset V_3 \dots$$

2. Densité : l'union de tous les sous espaces de $L^2(\mathbb{R})$ donne $L^2(\mathbb{R})$ c'est-à-dire l'espace $L^2(\mathbb{R})$ contient exclusivement les sous espaces V_j .

$$\cup_{j \in \mathbb{Z}} V_j = L^2(\mathbb{R}).$$

3. Séparabilité : l'intersection de tous les sous espaces de $L^2(\mathbb{R})$ donne l'ensemble vide.

$$\cap_{j \in \mathbb{Z}} V_j = \{0\}.$$

4. Dilation : les éléments des sous espaces sont liés par la relation suivante.

$$\text{Si } X(t) \in V_0 \text{ alors } X(2^m t) \in V_m$$

5. Translation : les éléments des sous espaces sont liés par la relation suivante.

$$\text{Si } X(t) \in V_0 \text{ alors } X(t - n) \in V_n$$

6. Base orthonormée de V_0 :

$$\exists \varphi(t) \in V_0 \text{ tel que } \{\varphi(t - k) \text{ quelque soit } k \in \mathbb{Z}\}$$

est une base orthonormale de V_0

Dans l'analyse multi-résolution, le signal est construit par raffinement successif du signal de base plus les détails. La fonction principale sur laquelle se base le processus d'analyse multi-résolution est l'ondelette père plus généralement appelée fonction d'échelle et l'ondelette mère.

3.3.4 Sous-espaces contenant le détail (AMR).

La relation d'emboîtement des différents espaces vecteurs V_j $j \in \mathbb{Z}$ ne permet pas de rassembler les fonctions échelle φ pour construire une base orthogonale de $L^2(\mathbb{R})$ [32]. L'intersection de V_j et de V_{j+1} est l'information de détail perdue à cause de la transition de j à $j+1$ d'où la construction des sous-espaces fermés $(W_j)_{j \in \mathbb{Z}}$, contenant la fonction nécessaire pour représenter le détail [32], [33].

Dans analyse de multi-résolution à fonction d'échelle φ , les espaces vectoriels $(V_j)_{j \in \mathbb{Z}}$ et les sous-espaces vectoriels $(W_j)_{j \in \mathbb{Z}}$ doivent vérifier les propriétés suivantes [31]:

1. Soient V_j et W_j deux sous-espaces orthogonaux et complémentaires de V_{j-1} , ce qui implique : $V_{j-1} = V_j \oplus W_j$ comme illustré à la figure 3-4
2. Les sous-espaces W_j quel que soit j élément \mathbb{Z} sont denses dans V_n

$$V_n = \bigoplus_{j=n+1}^{\infty} W_j$$

3. $\bigoplus_j W_j$ est dense dans L^2
4. W_i et W_j sont orthogonaux ($W_i \perp W_j$) si j différent de i .
5. Soit $f(x) \in W_j$ équivaut à $f(x/2) \in W_{j+1}$
6. Et $f(x) \in W_j$ équivaut à $f(x - 2^{-j}k) \in W_{j+1}$
7. \exists une fonction Ψ (ondelette mère non unique) tq $\{\Psi(x - k), k \in \mathbb{Z}\}$

forme une base orthonormée de W_0 et $\left\{ \psi_{j,k} = 2^{-\frac{j}{2}} \psi(2^{-j}x - k), k \in \mathbb{Z}, \right.$
 $\left. j \in \mathbb{Z} \right\}$

forme une base orthonormée de L^2

8. $\psi \in V_{-1}, \psi\left(\frac{x}{2}\right) \in V_0 \Rightarrow$ on peut écrire

$$\psi\left(\frac{x}{2}\right) = \sqrt{2} \sum_k g_k \varphi(x - k) \text{ avec } g_k = (-1)^k h_{N-k} \text{ ou } N \text{ est entier impair}$$

[33]

La figure 3.4 nous permet de visualiser la disposition de sous-espaces V_j par rapport aux sous-espaces W_j .

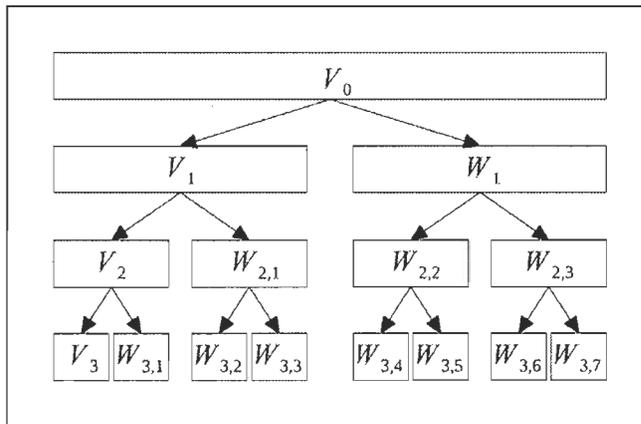


Figure 3-3 Configuration des espaces vectoriels dans AMR [27]

3.3.5 Ondelette père

Soit φ définie sur \mathbb{R} est une fonction d'échelle si

$$\int \varphi(x) dx = 1 \quad (3.7)$$

et il existe une suite de coefficients h_k tel que:

$$\varphi\left(\frac{x}{2}\right) = \sqrt{2} \sum_{k=k_0}^{k=k_1} h_k \varphi(x-k) \quad \text{avec } k \in Z \quad (3.8)$$

Pour le calcul, il faut que k_0 et k_1 soient finis et que φ soit un support compact d'un espace vectoriel. La fonction d'échelle φ de niveau j est exprimée comme une somme pondérée des fonctions de niveau supérieur. Cette propriété correspond à l'équation de raffinement [34].

3.3.6 Ondelette mère

Une ondelette mère est une fonction de base qui peut être translatée et dilatée, et permet de suivre le plan temps-fréquence afin d'analyser un signal, c'est-à-dire que l'ondelette mère doit être une onde qui doit vérifier l'équation 3.9. [5].

$$\int \psi(x) dx = 0 \quad (3.9)$$

Les ondelettes d'une même famille sont générées en faisant varier le paramètre de dilatation a et de translation b dans le temps.

$$\psi_{ab}(x_i) = \left(1 - \left(\frac{x_i - b}{a}\right)^2\right) e^{-0.5\left(\frac{x_i - b}{a}\right)^2} \quad \text{avec } a \in R^* \text{ et } b \in R \quad (3.10)$$

La figure 3-5 illustre la dilatation et la translation d'ondelette mère (Chapeau mexicain) ce qui se traduit respectivement par la variation a et b .

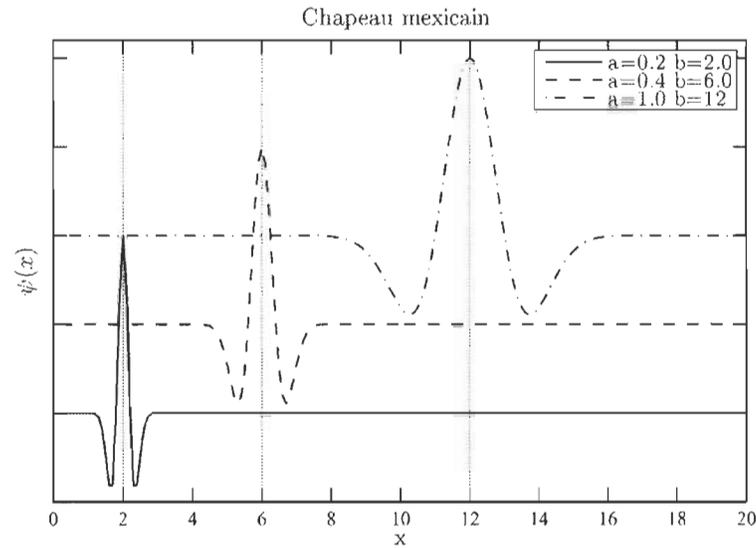


Figure 3-4 Dilatation et translation d'ondelette

3.3.7 Les bases orthonormées d'ondelettes

En mathématiques, les systèmes orthogonaux d'espace fonctionnel sont souvent utilisés dans les applications du traitement des images [35]. Il consiste à faire la représentations d'une fonction par une série ou une famille de coefficients [6].

Soit une base d'ondelettes de $L^2(\mathbb{R})$ composée de fonction $\Psi_{j,k}$ avec $j, k \in \mathbb{Z}$. Ψ est une ondelette mère associée à la fonction d'échelle φ et elle peut s'écrire sous la forme:

$$\Psi_{j,k}(x) = 2^{-\frac{j}{2}} \Psi(2^{-j}x - k) \quad (3.11)$$

Où j est l'indice d'échelle et k est l'indice de position.

Si j ne varie pas alors $\{\Psi_{j,k}, k \in \mathbb{Z}\}$ est une base de W_j .

Pour Ψ de support de longueur l alors $\Psi_{j,k}$ auront des supports de longueur $2^j l$. j représente le niveau de détail que l'ondelette mère $\Psi_{j,k}(x)$ permet d'analyser. Et k détermine la position de l'ondelette sur l'axe des x [3], [4].

3.3.8 Décomposition et reconstruction

L'opération de la décomposition et de la reconstruction s'exécute par des calculs de convolution à l'aide de filtres numériques d'ondelettes ou en baissant et augmentant l'échantillonnage selon qu'on fait la décomposition ou la reconstruction.

Nous allons présenter les algorithmes de calcul de la décomposition et reconstruction discrètes et finies. Cette présentation se base sur l'équation (3.12) [27], [36].

Soit L^2 un espace vectoriel et V_j, W_j des sous espaces orthogonaux de L^2 .

(φ, ψ) une ondelette orthogonale connue par les coefficients (h_k, g_k) . Considérons la fonction f dans L^2 et $s_j[k], d_j[k]$ les composants de f dans la base V_j et W_j ce qui implique qu'on a :

$$s_j[k] = (f, \varphi_{j,k}) \quad \text{et} \quad d_j[k] = (f, \psi_{j,k}) \quad (3.12)$$

Le principe de base du calcul de la décomposition est une suite de convolution d'un signal (s_j) avec des filtres numériques d'ondelette passe bas (g_j) et passe haut (h_j) et d'échantillonnage du signal de sortie de la convolution. Cette opération est décrite dans l'équation (3.13) et (3.14) et illustré dans la figure 3-5.

$$s_{j+1}[k] = \sum_{p=-\infty}^{\infty} h_{p-2k} s_j[p] = s_j * h^-[2k] \quad (3.13)$$

$$d_{j+1}[k] = \sum_{p=-\infty}^{\infty} g_{p-2k} s_j[p] = s_j * g^-[2k] \quad (3.14)$$

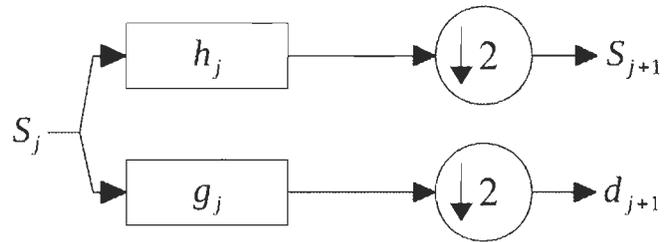


Figure 3-5. Algorithme décomposition analyse de Mallat [33]

Le principe de calcul de la reconstruction s'effectue de la même manière que la décomposition, cependant les filtres de décomposition sont remplacés par de filtres numériques de reconstruction, l'échantillonnage est remplacé par l'interpolation, et on fait la somme des deux signaux de sortie, comme illustré à la figure 3-6.

$$s_j[k] = \sum_{p=-\infty}^{\infty} h_{k-2p} s_{j+1}[p] + \sum_{n=-\infty}^{\infty} g_{k-2p} d_{j+1}[n] \quad (3.15)$$

$$= s'_{j+1} * h'[k] + d'_{j+1} * h[k] \quad (3.16)$$

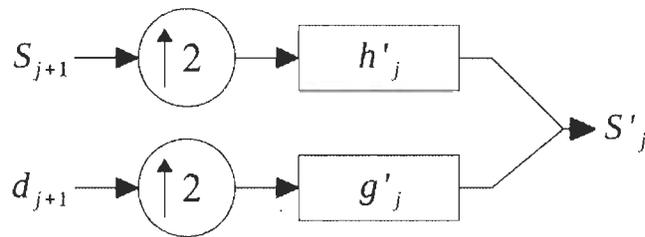


Figure 3-6 Algorithme de reconstruction de Mallat [33]

3.3.9 Banc de filtres

Les bancs de filtres sont des outils de traitement de signaux. Ils permettent de trouver des informations particulières contenues dans les signaux. Par exemple, dans l'analyse multi-résolution des bancs filtres discrets à deux chemins sont utilisés pour la décomposition, dans le premier chemin on fait une convolution d'un signal avec un filtre passe-bas et un filtre passe-haut dans le second chemin, à la sortie des deux canaux on baisse l'échantillonnage de moitié. Pour la reconstruction on recueille les signaux décomposés que l'on traite avec des filtres de reconstruction, et on insère une valeur moyenne entre deux échantillons successifs du signal obtenu en faisant une interpolation du signal issu de la convolution. La figure 3.7 permet d'illustrer un banc de filtres.

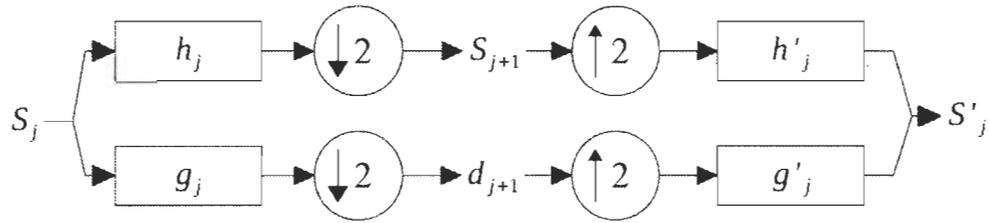


Figure 3-7 Banc de filtres

3.3.10 Relation entre l'ondelette et les coefficients des filtres

La clef de l'analyse multi-résolution est la détermination des coefficients pour la décomposition et la reconstruction des signaux. Ces coefficients sont exprimés en fonction des ondelettes pères φ et mères Ψ comme décrit précédemment. Cette relation est définie par l'équation 3.17, 3.18, 3.19 [32].

$$\varphi_{j,k} = \sum_{n=-\infty}^{+\infty} h_{n-2k} \varphi_{j+1,n} \quad (3.17)$$

$$\Psi_{j,k} = \sum_{n=-\infty}^{+\infty} g_{n-2k} \varphi_{j+1,n} \quad (3.18)$$

$$\varphi_{j+1,k} = \sum_{n=-\infty}^{+\infty} \overline{h_{k-2n}} \varphi_{j,n} + \sum_{n=-\infty}^{+\infty} \overline{g_{k-2n}} \Psi_{j,n} \quad (3.19)$$

3.3.11 Détermination des coefficients de décomposition : Ondelette de Daubechies

Les coefficients des ondelettes de Daubechies pour la décomposition et la reconstruction de signaux sont obtenus à partir du théorème 3.2 qui permet de calculer les coefficients pour les filtres de décomposition.

Théorème 3.2:

Considérons $h_0, \dots, h_{2N-1} \in R$, les coefficients d'une $N\varphi$

Ce qui équivaut à :

1. $\sum_{k=0}^{2N-1} h_k = \sqrt{2}$;
2. $\sum_{k=0}^{2N-1} (-1)^k k^n h_k = 0$
3. $\sum_{k=0}^{2N-1} h_k h_{k-2n} = 0$

Pour une valeur de N données nous pouvons faire la résolution du système d'équations et déterminer les coefficients h [17].

3.4 Les réseaux d'ondelettes:

Le fonctionnement des réseaux d'ondelettes est semblable aux réseaux de neurones à fonctions dorsales dans le sens que, les deux types de réseaux calculent une combinaison linéaire tout en ajustant les paramètres de la fonction non-linéaire dont la forme dépend de ces paramètres. La complexité du réseau dépend de deux paramètres importants: le nombre de paramètres ajustables et le nombre d'opérations élémentaires [5].

La performance du réseau dépend essentiellement du nombre d'entrées et du nombre de couches cachées selon le type de donnée. C'est-à-dire que, la façon dont les données d'entrées se comportent (haute fréquence et basse fréquence par exemple). Généralement, la détermination de la bonne combinaison du nombre de données d'entrée et du nombre de couches cachées se fait par essai-erreur.

L'ondelette utilisée dans la couche cachée de notre réseau ondelette est un chapeau mexicain (3.19) tel que montré par la Figure 3-8.

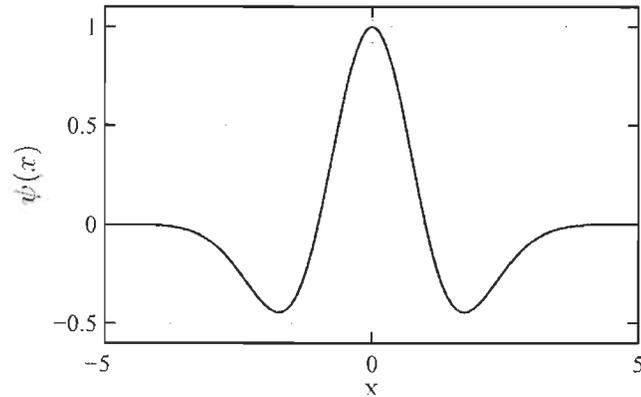


Figure 3-8 Ondelette de « chapeau mexicain ».

$$\psi(x) = (1 - x^2)e^{-0.5x^2} \quad (3.20)$$

3.4.1 Une ondelette multidimensionnelle

Une ondelette multidimensionnelle est le produit d'ondelettes monodimensionnelles [15]. Lorsque dans une couche cachée d'un réseau de neurones, il n'y a qu'une seule ondelette on dit qu'elles sont séparées ou qu'il s'agit d'ondelettes monodimensionnelles. L'équation suivante représente une ondelette multidimensionnelle.

$$\psi_j(x) = \prod_{i=1}^n \psi_{ij}(x) \quad (3.21)$$

Les réseaux d'ondelettes sont des réseaux de fonctions non-linéaires paramétrées, où le vecteur est constitué par les translations et les dilatations de l'ondelette multidimensionnelle.

Le schéma de la figure 3.9 représente la structure d'un réseau d'ondelettes.

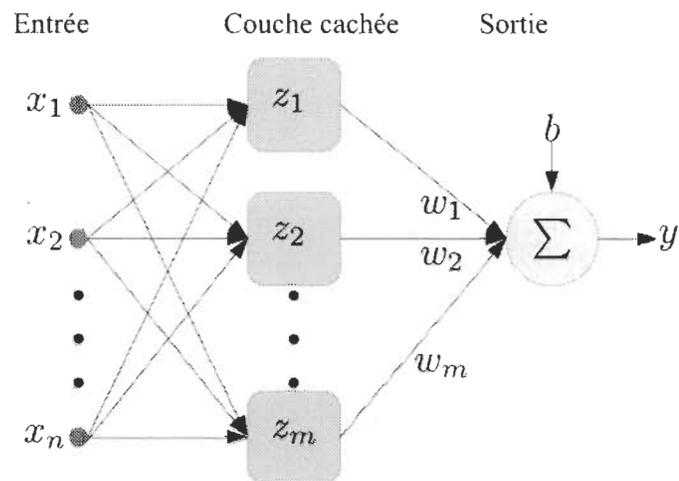


Figure 3-9 Réseau d'ondelettes [15].

La figure 3-10 schématise la structure de la couche cachée du réseau-ondelette de la figure 3-9.

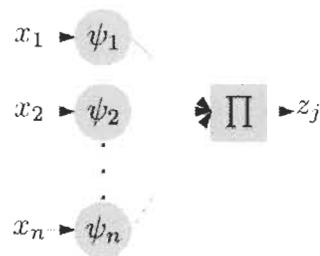


Figure 3-10 Structure de la couche cachée.

3.5 Conclusion

Considérant les limites de l'analyse de Fourier dans plusieurs domaines, l'introduction des ondelettes dans l'analyse de signaux est considérée comme une découverte importante pour le traitement de signal dans le domaine des sciences appliquées. Elles ont apporté une alternative à l'analyse de Fourier qui est mieux adaptée à la nature de certains phénomènes.

Ce chapitre a permis de mieux cerner la théorie de base des ondelettes, de comprendre le principe de base des transformées d'ondelette ainsi que l'analyse multi-résolution et ses propriétés fondamentales.

Chapitre 4 - Système de prédiction

L'intégration des énergies renouvelables au réseau est un réel défi à cause de leurs intermittences. La prédiction des sources d'énergies renouvelables est très importante dans la gestion des réseaux électriques (ayant des sources d'énergie renouvelable), car la stabilité de ces derniers est liée à l'équilibre de l'offre et de la demande de puissances du réseau.

La prédiction est un maillon important dans la gestion des sources d'énergie renouvelable. Il permet au système d'anticiper la puissance que les sources renouvelables pourraient fournir dans un horizon de court terme. Ce qui permet de prendre des décisions au niveau de la gestion afin d'assurer la stabilité du réseau.

Dans cette section il serait question de la méthode de prédiction qui a été proposée dans le cadre de ce projet. A savoir la théorie liée à cette méthode, ainsi qu'une description compréhensible des différentes parties du système.

4.1 Étude de la prédictibilité des données

Pour développer une méthode de prédiction il est important de bien analyser la prédictibilité des données et de définir une méthode pour les évaluer. La méthode de prédiction choisie pour ce projet utilise la décomposition et la reconstruction des données. Ce qui rend pertinent l'étude de prédictibilité des données. Nous allons évaluer spécifiquement la prédictibilité de toutes les composantes de la décomposition. Nous utilisons le calcul du coefficient de Hurst pour notre évaluation.

Exposant de Hurst : Hurst a proposé en 1951 une méthode pour la quantification de la mémoire à long terme[37] . L'exposant ou coefficient de Hurst est utilisé comme mesure de la mémoire à long terme de la série chronologique. Cette méthode se rapporte à des autocorrélations de la série de temps. Ainsi le coefficient de Hurst fournit une mesure de la prévisibilité d'une série de données [38].

L'exposant Hurst, H, est défini de manière à avoir un comportement asymptotique de la gamme rééchelonné en fonction de l'intervalle de temps d'une série chronologique comme suit :

$$E \left[\frac{R(n)}{S(n)} \right] = Cn^H \text{ Avec } n \text{ tend vers } +\infty$$

R (n) est la plage de premières valeurs de N et S (n) est l'écart-type. n est l'espace de temps de l'observation (nombre de points de données dans une série chronologique). E(x) est la valeur attendue et C un constant.

Estimation de l'exposant

Pour estimer l'exposant de Hurst, il faut d'abord estimer la dépendance de la gamme rééchelonné sur l'espace de temps d'observation n . Une série temporelle de longueur N est divisée en un certain nombre de séries chronologiques plus courtes de longueur $n = N, N/2, N/4, \dots$. La gamme rééchelonnée moyenne est ensuite calculée pour chaque valeur de n .

Pour une (partielle) série de temps de longueur n , $X = X_1, X_2, \dots, X_n$ la gamme rééchelonnée est calculé comme suit:

$$\text{Calcul de la moyenne } m = \frac{1}{n} \sum_{i=1}^n X_i.$$

Créer une série moyenne ajustée $Y_t = X_t - m$ avec variant de 1 à n .

Calculer la série à écart cumulatif Z ; $Z_t = \sum_{i=1}^t Y_i$ pour $t = 1, 2, \dots, n$.

Calculer la gamme R , $R(n) = \max(Z_1, Z_2, \dots, Z_n) - \min(Z_1, Z_2, \dots, Z_n)$.

Calculer l'écart type S ,
$$S(n) = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - m)^2}$$

Calculer la gamme rééchelonnée $R(n)/S(n)$ et moyenne sur toutes les séries de temps partielles de longueur n .

L'exposant Hurst est estimé en ajustant la loi de puissance $E \left[\frac{R(n)}{S(n)} \right] = Cn^H$ aux données.

Ceci peut être effectué en traçant le logarithme de $E \left[\frac{R(n)}{S(n)} \right]$ en fonction de $\log n$, et une régression linéaire; la pente de la droite donne H [39].

4.2 *Modèle de prédiction*

Le modèle de prédiction que nous avons adopté pour notre application se présente comme suit. Premièrement les données recueillis passent par une phase de décomposition à base d'ondelettes afin de traiter l'information reçue de manière spécifique. Les résultats de la décomposition sont envoyés à l'algorithme d'entraînement et de prédiction. Enfin, les résultats de la prédiction sont envoyés à l'algorithme de reconstruction (afin de reconstruire les données décomposées). La théorie liée à la décomposition et à la reconstruction a été abordée au chapitre 3. La figure 4-1 donne une illustration générale de la structure du système de prédiction.

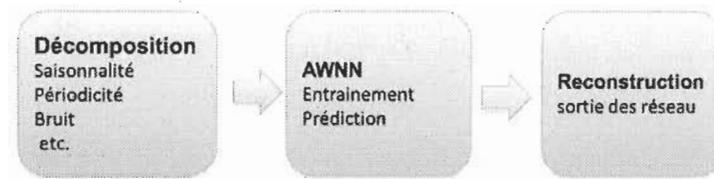


Figure 4-1 Structure générale du système de prédiction.

4.3 Décomposition

Les décompositions utilisées dans ce travail sont basées sur l'analyse multi-résolution. Les filtres utilisés dans la décomposition sont des filtres d'ondelette Daubechies. Elles sont schématisées à la figure 4-2 et figure 4-8.

Principe de fonctionnement de la décomposition :

La décomposition se déroule comme suite :

Les données sont passées en parallèle dans deux filtres de décomposition passe haut et passe bas (Les coefficients des deux filtres numériques ont été déterminés en fonction des ondelettes de Daubechies) à la sortie de chaque filtre on baisse l'échantillonnage des données de moitié. La sortie du filtre passe haut est conservée et celle du bas est de nouveau passée en parallèle par les mêmes filtres passe bas et passe haut et on fait baisser l'échantillonnage également. On répète cette opération deux fois de suite. À la fin on obtient quatre signaux de haute fréquence nommés $(d_1 d_2 d_3 d_4)$ et un signal de basse fréquence nommé A_4 . Ce qui est illustré à la figure 4-2.

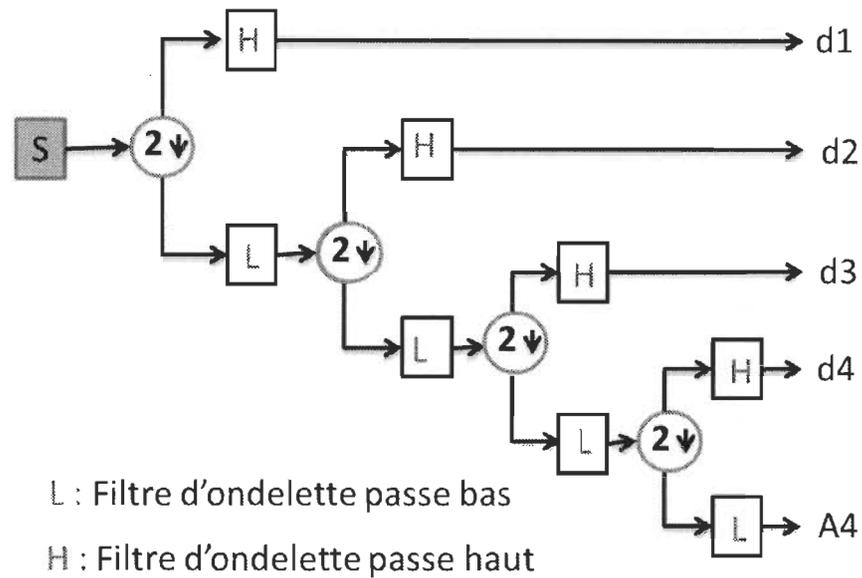


Figure 4-2 Décomposition des données d'entrée.

4.4 Prédiction

La prédiction est basée sur l'analyse de séries temporelles. L'algorithme utilisé dans ce travail est le réseau d'ondelettes qui est inspiré des réseaux de neurones. Dans notre cas, la prédiction est faite pour chaque signal de la décomposition (d_1 , d_2 , d_3 , d_4 , A_4). L'entrée de chaque réseau d'ondelette est un paquet de données qui varie selon la nature des données et comprend une suite chronologique de données allant du présent à quelques données du passé immédiat. Elles sont traitées par un réseau d'ondelettes pour la prédiction. Elle s'effectue en se basant sur les données présentes et passées (qui définit une tendance) et les propriétés d'apprentissage des réseaux d'ondelettes pour prédire une donnée dans le futur.

4.4.1 Architecture du réseau d'ondelette

La structure générale des réseaux d'ondelettes (WNN : Wavelet Neuron Network) comporte une couche d'entrée, une couche cachée d'ondelette et une couche de sortie.

L'ondelette mère utilisée pour cette application est la dérivée seconde de la fonction gaussienne. Elle est présentée par l'équation 4.1.

$$\psi(x) = (1 - x^2)e^{-0.5x^2} \quad (4.1)$$

Pour intégrer l'équation 4.1 dans l'algorithme de WNN nous la réécrivons sous sa forme discrète et est présenté à l'équation 4.2.

$$\psi_{ab}(x_i) = \left(1 - \left(\frac{x_i - b}{a}\right)^2\right) e^{-0.5\left(\frac{x_i - b}{a}\right)^2} \quad (4.2)$$

Il est important de déterminer de façon appropriée les coefficients a et b , puisque la contribution des ondelettes dans l'algorithme du réseau d'ondelette est déterminée par le choix de ces paramètres. Les paramètres a et b sont introduits dans l'expression de l'ondelette mère par l'équation 4.2.

L'ondelette multidimensionnelle z_j est le produit des n ondelettes mères de l'équation 4.2. n étant le nombre d'entrées du réseau d'ondelette, elle est définie dans la couche cachée du réseau.

$$z_j = \prod_{i=1}^n \psi_{a_{ij}b_{ij}}(x_i) \quad (4.3)$$

Où

$$\psi_{a_{ij}b_{ij}}(x_i) = \left(1 - \left(\frac{x_i - b_{ij}}{a_{ij}}\right)^2\right) e^{-0.5\left(\frac{x_i - b_{ij}}{a_{ij}}\right)^2} \quad (4.4)$$

La figure 4.4 permet de bien visualiser l'architecture du réseau d'ondelettes, nous pouvons voir que la couche d'entrée est constituée des données d'entrée, celle cachée porte l'ondelette multidimensionnelle z_j et la dernière couche est la sortie du réseau.

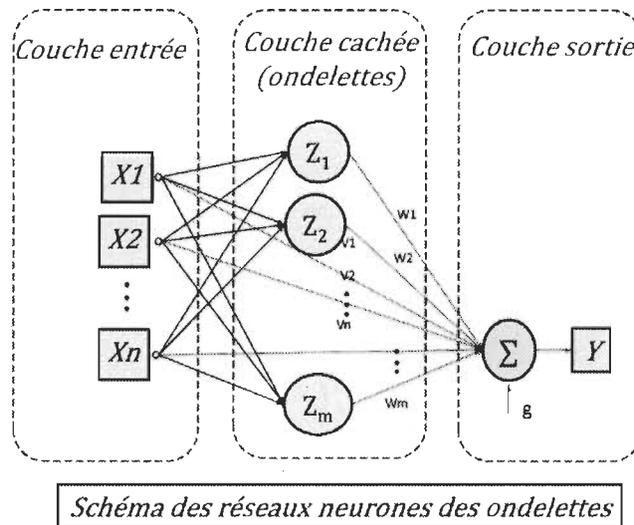


Figure 4-3 Réseau d'ondelette [40]

Le schéma de la figure 4.4 équivaut à l'équation 4.5 qui correspond à l'expression algébrique du schéma.

$$Y = \sum_{j=1}^m w_j z_j + \sum_{i=1}^n v_i x_i + g \quad (4.5)$$

Pour faire une bonne prédiction, il faut déterminer de façon optimale les paramètres w_j , v_i et g ainsi que les paramètres internes de z_j (a et b). Ce processus est appelé entraînement ou optimisation des poids synaptique [22], [23].

4.4.2 Optimisation des paramètres

Cet exercice est appelé entraînement. Dans ce cas on fait un entraînement en ligne c'est-à-dire que les paramètres sont ajustés pendant que le processus de prédiction est en marche. Plus précisément, après l'initialisation du système on procède à un premier ajustement des paramètres, ces paramètres sont envoyés à l'algorithme de prédiction. Par la suite le système surveille l'erreur de prédiction. Dès que l'erreur arrive à un seuil que nous fixons le processus d'entraînement se relance de nouveau et ainsi de suite.

L'optimisation des poids se base sur la minimisation de la fonction de coût définie comme suit :

$$E = \frac{1}{2N} \sum_{p=1}^N e(p)^2 \quad (4.6)$$

Avec:

$$e(p) = y^*(p) - y(p) \quad (4.7)$$

$y^*(p)$ est la valeur à prédire ou valeur désirée et $y(p)$ est la valeur prédite.

Le but de cette optimisation est de déterminer d'une manière optimale les poids w_j , v_i , a_{ij} , b_{ij} et g de l'algorithme de prédiction. Ce qui revient à calculer la dérivée partielle de la fonction de coût E , selon chacune des variables à optimiser (les poids).

$$\nabla_{w_j} = \frac{\partial E}{\partial w_j} = \frac{\partial E}{\partial y} \frac{\partial y}{\partial w_j} = ez_j \quad (4.8)$$

Avec

$$w_j(k + 1) = w_j(k) + \eta \nabla w_j(k) + \alpha \nabla w_j(k - 1) \quad (4.9)$$

Où α est un paramètre dynamique qui doit être déterminé par « essai-erreur ». Ce paramètre permet d'accélérer la convergence vers le minimum en amortissant les oscillations et peut également aider à sortir d'un minimum local [41]; η est le taux d'apprentissage; et k est un entier naturel déterminant le nombre de fois où on repasse les données dans l'algorithme de prédiction pour faire l'apprentissage des poids;

L'équation 4.10 nous permet d'ajuster le taux d'apprentissage en fonction du signe de l'erreur [22].

$$\eta(n + 1) = \begin{cases} 1.05 \eta(n) & ; \nabla E(n) > 0 \\ 0.7 \eta(n) & \text{si non} \end{cases} \quad (4.10)$$

L'équation 4.9 permet de déterminer une nouvelle valeur de la variable à optimiser qui aide à faire converger le gradient de la fonction de coût par rapport à w vers zéro. Elle est valable pour tous les paramètres à optimiser. Le paramètre η (le taux d'apprentissage) permet de contrôler la vitesse de convergence du gradient de la fonction de coût et α est un paramètre dynamique.

Le processus de l'actualisation des paramètres est répété pour tous les autres paramètres du réseau d'ondelettes tel que décrit algébriquement ci-dessous. L'équation 4.11 représente le gradient de la fonction de coût (E) par rapport au paramètre v . Ce gradient est utilisé par la suite pour l'actualisation de v dans l'équation 4.12. Ce calcul est effectué pour tous les autres paramètres du réseau d'ondelettes.

$$\nabla v_i = \frac{\partial E}{\partial v_i} = - \frac{\partial E}{\partial y} \frac{\partial y}{\partial v_i} = e x_j \quad (4.11)$$

$$v_i(k+1) = v_i(k) + \eta \nabla v_i(k) + \alpha \nabla v_i(k-1) \quad (4.12)$$

$$\nabla g = \frac{\partial E}{\partial g} = - \frac{\partial E}{\partial y} \frac{\partial y}{\partial g} = e \quad (4.13)$$

$$g(k+1) = g(k) + \eta \nabla g(k) + \alpha \nabla g(k-1) \quad (4.14)$$

$$\nabla a_{ij} = \frac{\partial E}{\partial a_{ij}} = - \frac{\partial E}{\partial y} \frac{\partial y}{\partial z_j} \frac{\partial \psi_{ij}}{\partial \psi_{ij}} \frac{\partial z_j}{\partial a_{ij}} \quad (4.15)$$

$$= e w_j z_j \left[\frac{1}{a_{ij}} \right] \left[\frac{x_i - b_{ij}}{a_{ij}} \right]^2 \left[3 - \left[\frac{x_i - b_{ij}}{a_{ij}} \right] \right] e^{-0.5 \left[\frac{x_i - b_{ij}}{a_{ij}} \right]^2}$$

$$a_{ij}(k+1) = a_{ij}(k) + \eta \nabla a_{ij}(k) + \alpha \nabla a_{ij}(k-1) \quad (4.16)$$

$$\nabla b_{ij} = \frac{\partial E}{\partial b_{ij}} = - \frac{\partial E}{\partial y} \frac{\partial y}{\partial z_j} \frac{\partial \psi_{ij}}{\partial \psi_{ij}} \frac{\partial z_j}{\partial b_{ij}} \quad (4.17)$$

$$= e w_j z_j \left[\frac{1}{a_{ij}} \right] \left[\frac{x_i - b_{ij}}{a_{ij}} \right] \left[3 - \left[\frac{x_i - b_{ij}}{a_{ij}} \right] \right] e^{-0.5 \left[\frac{x_i - b_{ij}}{a_{ij}} \right]^2} \quad (4.18)$$

$$b_{ij}(k+1) = b_{ij}(k) + \eta \nabla b_{ij}(k) + \alpha \nabla b_{ij}(k-1) \quad (4.19)$$

4.4.3 Algorithme d'entraînement

L'algorithme d'entraînement recueille les données de la même manière que dans la prédiction et c'est le même réseau d'ondelettes qui est utilisé pour faire l'entraînement. Sauf

que dans cette section on fait intervenir un algorithme de moindres carrés (LMS pour Least Mean Squares) pour faire l'ajustement des paramètres. Le processus se déroule comme suit: On compare la sortie du réseau d'ondelettes à une valeur désirée afin de déterminer l'erreur. Ensuite on procède à la minimisation de l'erreur par la méthode du gradient (erreur moyenne quadratique) par rapport aux différents paramètres à optimiser du réseau. Par la suite on ajuste les paramètres en utilisant l'équation 4.9. Cette opération est répétée plusieurs fois jusqu'à ce qu'on obtient la minimisation de l'erreur. Enfin, les paramètres ajustés seront récupérés et envoyés au réseau d'ondelettes pour la prédiction. La figure 4.5 permet de bien illustrer le fonctionnement de l'algorithme d'entraînement qui comporte trois étapes.

La première étape consiste à lire les données à prédire (les données $X_1 X_2 \dots X_n$ représentant les données du présent et quelques données du passé immédiat) et les paramètres du réseau ($w_1 w_2 \dots w_m, v_1 v_2 \dots v_n, g$ et les paramètres des ondelettes). Ces données sont par la suite présentées au réseau d'ondelettes.

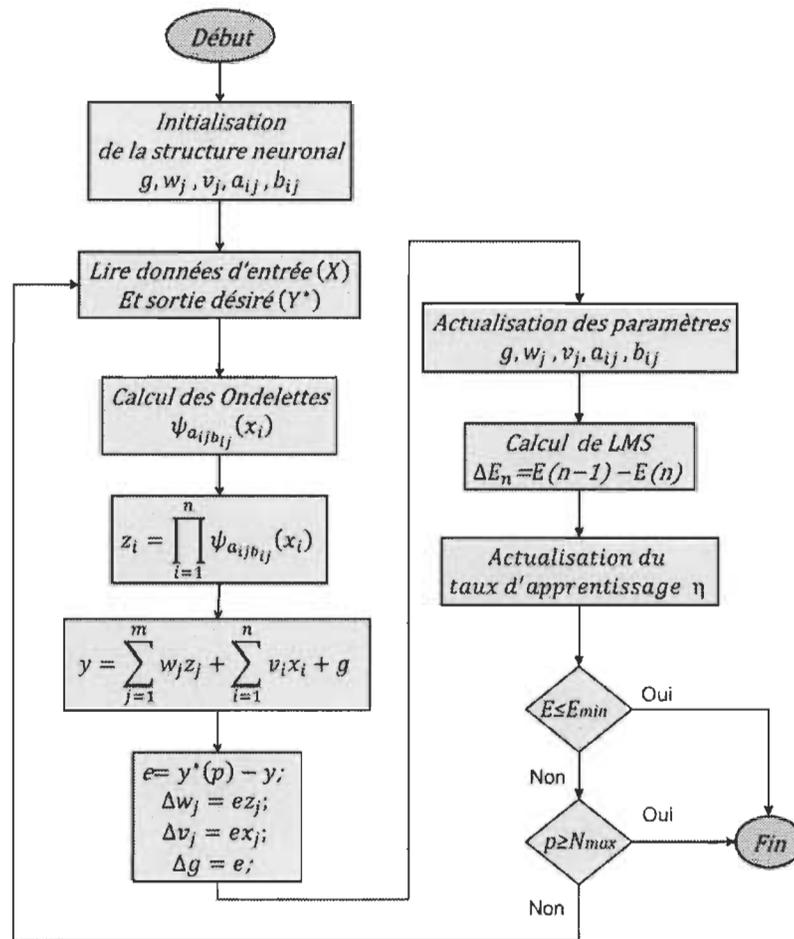


Figure 4-4 Algorithme d'entraînement

La deuxième étape consiste à démarrer le processus de minimisation de l'erreur qui est basé sur la méthode du gradient. Pour ce faire on procède au calcul de l'erreur de prédiction et par la suite au calcul du gradient de la fonction de coût (E) par rapport à chacun des paramètres du réseau d'ondelettes (w_1, w_2, \dots, w_m), (v_1, v_2, \dots, v_n), g , (a_{11}, \dots, a_{nm}), (b_{11}, \dots, b_{nm}), où n et m sont respectivement la dimension des données d'entrée de l'algorithme de prédiction et de la couche cachée. L'ajustement de ces paramètres est équivalent à l'entraînement de l'algorithme de prédiction.

La troisième étape consiste à envoyer les paramètres ajustés à l'algorithme de prédiction dont le principe de fonctionnement est illustré à la figure 4.6 afin d'améliorer l'erreur de prédiction.

Le processus d'optimisation des poids (entraînement) est déclenché à chaque fois que l'erreur atteint un certain seuil, déterminé en fonction de la prédictibilité de la série temporelle. La figure 4.5 permet de voir les différentes parties du processus d'entraînement. La figure 4-6 permet d'illustrer le principe de fonctionnement de la prédiction.

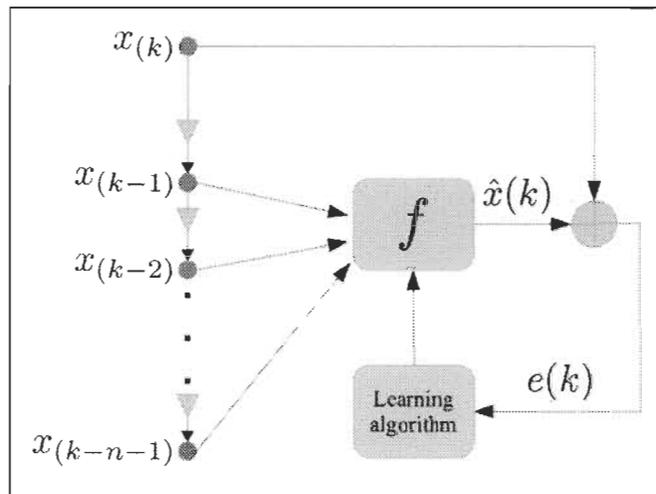


Figure 4-5 Structure de l'entraînement

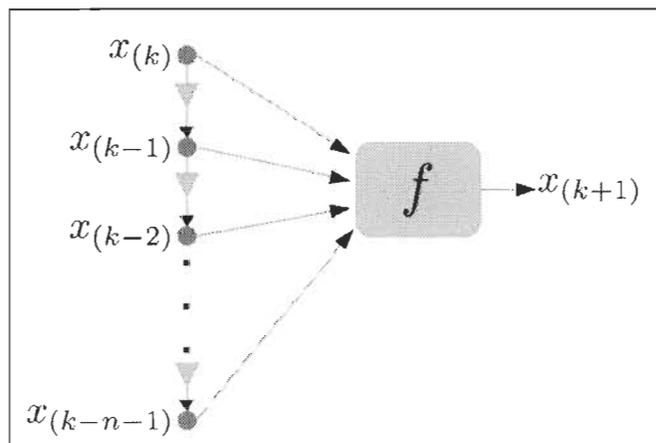


Figure 4-6 Principe de la prédiction

4.5 Reconstruction

Nous avons à la sortie de la décomposition cinq signaux dont quatre signaux de haute fréquence (d_1, d_2, d_3 et d_4) et un signal de basse fréquence A_4 . Les cinq signaux de sortie vont être les entrées de l'algorithme de reconstruction. Les signaux de haute fréquence seront passés par des filtres de reconstruction d'ondelettes passe haut et celui de basse fréquence sera passé par un filtre de reconstruction d'ondelettes passe bas. Par la suite on fait doubler l'échantillonnage de chacune de ces sorties en faisant une interpolation des données de sortie des filtres. Nous commençons par faire les sommes des signaux recueillis du d_4 et du A_4 qui ont la même fréquence d'échantillonnage. Le résultat obtenu est passé par un filtre de reconstruction passe bas, et ensuite interpolé. Le signal interpolé sera sommé au signal recueilli de d_3 . On continue la sommation de façon analogue que précédemment jusqu'à la sommation du signal recueilli de d_1 . Enfin on fait une interpolation du signal recueilli, ce qui constituera le signal reconstruit. La figure 4.7 donne une bonne lecture de la décomposition et de la reconstruction ainsi que l'emplacement du réseau d'ondelettes dans le processus de fonctionnement de la méthode de prédiction.

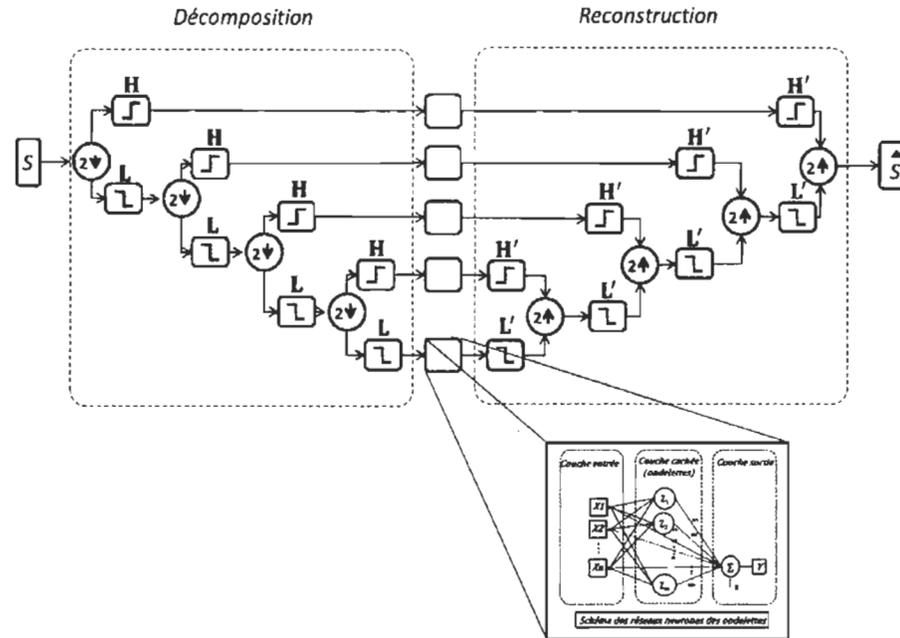


Figure 4-7 Décomposition prédiction et reconstruction

4.6 Méthode de décomposition reconstruction utilisant MODWT.

L'analyse multi-résolution basée sur les transformées discrètes d'ondelettes présente quelques insuffisances, comme le sous-échantillonnage des données ce qui entraîne des pertes d'information (implique un manque de précision), contrairement à la méthode AMR (Analyse Multi-Résolution) basée sur MODWT (pour Maximal Overlap Discrete Wavelet Transform), celle basée sur les DWT (Discrete Wavelet Transform) présente seulement deux filtres de décomposition et deux de reconstruction ce qui limite les tendances de basse fréquence dans la décomposition. Dans cette décomposition nous recueillons seulement un signal de basse fréquence et tous les autres signaux sont de haute fréquence et qui peut être considéré comme du bruit. Cette dernière caractéristique est un désavantage pour la prédictibilité des signaux. Puisque les signaux de tendance aléatoire (bruit) ont une prédictibilité très faible. La figure 4-8 permet d'illustrer la méthode de décomposition

MODWT. La reconstruction est faite par le même principe que dans la reconstruction basée sur les DWT.

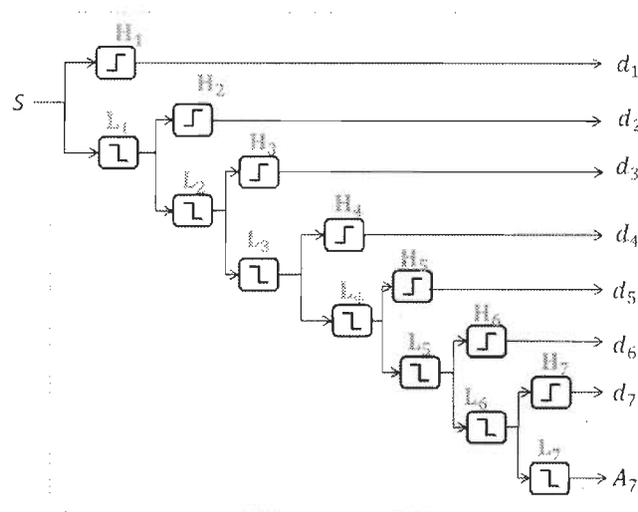


Figure 4-8 Structure de la décomposition MODWT

4.7 Conclusion

La prédiction par la méthode de réseau d'ondelettes a des points communs par rapport aux autres méthodes adaptatives. Cependant, il y a des spécificités qui la différencient des autres réseaux de neurones; à savoir : les paramètres internes des ondelettes de la couche cachée sont des éléments importants lorsqu'il s'agit de construire un signal à partir de l'information spécifique de celui-ci. Ce qui est d'avantage important pour les réseaux d'ondelettes, à cause que les paramètres des ondelettes de la couche cachée permettent un suivi fréquentiel et temporel du signal. Cette propriété des ondelettes est importante d'autant plus que les données de la vitesse du vent ont une fréquence variable dans le temps.

L'analyse multi-résolution est aussi un maillon important dans cette méthode. Puis, il permet de réaliser la prédiction sur chacun des éléments de la décomposition. Ce qui permet au réseau d'ondelettes de prédire des informations qui ont des caractéristiques semblables.

Chapitre 5 - Analyses des résultats

Dans ce chapitre, nous présentons les travaux réalisés pour la prédiction des sources d'énergie renouvelables. Les travaux vont être présentés en deux étapes :

La première étape est consacrée à la méthode AWNN réalisée en faisant une décomposition en base des transformées d'ondelettes discrète (DWT), qui présente quelques insuffisances. La deuxième étape est dédiée à la méthode AWNN, qui utilise le « Maximum Over-lap Discrete wavelet Transform » (MODWT) dans la décomposition et reconstruction qui corrige les insuffisances présentées dans la première partie. Une attention particulière a été mise sur la prédictibilité des séries temporelles, à savoir faire une analyse de la prise en compte des données non-prédictibles ou qui ont une prédictibilité très faible. C'est-à-dire qu'en fonction de la prédictibilité des séries temporelles, on procédera à une optimisation des ressources de calculs de l'algorithme en gardant une bonne précision de la prédiction.

Il sera également présenté le banc d'essai (micro réseau) pour lequel la prédiction est destinée. Ensuite on présente les résultats de simulation. Une comparaison des résultats obtenus dans ce projet avec ceux des méthodes classiques est aussi présentée.

Nous ferons également une discussion sur les résultats obtenus, sur les points forts et les faiblesses de la méthode adoptée dans ce projet ainsi que sur les difficultés rencontrées au cours de ce travail de recherche.

5.1 Banc d'essais des énergies renouvelables - Institut de Recherche sur l'Hydrogène

L'Institut de Recherche sur l'Hydrogène est doté, entre autres, d'une éolienne, des panneaux photovoltaïques, de plusieurs systèmes de pile à combustible, et d'un électrolyseur alcalin qui peut être utilisé pour le stockage d'énergie sous forme d'hydrogène. Les sources primaires (éolienne, solaire et pile à combustible) sont munies de chaînes de conversions d'énergie et des algorithmes de contrôle qui permettent leur synchronisation (fréquence et tension) afin de les opérer en mode de micro-réseau [42], [43]. Puisque l'objectif de ce travail est de réaliser la prédiction des sources d'énergies renouvelables du micro-réseau, nous nous concentrons sur l'éolienne et les panneaux photovoltaïques. Une collecte des données de test au niveau de la sortie du redresseur (dans la chaîne de conversion de l'éolienne) a été réalisée. La figure 5.1 représente une image du banc d'essai.

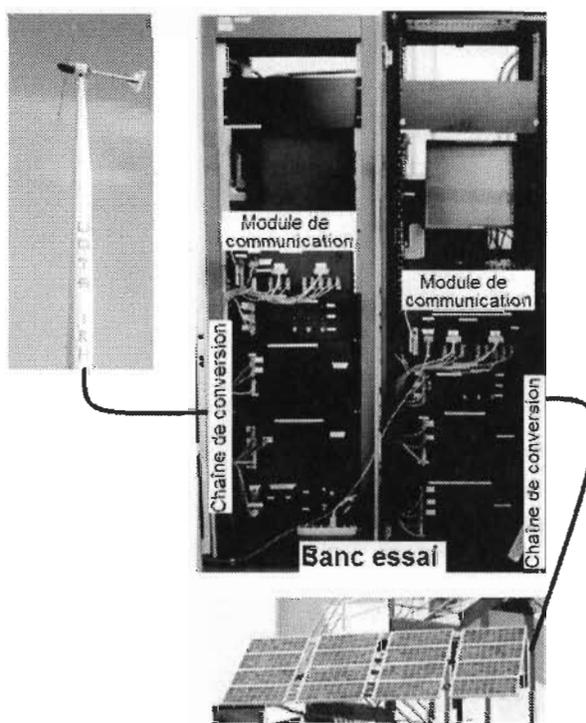


Figure 5-1 Banc d'essai.

La figure 5-2 est un schéma du redresseur, des hacheurs et des onduleurs utilisés dans le banc d'essai. Nous remarquons qu'à l'entrée et à la sortie de chacun des convertisseurs est placé un capteur de courant et de tension. Ce qui nous permet de recueillir des données à temps-réel pour la prédiction ainsi que pour la gestion et contrôle du micro-réseau.

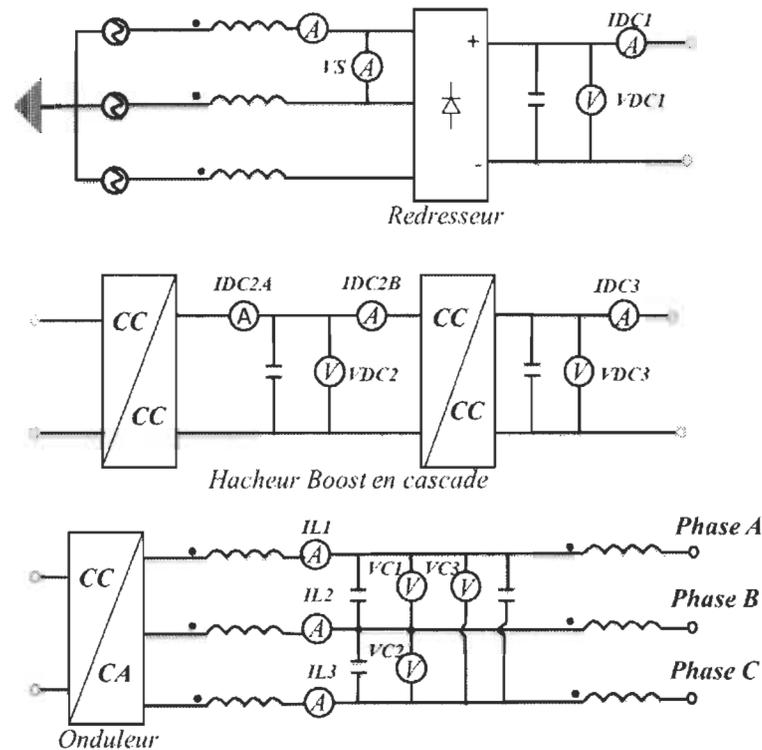


Figure 5-2 Chaîne de conversion de l'éolienne [44].

5.2 Acquisition et stockage des données

Le schéma de la figure 5.3 nous donne une visualisation du chemin suivi pour collecter des données de la puissance électrique du vent à la sortie du redresseur.

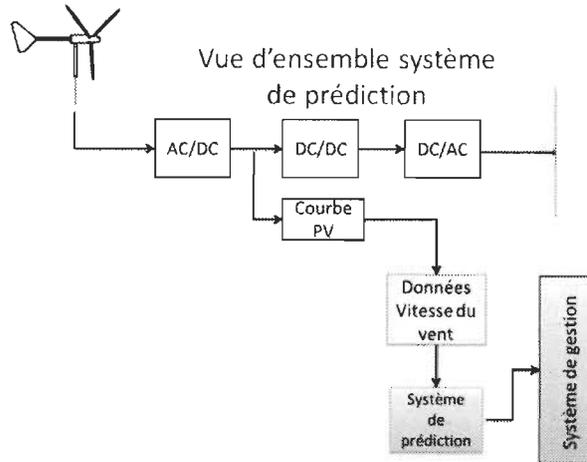


Figure 5-3 Vue d'ensemble du système acquisition, prédiction, et gestion.

Les données sont recueillies par le billet du banc d'essais. Le système de mesure comprend des capteurs, des filtres, des suiveurs pour stabiliser le signal et un convertisseur analogique -numérique, comme son nom l'indique permet de convertir le signal analogique en signal numérique. Ce signal est utilisé pour la prédiction, affichage et aussi le contrôle du système de gestion du micro-réseau.

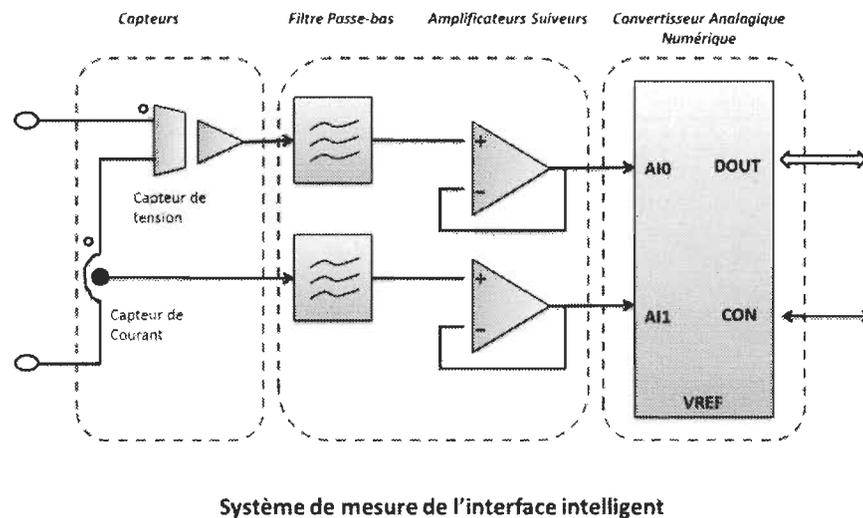


Figure 5-3 Système de mesure de l'interface intelligent [44].

Les capteurs utilisés sont des capteurs à effet Hall avec une isolation galvanique. Les types de capteurs utilisés sont les suivants : Capteur de tension LAH50-P et HAS 100-S, Capteur de courant LV25-P. Les capteurs de courant et tension sont des traits d'union entre le circuit de puissance et le circuit de contrôle, l'isolation galvanique permet d'isoler les deux circuits. Ce qui constitue un élément de sécurité essentiel.

Les données utilisées pour la simulation ont été recueillies à la sortie du redresseur en suite passent par le convertisseur analogique-numérique et envoyées par une connexion USB à l'ordinateur. Elles sont enregistrées sur l'ordinateur dans un fichier Excel. On appelle le fichier dans Workspace de MATLAB. Par la suite ces données sont utilisées par l'algorithme de décomposition. Nous avons également pris des données de vent dans une base de données d'Hydro-Québec (<https://www.simeb.ca/>), dont la période d'échantillonnage est une heure, qui a été également importé sur MATLAB.

L'éolienne à l'IRH présentée à la figure 5-4, a une puissance d'environ 7.5 KW. Elle est munie d'une machine synchrone à aimants permanents. Sa vitesse varie entre 3.6 m/s et 14 m/s. En effet lors que la vitesse du vent est inférieure 3.6m/s l'inertie de l'éolienne est plus importante que la force produite par cette vitesse, ce qui produit l'arrêt l'éolienne. Pour des raisons de sécurité par rapport à la structure et le support de l'éolienne, lorsque la vitesse dépasse 14 m/s, un mécanisme se met en marche et dévie l'axe de l'éolienne, ce qui a pour effet de réduire la puissance recueillie par l'éolienne. Cette chute de puissance se continue et devient quasiment nulle lors que la vitesse du vent atteint 16.7 m/s. Il est connecté à l'entrée du redresseur du banc d'essai [45].

La puissance de l'éolienne est décrite par l'équation 5.1. Elle relie la vitesse du vent à la puissance fournie par l'éolienne [46], [45].

$$P_{vent} = \rho \frac{\pi}{8} v^3 D^2 \quad (5.1)$$

ρ est la densité de l'air;

D est la longueur des pales;

v est la vitesse du vent.

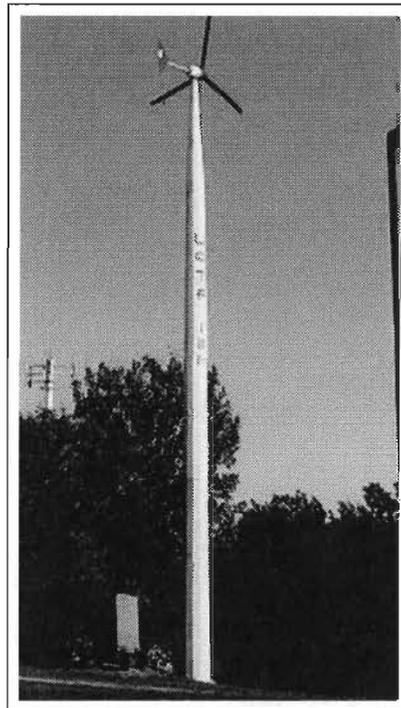


Figure 5-4 Image de l'éolienne de l'IRH

Les panneaux solaires de l'IRH ont une puissance de 1kW et sont de modèle GP-64, de la compagnie Golden Genesis [45]. Ils sont connectés au banc d'essais par un hacheur. Comme l'éolienne, la puissance fournie par les panneaux transite par une chaîne de conversion composée de hacheur et d'onduleur permettant de se synchroniser au micro-réseau. La figure 5-5 représente l'image des panneaux solaire de l'IRH.

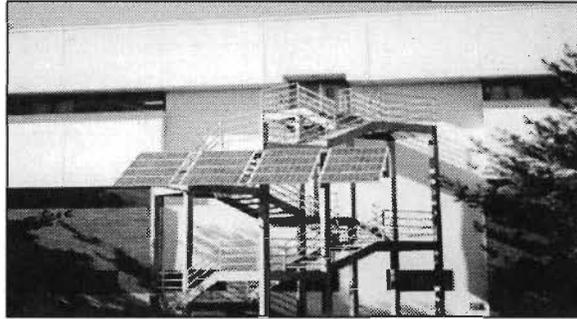


Figure 5-5 Image des panneaux solaires de l'IRH

5.3 Objectifs de simulation

Le but de la simulation est de développer et de tester l'algorithme de prédiction à court terme. Afin d'atteindre les résultats espérés. Nous allons :

- Évaluer nos données afin de déterminer leurs prédictibilité, cet exercice nous permet de quantifier les résultats que nous pouvons attendre des données. Elle a également pour but de mieux de cerner les composantes de la décomposition qui ont un faible taux de prédictibilité, afin de les supprimer éventuellement si elles n'ont pas un apport à la précision de la prédiction, pour optimiser les ressources de calcul du système de prédiction.
- Réaliser une méthode de prédiction permettant de répondre aux besoins de gestion d'un micro-réseau intelligent.
- Valider la méthode de prédiction et la comparer aux méthodes classiques.
- Évaluer la performance du système de prédiction en fonction des besoins du système de gestion.

5.4 *Scenario de test*

Le scénario élaboré pour le test de la prédiction est structuré en trois parties. Dans un premier temps, nous étudions la prédictibilité des séries temporelles, qui se traduit par l'identification à titre d'exemple de quelques séries temporelles prédictibles, non-prédictibles ou moyennement prédictibles. Pour déterminer la prédictibilité des séries nous calculons L'exposant de Hurst (ou coefficient de Hurst) de ces séries qui permet de classier la prédictibilité des séries [37], [47]. Cette classification est réalisée en assignant à chaque série une note entre 0 et 1. Plus cette note est proche de 0 plus la série est moins prédictible, plus elle tend vers 1 plus la série est prédictible. Par la suite nous déterminons la prédictibilité des données de test, ainsi que celle de tous les signaux de la décomposition. Cet exercice nous permet d'analyser la prédictibilité de nos données en détail. Dans un second temps nous déterminons la prédiction des données sur un horizon variant d'une heure à cinq heures. Enfin nous comparons les résultats de prédiction de notre méthode avec une méthode classique de prédiction AR (processus autorégressif).

5.4.1 *Évaluation de la prédictibilité des séries temporelles.*

La prédictibilité des séries temporelles dépend de la logique qui se cache dans la chronologie des données, à savoir si cette chronologie est liée de façon purement aléatoire ou s'il y a une logique sous-jacente permettant de déterminer un lien entre le passé, le présent et le futur. L'existence de ce lien définit le caractère déterministe d'une série temporelle. Les séries temporelles possèdent généralement les deux caractéristiques, une déterministe et l'autre aléatoire. Leurs prédictibilités dépendent de la tendance à être plus déterministe ou plus aléatoire [48].

Il existe plusieurs types de séries temporelles, nous pouvons citer les séries déterministes, aléatoires, à marche aléatoire etc. Nous allons évaluer notre algorithme de prédiction et aussi faire le calcul du coefficient de Hurst sur une série déterministe (ayant un fort potentiel déterministe), une série moyennement déterministe et une série aléatoire. Cet exercice permet de vérifier la performance de l'algorithme de prédiction et aussi de déterminer l'influence de la nature des données sur les résultats de prédiction. La prédictibilité des différents types de séries temporelles citée ci-dessus sont défini ci-dessous [49], [50].

5.4.1.1 Les séries temporelles déterministes

Dans cette étude nous allons utiliser la série temporelle de Mackey-Glass pour représenter la série déterministe [51]. Elle peut être utilisée comme référence pour évaluer la capacité d'un algorithme à prédire une série temporelle déterministe.

$$x(t + 1) = x(t) + \frac{bx(t - \tau)}{1 + x^c(t - \tau)} - ax(t) \quad (5.2)$$

Ou $a = 0.1$, $b = 0.2$, et $\tau = 16$

Nous avons testé la série Mackey-Glass sur l'algorithme de prédiction illustré à la Figure 5-6 afin d'évaluer la prédictibilité de cette série [49].

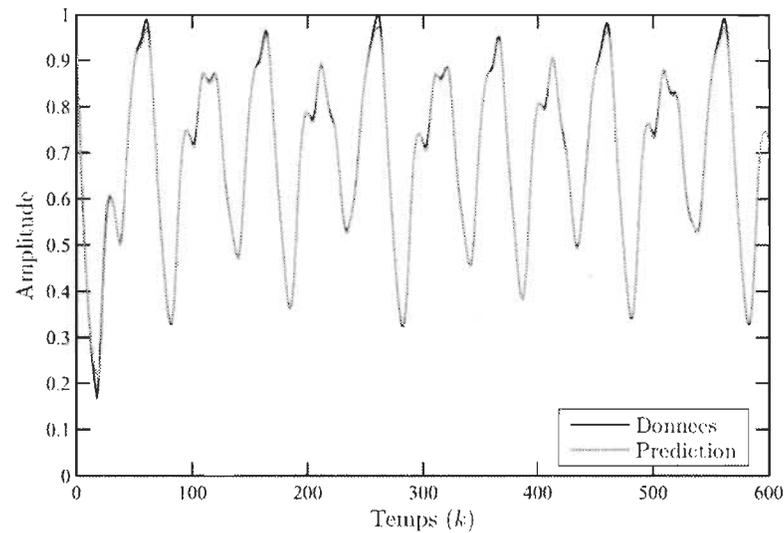


Figure 5-6 Test de prédiction avec Série de Mackey-Glass

Nous constatons une bonne précision de la prédiction. Nous avons calculé les coefficients de Hurst de la série de Mackey-Glass et il est égal à 0.9702, ce qui montre qu'elle est fortement prédictible [49].

5.4.1.2 Les séries temporelles marche aléatoire

Dans cette partie, le test de la prédiction d'une série à marche aléatoire est réalisé. Cette série a comme caractéristique, qu'elle est moyennement déterministe.

Soit $\{R_t\}$ la série de la marche aléatoire tel que :

$$R_t = R_{t-1} + a_t \quad (5.3)$$

Où a_t est une variable aléatoire et $t = 1, 2, \dots, N$.

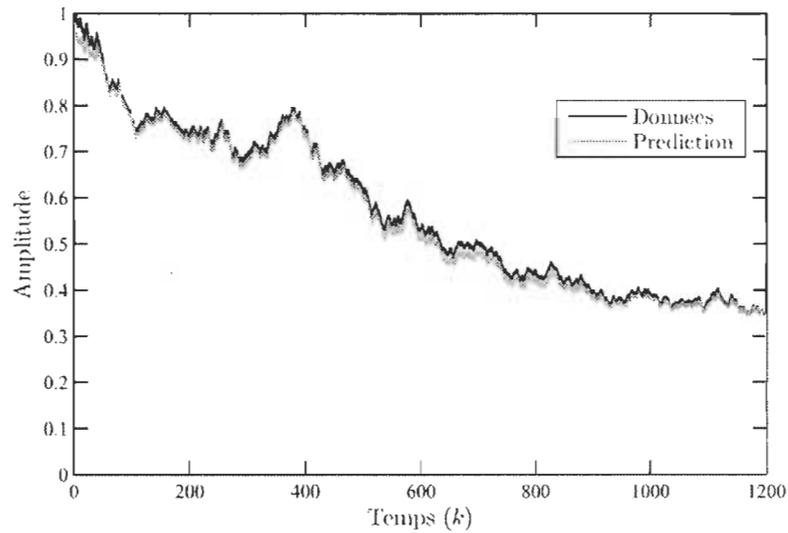


Figure 5-7 Série à marche aléatoire test de prédiction

Selon les résultats de test (voir figure 5-7) effectué sur l'algorithme de prédiction en lui présentant les données de la série à marche aléatoire, nous avons des résultats moyennement précis et le coefficient de Hurst de cette la série est de 0.5173. Ce qui confirme que la série est moyennement prédictible [49].

5.4.1.3 Le bruit blanc des séries chronologiques

Une série chronologique de bruit blanc a été générée en utilisant un générateur de nombre aléatoire gaussien de moyenne nulle et de variance 1.

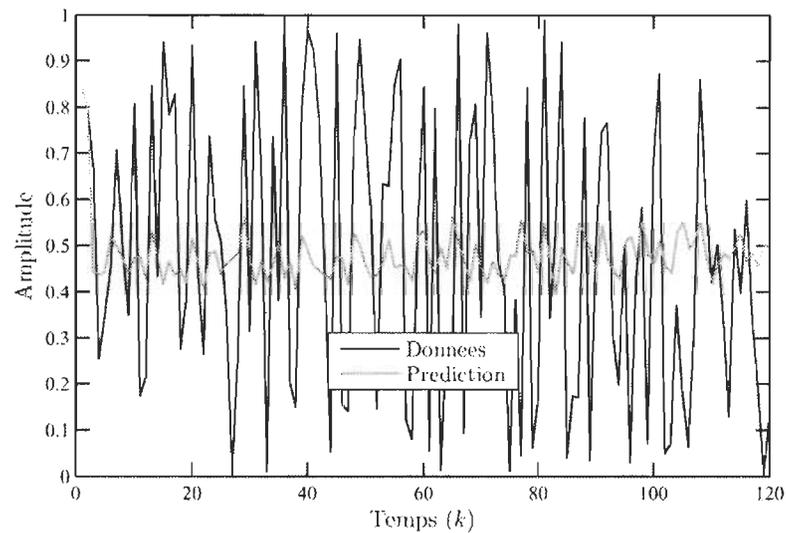


Figure 5-8 Série aléatoire test de prédiction

Nous constatons que la série aléatoire est très peu prédictible par notre algorithme (voir figure 5-8) et le calcul du coefficient de Hurst donne 0.0305. Ce qui implique un très faible potentiel de prédictibilité. Ce résultat confirme le caractère aléatoire de la série.

Tableau 5-1 Erreur de prédiction des séries par l'algorithme proposé.

Erreur_p Série	SMAPE	MAE	MSE	RMSE	Horizon (h)
déterministe	0.5562	0.6641	2.1e-004	1.4501	1
Marche aléatoire	2.0227	3.0173	0.0016	3.9760	1
Aléatoire	8.7538	7.9146	0.0266	16.3027	1

5.5 Données de test

Dans la figure 5.9 nous avons des données de vitesse de vent utilisées pour le test de l'algorithme de prédiction. Elles sont recueillies avec une période échantillonnage d'une heure. Sur le site web (https://www.simeb.ca:8443/index_fr.jsp) de SIMEB (Simulation

énergétique des bâtiments). Qui est un outil qui simule le comportement énergétique de bâtiments commerciaux et institutionnels. Les données de vitesse de vent utilisées ont été recueillies sur la période du 01 jan 2013 au 01 jan 2014 pour la ville de Trois-Rivières. La base de données contient aussi de l'information sur le rayonnement solaire, la température, et l'humidité.

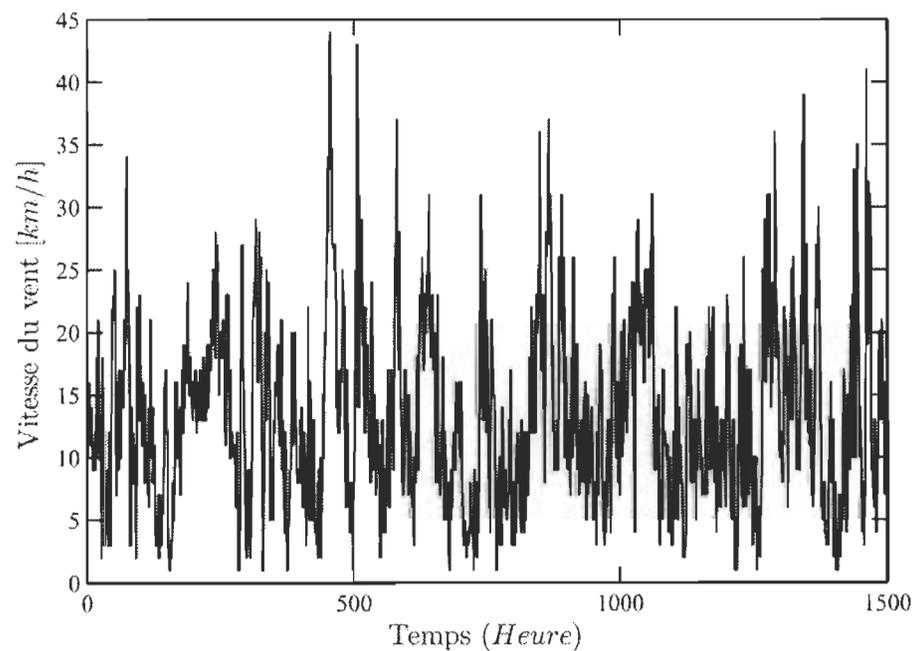


Figure 5-9 Données de vitesse du vent prises de site web : <https://www.simeb.ca>

5.6 Résultats prédiction AWNN (DWT)

Il sera présenté dans un premier temps les résultats de la décomposition et dans second temps les résultats de la prédiction après la reconstruction des données de décomposition prédites.

5.6.1 Résultats Décomposition

Cette décomposition a été réalisée en utilisant la plateforme Simulink. Nous utilisons trois blocs Simulink dont les fonctionnalités sont respectivement, la réception des données par paquet correspondantes à la dimension de chaque entrée des réseaux d'ondelettes réceptionnant les sorties des signaux décomposés, les deux blocs servent à la convolution des données d'entrée avec les filtres d'ondelettes, le troisième bloc permet de baisser l'échantillonnage des signaux de sortie de la convolution de moitié. La figure 5-10 montre un schéma Simulink de la décomposition. Et les résultats de la décomposition sont présentés à la figure 5-11.

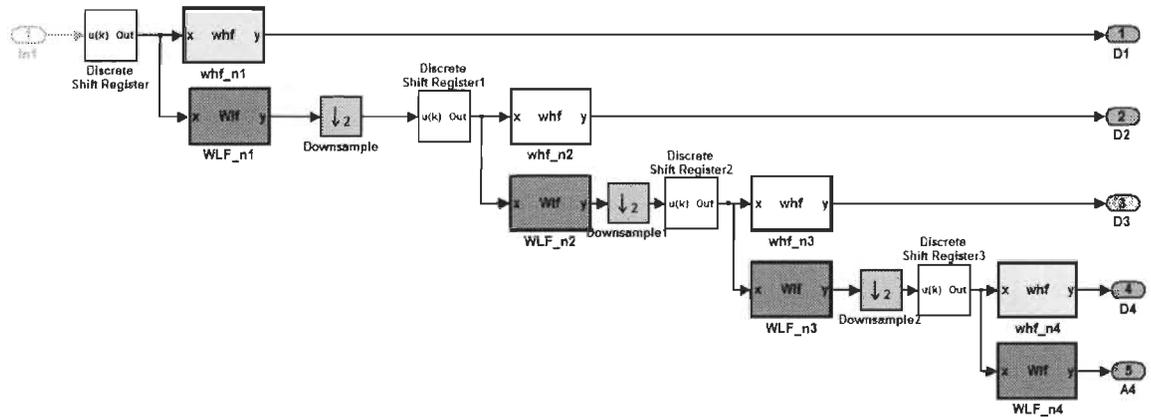


Figure 5-10 Schéma Simulink de la décomposition.

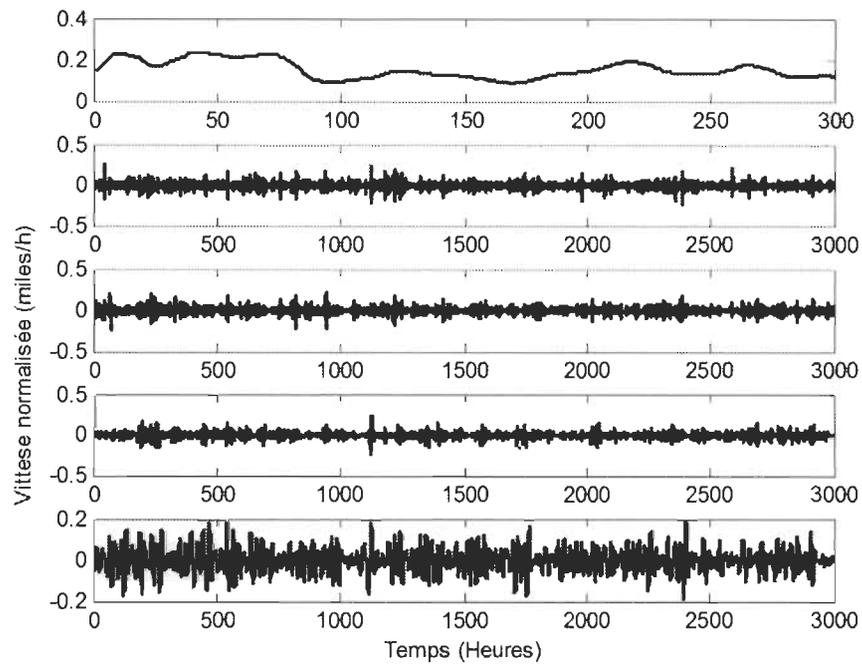


Figure 5-11 Résultats de la décomposition AWNN(DWT).

5.6.2 *Entraînement*

L'ajustement des paramètres du réseau d'ondelettes se fait, pendant que la prédiction de tous les réseaux d'ondelettes des différents signaux décomposés est en cours. Le principe de fonctionnement est que le mécanisme d'entraînement se met en marche à chaque fois que l'erreur de prédiction atteint un certain seuil que nous fixerons. Cette façon d'ajuster les paramètres a l'avantage d'avoir des paramètres optimaux à temps-réel selon l'erreur minimum que nous fixerons et aussi d'économiser des ressources de calcul en évitant de rouler l'algorithme d'entraînement pendant que l'erreur est acceptable. Le schéma Simulink du processus d'entraînement est présenté à la figure 5-12.

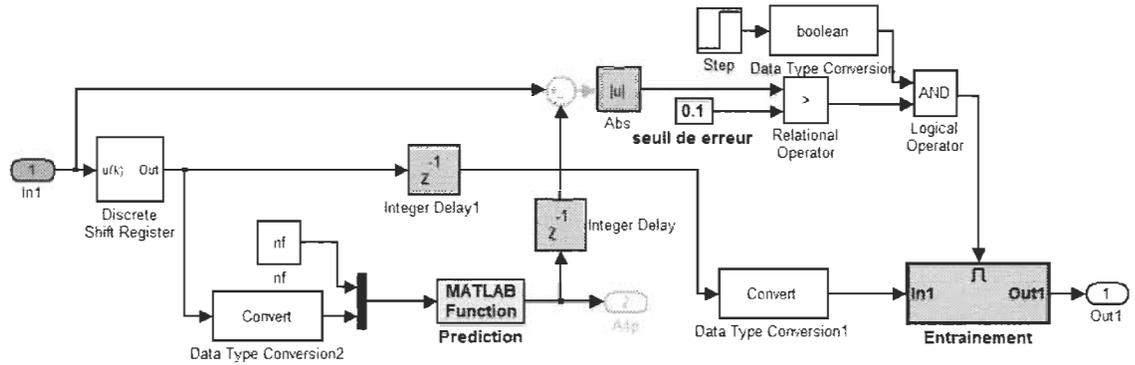


Figure 5-12 Schéma Simulink de l'entraînement.

5.6.3 Reconstruction

La reconstruction du signal d'entrée est réalisée en faisant l'opération inverse de la décomposition. De manière spécifique, elle est réalisée, en calculant la convolution des signaux avec des filtres d'ondelettes de reconstruction et par la suite on fait une interpolation des signaux de sorties qui seront additionnés en fonction de leurs séquences de réception. La figure 5-13 représente le schéma Simulink de la reconstruction.

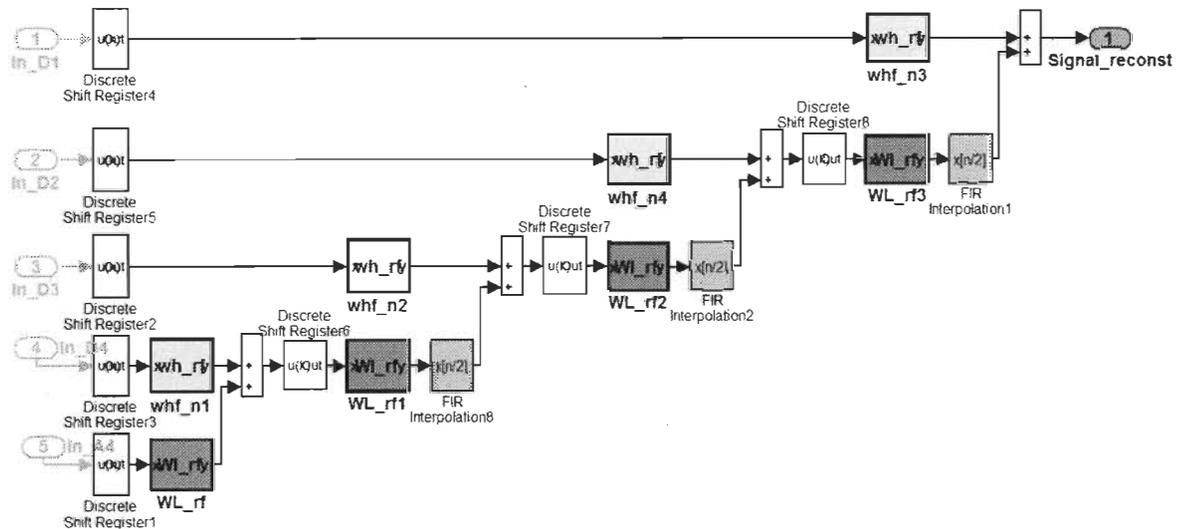


Figure 5-13 Schéma Simulink de la reconstruction.

La figure 5-14 représente toute la structure de la prédiction. Cette structure est composée des données à prédire, d'un bloc pour la décomposition, d'un bloc pour l'entraînement et la prédiction, et d'un bloc pour la reconstruction des données et l'affichage. La figure 5-15 représente les résultats de simulation de la prédiction de la méthode AWNN(DWT).

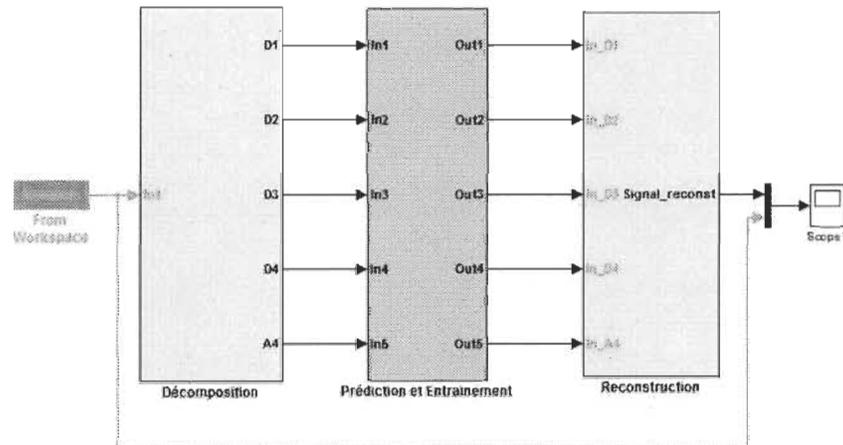


Figure 5-14 Schéma Simulink prédiction.

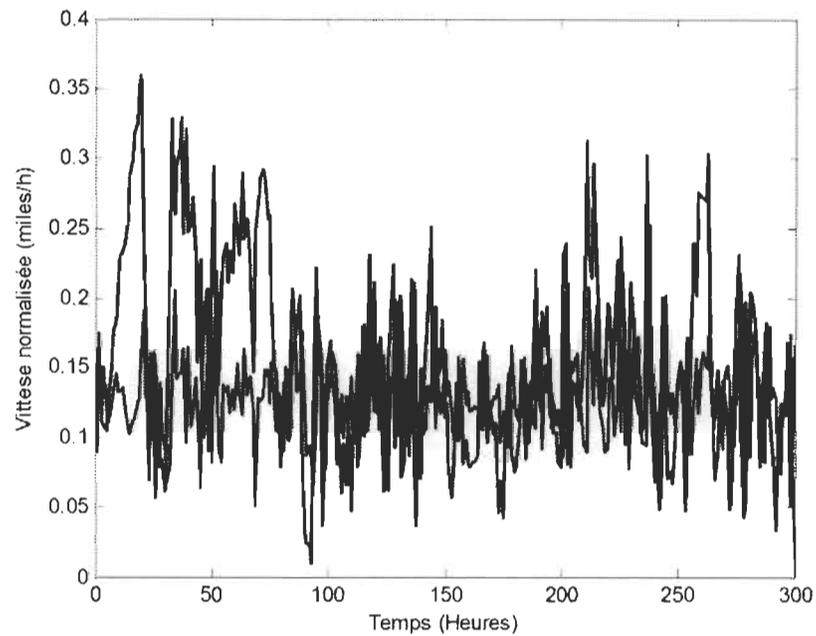


Figure 5-15 Résultat de la prédiction du vent (Horizon 1 heure) avec DWT.

5.6.4 Erreur de prédiction de la méthode AWNN (DWT).

Nous remarquons que l'erreur de prédiction par la méthode AWNN (DWT) est beaucoup plus grande que la méthode AWNN (MODWT). La faiblesse de la méthode utilisant la DWT réside dans la décomposition, comme il a été expliqué au chapitre 4. Les résultats présentés au tableau 5-2 sont les erreurs de prédiction de la méthode AWNN(DWT). Cette méthode a été abandonnée au profit de l'AWNN (MODWT).

Tableau 5-2 Erreur de prédiction de la méthode AWNN (DWT)

Horizon (h)	AWNN (DWT)			
	SMAPE	MAE	MSE	RMSE
1	23.1163	6.6032	0.0069	8.3112
2	22.9415	6.6448	0.0072	8.4642
3	21.7773	6.3198	0.0066	8.1120
4	22.5918	6.5822	0.0144	8.3200
5	21.5631	6.3086	0.0066	8.1447

5.7 Résultats prédiction AWNN(MODWT)

5.7.1 Décomposition

Les résultats de la figure 5-16 correspondent à la décomposition des données de vitesse de vent par la méthode MODWT. Comme on peut le remarquer, les résultats de décomposition ne présentent pas de perte d'information. Toutes les données décomposées ont le même nombre d'échantillons. On remarque également que les signaux décomposés présentent des tendances de basse fréquence. La méthode MODWT présente la même structure que la DWT, la différence entre les deux méthodes se situe au niveau des filtres de décomposition de reconstruction, du sous-échantillonnage et de l'interpolation des données. La méthode MODWT présente un filtre différent à tous les niveaux de la décomposition et le signal ne subit pas de sous-échantillonnage ni interpolation.

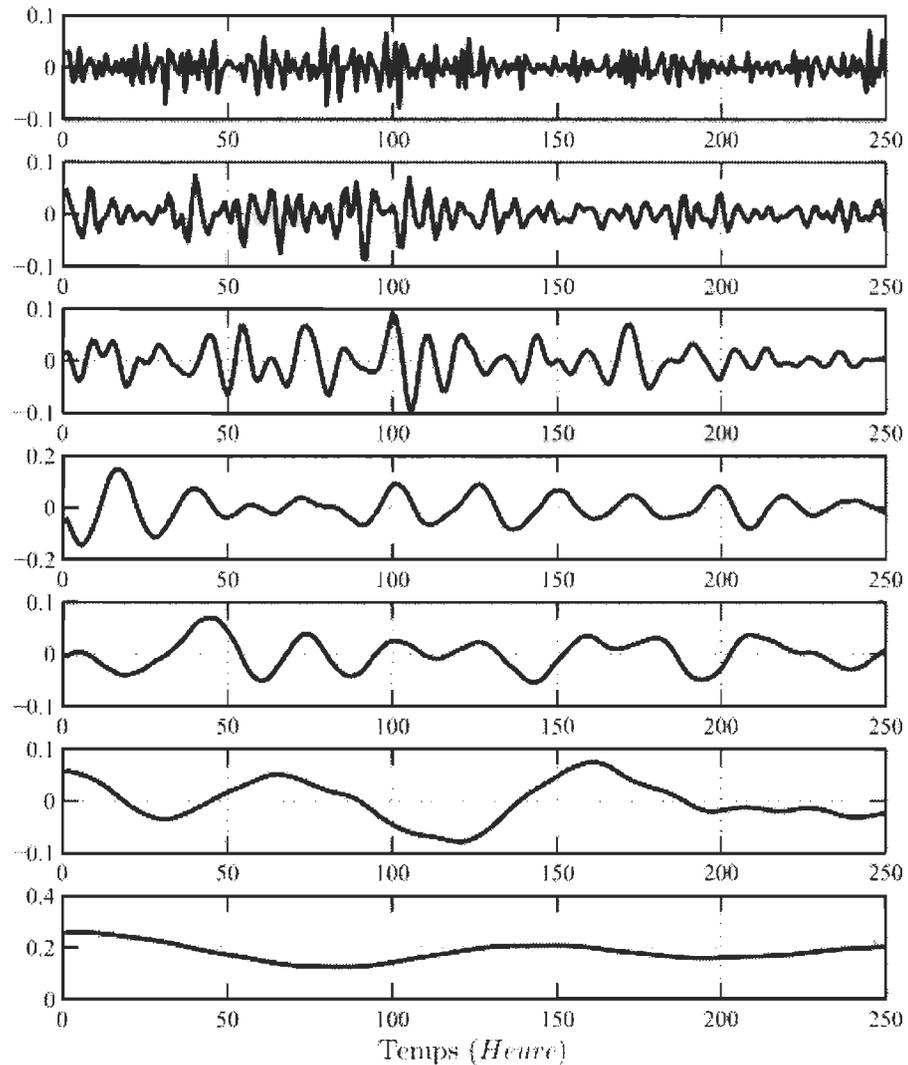


Figure 5-16 Décomposition de données du vent (300 échantillons).

Nous constatons que les tendances de plus basse fréquences des signaux de décomposition ont un coefficient de Hurst proche de un, ce qui implique une prédictibilité plus élevée et celles de haute fréquence ont un coefficient proche de zéro, donc une prédictibilité faible. La figure 5-17 présente la prédictibilité des composantes de la décomposition par le calcul des coefficients de Hurst.

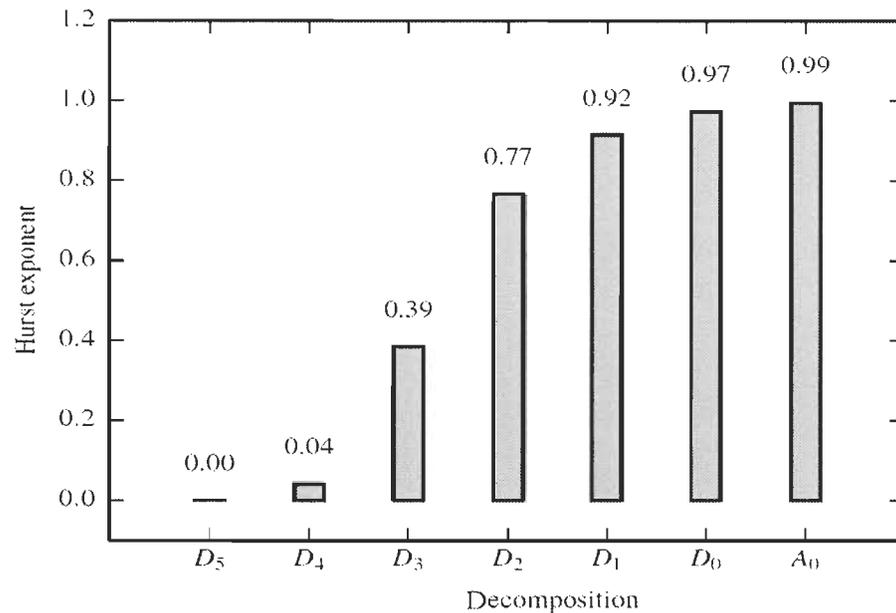


Figure 5-17 Exposant de Hurst de la décomposition.

5.7.2 Prédiction.

Les résultats de la figure 5-18 représentent les données de la prédiction par rapport aux données réelles, pour un horizon de prédiction d'une heure. Et celles de la figure 5-19 représentent la prédiction de vitesse du vent pour un horizon de prédiction de 5 heures. Nous constatons que plus l'horizon de prédiction est court plus la prédiction est précise. Nous avons fait le test de prédiction avec les mêmes données à un horizon de prédiction allant de une heure à cinq heures, nous constatons que l'algorithme est de moins en moins précis, plus l'horizon est éloigné. Cette remarque est confirmée dans le tableau 5-3.

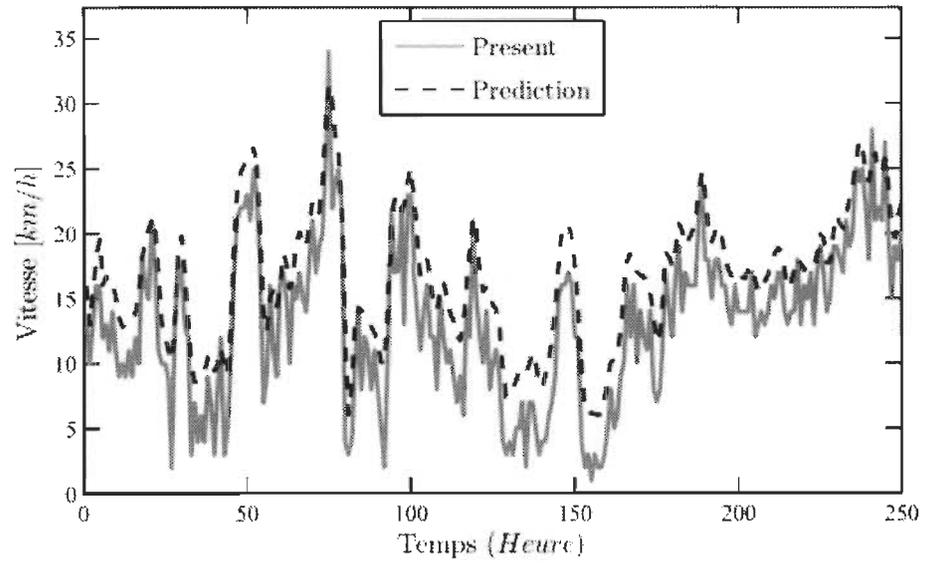


Figure 5-18 Résultat de la prédiction du vent (Horizon 1 heure) avec MODWT.

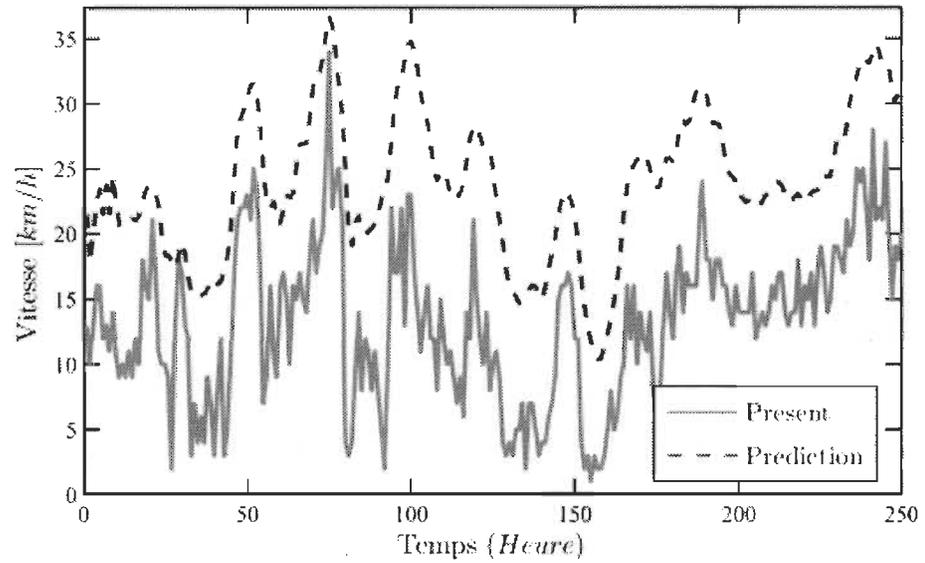


Figure 5-19 Résultat de la prédiction du vent (Horizon 5 heure) avec MODWT.

5.7.3 Calcul d'erreurs

Nous avons plusieurs méthodes de calcul de l'erreur de prédiction, les plus utilisés sont les suivants : Symmetric Mean Absolute Percent Error (SMAPE), Mean Absolute Percent Error (MAPE), Mean Absolute Error (MAE), Root Mean Square Error (RMSE) [52].

$$\text{SMAPE} = \frac{2}{N} \sum_{k=1}^N \frac{|F_k - A_k|}{F_k + A_k} \quad (5.1)$$

$$\text{MAE} = \frac{1}{N} \sum_{k=1}^N |F_k - A_k| \quad (5.2)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{k=1}^N (F_k - A_k)^2}{N}} \times 100 \quad (5.3)$$

$$\text{MSE} = \frac{\sum_{k=1}^N (F_k - A_k)^2}{N} \quad (5.3)$$

$$\text{MAPE} = \frac{1}{N} \sum_{k=1}^N \frac{|F_k - A_k|}{A_k} \quad (5.4)$$

Erreur de prédiction de la méthode proposée dans ce travail.

L'erreur de prédiction sur la vitesse du vent des données complètes et sans D_4 , D_5 sont présentées respectivement dans les tableaux 5-3 et 5-4. Le tableau 5-5 présente les résultats de prédiction de la méthode autorégressive (AR) pour des fins de comparaisons avec la méthode choisi avec l'AWNN (MODWT).

Au niveau de la décomposition et de la reconstruction des données, deux différents transformées d'ondelette ont été testées à savoir le DWT et le MODWT.

Les erreurs de prédiction de la méthode proposée dans ce projet.

Tableau 5-3 Erreur de prédiction données complètes AWNN(MODWT)

Horizon (h)	AWNN (MODWT)			
	SMAPE	MAE	MSE	RMSE
1	12.8975	3.8798	0.0021	4.5777
2	19.5902	6.9163	0.0067	8.1595
3	23.1983	8.8310	0.0108	10.3794
4	25.4641	10.1648	0.0144	11.9943
5	26.2069	10.6160	0.0156	12.5048

Tableau 5-4 Erreur de prédiction sans D_5 et D_4 AWNN(MODWT)

Horizon (h)	AWNN (MODWT) sans D_4 et D_5			
	SMAPE	MAE	MSE	RMSE
1	12.8906	3.8788	0.0021	4.5778
2	19.5915	6.9165	0.0067	8.1599
3	23.1975	8.8311	0.0107	10.3791
4	25.4655	10.1652	0.0145	11.9945
5	26.2072	10.6165	0.0156	12.5050

Erreur de prédiction de la méthode classique choisie (AR).

Nous présentons les résultats de l'erreur de prédiction en utilisant la méthode AR dans le tableau 5-4. Comme dans les cas précédents nous avons fait la prédiction pour un horizon de 1 à 5 heures.

Tableau 5-5 Erreur de prédiction de la méthode (AR).

Horizon (h)	AR (autorégressive)			
	SMAPE	MAE	MSE	RMSE
1	15.2063	4.6390	0.0038	6.1965
2	18.3393	5.7388	0.0058	7.5945
3	20.1295	6.4068	0.0071	8.4166
4	21.7576	6.9679	0.0083	9.301
5	23.4815	7.5441	0.0096	9.8092

5.7.4 *Analyse des résultats :*

L'analyse faite par rapport à l'AMR au chapitre 4 est clairement confortée par les résultats des deux méthodes. Nous constatons qu'AWNN (MODWT) est nettement meilleur à celui de la méthode AWNN (DWT). L'erreur quadratique moyenne (RMSE) de la méthode proposée est égale à 4.5777 et est nettement meilleur à l'AWNN (DWT) dont le RMSE est égale à 8.3112 pour un horizon de prédiction d'une heure dans les deux cas.

L'analyse de la figure 5-17 nous montre que la prédictibilité de la composante D_5 et D_4 sont quasiment nuls. Ce qui implique que leurs apports dans la précision de la prédiction sont négligeables. Nous avons testé l'algorithme de prédiction avec les données complètes et sans

D_5, D_4 ; nous constatons que la précision de la prédiction dans les deux cas sont sensiblement égales. Les tableaux 5-3 et 5-4 représentent l'erreur de prédiction des deux cas. Pour un horizon de prédiction de 1 heure, nous constatons qu'avec les données complètes le RSME est de 4.5777 et sans D_5 et D_4 le RSME est de 4.5778. La réduction des composantes de la prédiction des deux composantes est une réelle économie des ressources de calculs de la méthode de prédiction. Cette économie est estimée à 28,57 % de la capacité totale de calcul de la méthode de prédiction. En effet, dans le processus de calcul de l'algorithme de prédiction, les données de la décomposition sont individuellement passées dans l'algorithme de prédiction. En éliminant deux composantes sur sept et en faisant une règle, on détermine le pourcentage d'économie des ressources de calcul.

Nous constatons que la prédiction à court terme de la méthode proposée (AWNN-MODWT) est plus précise que la méthode AR. Pour un horizon de prédiction de 1 heure, nous constatons que l'erreur quadratique moyenne (RMSE) est égale à 4.5777 et le pourcentage d'erreur absolue moyen symétrique (SMAPE) est égal à 12.8975; les erreurs avec la méthode proposée sont plus petites que celles d'AR qui sont respectivement RMSE égale à 6.1965 et SMAPE égale à 15.2063.

Rappelons que la méthode AWNN(MODWT) a été proposée pour la prédiction de la vitesse du vent du banc d'essai (micro-réseau) présenté au paragraphe 5.1, qui nécessite une prédiction à court terme pour la gestion du micro-réseau.

5.8 Conclusions

Dans ce projet, nous avons réalisé une méthode de prédiction à base de réseaux d'ondelettes. Nous avons évalué deux méthodes de décomposition et reconstruction

d'ondelette pour la prédiction de la vitesse du vent. Il s'agit de celle des transformées discrète d'ondelettes (DWT) et le Maximal Overlap Discrete Wavelet Transform (MODWT). Dans un premier temps nous avons utilisé la méthode DWT, qui présentait quelques insuffisances à savoir une perte de données des signaux décomposés dû au sous-échantillonnage, et qu'on rattrapait par une interpolation dans la reconstruction. Aussi le fait qu'on utilisait le même filtre à tous les niveaux de la décomposition, donnait des résultats de décompositions avec quatre signaux de hautes fréquences et un signal de basse fréquence. Ces situations avaient une influence négative sur la précision de la prédiction. Pour corriger cette insuffisance nous avons adopté la méthode MODWT qui permet de corriger non seulement les pertes d'information mais donne aussi des signaux décomposés avec des tendances de plus basse fréquence à cause de l'utilisation de différents types de filtres à tous les niveaux de la décomposition, ce qui est un atout dans la précision de la prédiction.

Nous avons aussi fait une étude sur la prédictibilité des série temporelle afin de définir les attentes des résultats de la prédiction et aussi de juger de la nécessité de l'utilisation de certaines données de la décomposition dont la prédictibilité est faible, pour des raisons d'économie des ressources de calcul. Nous avons comparé les résultats de prédiction de notre méthode avec une méthode classique de prédiction AR (processus autorégressif).

Chapitre 6 - Conclusion

Dans ce travail, il a été développé une méthode de prédiction de la vitesse du vent, dont l'algorithme de calcul est un réseau d'ondelette. La méthode utilise l'analyse multi-résolution des données. Elle consiste à faire la décomposition et la reconstruction des données utilisées pour la prédiction et l'entraînement de l'algorithme. La décomposition a pour avantage de séparer les informations contenues dans le signal d'entrée selon leurs spécificités. Il est important de savoir que toutes les informations ne sont pas prédictibles. C'est pourquoi nous avons trouvé important de faire une étude de la prédictibilité des données afin d'identifier en fonction des résultats de la décomposition les informations selon leur potentiel de prédictibilité. Cet exercice nous permet d'optimiser les ressources de calcul de l'algorithme de prédiction. Nous avons analysé la prédictibilité de chaque composante de la décomposition et avons éliminé les composantes dont les prédictibilités tendent vers zéro. Ce qui a pour but de réduire considérablement les ressources de calcul de l'algorithme tout en gardant le même niveau de précision des résultats de prédiction.

Les tests effectués ont été validés par simulation sur Matlab. Nous avons recueilli des données de la vitesse du vent de la région de Trois-Rivières sur le site web de SIMEB-Hydro-Québec (Simulation énergétique des bâtiments). Il a été réalisé la prédiction pour un horizon de prédiction allant de une à cinq heures. Pour le même algorithme de prédiction nous avons effectué le test sur deux méthodes de décomposition de l'analyse multi-résolution (avec DWT et MODWT). Les résultats obtenus en utilisant les deux méthodes se sont avérés très différents en termes de précision de la prédiction. La décomposition avec MODWT présente de bien meilleurs résultats qu'avec DWT, car la décomposition avec MODWT

donne des composantes de prédictibilité élevée, plus que celle avec DWT. La méthode de prédiction développée dans ce travail donnée une bonne précision si on la compare aux méthodes présentées dans la littérature. Elle répond également aux besoins de prédictions du banc d'essai du micro-réseau en développement dans l'équipe d'énergie renouvelable de l'IRH.

Les résultats de prédiction de la méthode proposée pour un horizon de prédiction d'une heure, donne une erreur quadratique moyenne (RMSE) de 4.578%. Nous avons également testé ces mêmes données, avec le même horizon de prédiction, avec la méthode AR sur Matlab, nous obtenons une erreur quadratique moyenne 6.197%. La méthode utilisée comprend, la décomposition des données en sept composantes. La prédictibilité de chacune de ces composantes est évaluée par le calcul des coefficients de Hurst. Les composantes qui ont une prédictibilité faibles sont éliminées afin d'optimiser les ressources. Par la suite les composantes qui ont une prédictibilité élevée sont passées par un réseau d'ondelette pour la prédiction de celle-ci. Enfin les résultats de la prédiction passent par l'algorithme de reconstruction, qui permet de reconstituer le résultat final de la prédiction.

Discussion

Il y a un engouement réel pour les énergies renouvelables dans le monde. Si les recherches sont poussées dans le sens de la pénétration des énergies renouvelables intermittentes (éolienne et solaire) dans les réseaux électriques et pour l'alimentation en électricité des régions éloignées. Ces sources d'énergies pourront être une bonne partie de la solution du réchauffement climatique. Le caractère intermittent de ces sources rend leurs prédictions incontournables pour participer à l'alimentation des réseaux électriques. À cause que, pour la stabilité du réseau électrique il faut que l'offre de puissance équilibre à la

demande de puissance. Donc le développement de méthodes de prédictions est nécessaire pour la gestion des énergies renouvelables dans des réseaux électriques.

Perspectives

Pour la suite des travaux il est souhaitable d'implanter l'algorithme de prédiction développé sur le banc d'essai présenté au chapitre 5, en développement par l'équipe d'énergie renouvelable de l'IRH.

Il est également souhaitable de construire une base de données de la vitesse du vent sur plusieurs années. Et du rayonnement solaire. Ce qui nécessite, l'installation d'anémomètre et le développement d'un système d'acquisition et de stockage des données. L'utilisation de ces données pour entraîner les réseaux ondelettes peuvent améliorer la prédiction. Puis que les données générales de la ville de Trois-Rivières ne représentent pas les données de la vitesse du vent au niveau de l'IRH.

Bibliographie (ou Références)

- [1] R. Dixon, M. Eckhart, D. Hales, and G. Thompson, “Rapport mondial 2012 sur les énergies renouvelables 2012,” *Renewable Energy Policy Network for the 21st Century*, pp. 1-20, 2012.
- [2] O. Edenhofer, R. Pichs-Madruga, Y. Sokona “ Rapport spécial sur les sources d ’ énergie renouvelable et l ’ atténuation du changement climatique,” *Institut de recherche de Potsdam sur les effets du changement climatique*, pp. 1-226, 2011.
- [3] Ministres de l’énergie et des Mines “ Le Canada – Chef de file mondial dans le domaine de l ’ énergie renouvelable,” *Conférence des ministres de l’énergie et des Mines, Yellowknife, Territoires du Nord-Ouest*, 2013.
- [4] A. Tiedemann, S. Oehlschlaeger, “Intégration des énergies renouvelables au réseau,” *renac (renewable Academy)*, pp. 1–36, Berlin, 2013,
- [5] S. Kélouwani and K. Agbossou, “Nonlinear model identification of wind turbine with a neural network,” *Energy Conversion, IEEE*, vol. 19, no. 3, pp. 607–612, 2004.
- [6] E. Goutard, “Renewable energy resources in energy management systems,” *Smart Grid Technol. Conf. Eur. ISGT*, pp. 1–6, Oct. 2010.
- [7] K. De Vos and J. Driesen, “Balancing management mechanisms for intermittent power sources—A case study for wind power in Belgium,” *Energy Mark. 2009. EEM 2009. 6th*, 2009.
- [8] S. S. Soman, H. Zareipour, O. Malik, and P. Mandal, “A review of wind power and wind speed forecasting methods with different time horizons,” in *North American Power Symposium 2010*, pp. 1–8, 2010.
- [9] Y.-K. Wu and J.-S. Hong, “A literature review of wind forecasting technology in the world,” *2007 IEEE Lausanne Power Tech*, pp. 504–509, Jul. 2007.
- [10] D. Delignières, “Séries temporelles – Modèles ARIMA.” *Seminaire EA (Sport performance Santé)*, pp.1-19 Mars 2000.
- [11] A. El Ghini, “Contribution à l ’ identification de modèles de séries temporelles,” *Université Charles De Gaule Lille III, Thèse*, pp. 1-130, 2008.

- [12] M. Agnès Lagnoux, Mix, “Séries Chronologiques.” *Université de Toulouse le Mirail ISMAG Master*, pp. 1-53
- [13] G. Mélard, “Initiation à l’analyse des séries temporelles et à la prévision,” *Rev. Modul.*, pp. 82–129, 2006.
- [14] D. Pastre, “L’intelligence artificielle definition generalites histoire,” *Université de Paris 5 Maître MASS - MST ISASH* pp. 1–10, 2000.
- [15] E. Brakni, “Réseaux de neurones artificiels appliqués à la méthode électromagnétique transitoire Infini TEM,” *Université du Québec à Chicoutimi Maîtrise* 2011.
- [16] Y. Bennani, “Apprentissage par réseaux de neurones artificiels,” *Université Paris 13, Ecole de printemps sur l’apprentissage arTficiel*, 2014.
http://epat2014.sciencesconf.org/conference/epat2014/pages/EPAT_2014_ANN.pdf.
- [17] Y. Oussar, “Réseaux d’ondelettes et réseaux de neurones pour la modélisation statique et dynamique de processus,” *Université de Paris VI Thèse* 1998.
- [18] I. Wikistat, “Machines à vecteurs supports,” *Wiki Stat* pp. 1–16, 1995.
- [19] M. Bhaskar, A. Jain, and N. Venkata Srinath, “Wind speed forecasting: Present status,” *2010 Int. Conf. Power Syst. Technol.*, pp. 1–6, Oct. 2010.
- [20] P. Gomes and R. Castro, “Comparison of statistical wind speed forecasting models,” *Sustain. Technol. (WCST)*, 2011, no. 2, pp. 56–61, 2011.
- [21] G. Li and J. Shi, “On comparing three artificial neural networks for wind speed forecasting,” *Appl. Energy*, vol. 87, no. 7, pp. 2313–2320, Jul. 2010.
- [22] K. Bhaskar and S. Singh, “Wind speed forecasting using MRA based adaptive wavelet neural network,” *Proc. 16th Natl. Power Syst. Conf*, pp. 18–25, 2010.
- [23] K. Bhaskar and S. N. Singh, “AWNN-Assisted Wind Power Forecasting Using Feed-Forward Neural Network,” *IEEE Trans. Sustain. Energy*, vol. 3, no. 2, pp. 306–315, Apr. 2012.
- [24] S. Lamens and W. D’haes, “Parameter Optimization Methods for the EDS Model,” *Acoust. Speech Signal*, pp. 480–483, 2006.
- [25] T. Ho, “Étude de la méthode de la transformation en ondelette et l’application à la compression des images Remerciements,” *Rapport final de TIPE Luong Hông Viêt* 2005.

- [26] J. Morlet and A. Grossmann, “Les ondelettes et le CIRM,” *smf4.emath.fr*, pp. 47–57, 2012.
- [27] F. Truchetet, “Ondelettes pour le signal numérique”, *Hermes. Paris*, 1998.
- [28] J. Gretilat, “Modification de l’algorithme de la transformée en ondelettes discrète pour l’obtention d’une représentation invariante sous rotation,” *Université Laval Maitrise Québec*, 2006.
- [29] S. Mallat, “A theory for multiresolution signal decomposition: the wavelet representation,” *Pattern Anal. Mach. Intell. IEEE*, vol. 1, no. 7, pp. 674–693, 1989.
- [30] N. Ferlay, “Analyse multi résolution du Transfert Radiatif en milieu hétérogène: application de la méthode de Galérien-ondelettes à l’Équation du Transfert Radiatif,” *Université Blaise Pascal* thèse 2003.
- [31] S. Dubois, “Décomposition spatio-temporelles pour l’étude des textures dynamiques,” *Université de la Rochelle*, Thèse 2010.
- [32] M. Pouliot, “La détermination des coefficients des ondelette de Daubechies,” *Université Laval Maîtrise* 2009.
- [33] C. Guillemot, R. Leonardi, N. Moreau, G. Piella, and B. Matei, “Ondelettes et décomposition spacio-temporelles avancées,” *Ecole nationale supérieure des télécommunications*, 2006.
- [34] M. Unser and T. Blu, “Wavelet theory demystified,” *Signal Process. IEEE Trans.*, vol. 51, no. 2, pp. 470–483, 2003.
- [35] V. Problems, A. Chambolle, R. A. Devore, N. Lee, B. J. Lucier, and S. Member, “Nonlinear Wavelet Image Processing : *Noise Removal Through Wavelet Shrinkage*,” vol. 7, no. 3, pp. 319–335, 1998.
- [36] I. Adam and E. Rădoi, “Complex wavelet transform: Application to denoising,” *Politehnica University of Timisoara and Université de Rennes 1*, pp. 1–146, 2010.
- [37] O. Mesa and G. Poveda, “The Hurst effect: the scale of fluctuation approach,” *Water Resour. Res.*, vol. 29, no. 12, pp. 3995–4002, 1993.
- [38] D. Delignières, “L’analyse des processus stochastiques,” *Sport. Performance, Santé*, *EA*, pp. 1–12, 2001.
- [39] B. Qian and K. Rasheed, “Hurst exponent and financial market predictability,” *IASTED Int. Conf. Financ.*, 2004.

- [40] K. Bhaskar and S. Singh, "Wind speed forecasting using MRA based adaptive wavelet neural network," *Proc. 16th Natl. Power Syst.*, pp. 18–25, 2010.
- [41] E. Istook and T. Martinez, "Improved backpropagation learning in neural networks with," v *In international Journal of Neural Systems*, vol. 12, no. 3, pp. 303–318, 2000.
- [42] C. Guzman, A. Cardenas, and K. Agbossou, "Load Sharing Strategy for Autonomous AC Microgrids Based on FPGA Implementation of ADALINE&FLL," *ieeexplore.ieee.org*, vol. 29, no. 3, pp. 663–672, 2014.
- [43] E. Padilla, K. Agbossou, and A. Cardenas, "Towards Smart Integration of Distributed Energy," *IEEE Transactions on Smart Grid*, vol. 5, no. 4, pp. 1686–1695, 2014.
- [44] E. M. P. Orejuela, "Développement d'une interface intelligente pour intégrer des sources d'énergies renouvelable dans un micro réseau à courant alternatif," *Université du Québec à Trois Rivières*, Maîtrise 2014.
- [45] É. Granger, "Modélisation du système à énergies renouvelables," *Institut de Recherche sur Hydrogène Trois Rivières*, 2008.
- [46] B. Beltran, "Maximisation de la puissance produite par une génératrice asynchrone Double alimentation d'une éolienne par mode glissant d'ordre supérieur," *JCGE'08 Lyon*, decembre 2008.
- [47] P. Jain, "Competitive Crowdsourcing," *Analytic magazine*, July/ August 2012.
- [48] A. Lendasse, *Analyse et prédiction de série temporelle par méthodes non linéaire. UCL Presses Université de Louvain*, p. 11, 2013.
- [49] M. Duan, "Time series predictability," *Marquette University Master of Science Milwaukee, Wisconsin*, April 2002.
- [50] P. J. Brockwell and R A. Davis, "Introduction to Time Series and Forecasting," *Second Edition Springer Texts in Statistics*, Springer-Verlag New York, 2002.
- [51] K. Buza, A. Nanopoulos and L. Schmidt- Thieme "IQ estimation for accurate time-series classification," *IEEE Intelligence and Data*, no. c, 2011.
- [52] H. Shaker, H. Zareipour, and D. Wood, "On error measures in wind forecasting evaluations," *Can. Conf. of Electrical and Computer Engineering*, pp. 0–5, 2013.

Index

Aucune entrée d'index n'a été trouvée.

Annexe A – Titre de l'annexe A

Le neurone formel

Les réseaux de neurone formelle est inspiré du concept des neurones biologiques. Ce neurone formel peut être considéré comme un opérateur qui a pour entrées des variables du milieu extérieur ou d'autres neurones. Chacune de ces entrées est associée à un poids synaptique (w_i) et fournit une sortie que lorsque la somme atteint un certain seuil. L'évaluation de la sortie se fait typiquement par la somme pondérée des entrées et le passage du résultat à travers $f(\cdot)$. Ce qui peut se modéliser algébriquement par [7] :

$$S = \sum_{i=0}^n w_i \cdot x_i + w_0 \cdot x_0 \quad (6.1)$$

$$y = f(S)$$

x_i : Composantes de u vecteur d'entrée.

w_i : Composant du poids synaptique.

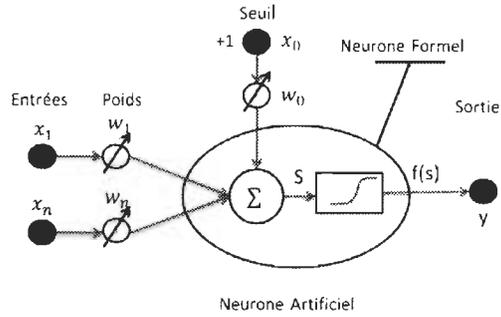
S : somme pondérée appelée potentiel.

Le terme $(w_0 \cdot x_0) = \Theta$ avec $x_0=1$ représente la valeur seuil interne qui doit être dépassé pour l'activation de la sortie de neurone. $f(\cdot)$ Est appelée fonction d'activation.

6.1.1 Fonction d'activation

Les fonctions d'activation sont de plusieurs types. Elles servent à limiter l'amplitude de la sortie du signal du neurone. Les fonctions d'activation les plus utilisées sont : la fonction seuil,

linéaire et sigmoïdale. Le tableau suivant énumère les différentes fonctions d'activation.



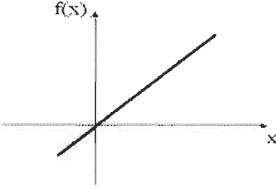
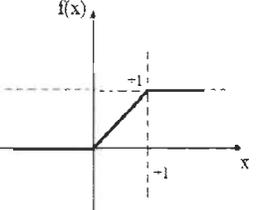
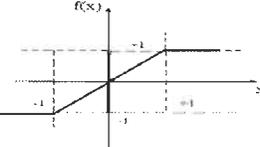
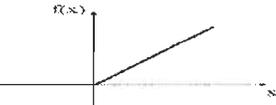
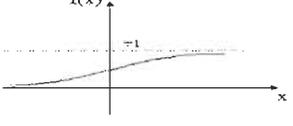
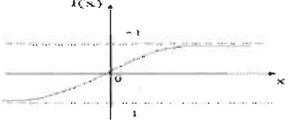
Modèle d'un neurone formel à entrées n

Figure 6-1 Neurone formel [7]

Le tableau suivant énumère les différentes fonctions d'activation.

Tableau 3

Nom de la fonction	Relation (entrée et sortie)	Allure de la courbe
Seuil	$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0 \end{cases}$	
Seuil symétrique	$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0 \end{cases}$	

Linéaire	$f(x) = x$	
Linéaire saturé	$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{si } 0 \leq x \leq 1 \\ 1 & \text{si } x > 1 \end{cases}$	
Linéaire saturé symétrique	$f(x) = \begin{cases} -1 & \text{si } x < -1 \\ x & \text{si } -1 \leq x \leq 1 \\ 1 & \text{si } x > 1 \end{cases}$	
Linéaire positif	$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{si } x \geq 0 \end{cases}$	
Sigmoidale	$f(x) = \frac{1}{1 + e^{-x}}$	
Tangente yperbolique	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	

Le paramètre le plus important de ce système est les coefficients synaptiques il permet de définir le modèle du système en fonction des informations données aux systèmes. Il trouve un mécanisme qui permet de calcul à partir des grandeurs que l'on peut acquérir du problème. C'est le principe de l'apprentissage.

<http://flylib.com/books/en/2.537.1.25/1/>

<http://www.ncbi.nlm.nih.gov/pmc/articles/PMC3590761/>