

UNIVERSITÉ DU QUÉBEC À MONTRÉAL

MODÈLES DE PRÉDICTION À APPRENTISSAGE AUTOMATIQUE POUR
LES RÉSEAUX DE CAPTEURS SANS FIL À ÉNERGIE RENOUVELABLE

MÉMOIRE PRÉSENTÉ
COMME EXIGENCE PARTIELLE
DE LA MAITRISE EN GÉNIE ÉLECTRIQUE

PAR
EL-HADI ZAZOUA

AVRIL 2022

UNIVERSITÉ DU QUÉBEC À MONTRÉAL
Service des bibliothèques

Avertissement

La diffusion de ce mémoire se fait dans le respect des droits de son auteur, qui a signé le formulaire *Autorisation de reproduire et de diffuser un travail de recherche de cycles supérieurs* (SDU-522 – Rév.04-2020). Cette autorisation stipule que «conformément à l'article 11 du Règlement no 8 des études de cycles supérieurs, [l'auteur] concède à l'Université du Québec à Montréal une licence non exclusive d'utilisation et de publication de la totalité ou d'une partie importante de [son] travail de recherche pour des fins pédagogiques et non commerciales. Plus précisément, [l'auteur] autorise l'Université du Québec à Montréal à reproduire, diffuser, prêter, distribuer ou vendre des copies de [son] travail de recherche à des fins non commerciales sur quelque support que ce soit, y compris l'Internet. Cette licence et cette autorisation n'entraînent pas une renonciation de [la] part [de l'auteur] à [ses] droits moraux ni à [ses] droits de propriété intellectuelle. Sauf entente contraire, [l'auteur] conserve la liberté de diffuser et de commercialiser ou non ce travail dont [il] possède un exemplaire.»

REMERCIEMENTS

Je tiens à remercier ma famille pour leur soutien et mes encadreurs, monsieur Wessam Ajib et monsieur Mounir Boukadoum pour leurs enseignements et conseils tout au long de l'élaboration de ce mémoire.

RÉSUMÉ

Les performances des réseaux de capteurs sans fil à récolte d'énergie sont dépendantes de la disponibilité de l'énergie ambiante aux nœuds du réseau. Une bonne gestion de l'énergie récoltée est primordiale au bon fonctionnement du réseau. Les nœuds du réseau suivent une politique d'allocation d'énergie qui réduit les dépenses inutiles. La transmission abusive est l'une de ces dépenses inutiles. Elle survient lorsqu'un nœud émetteur ignore si le nœud récepteur est apte à recevoir ou non. Lors d'un envoi infructueux, en attente d'un accusé de réception, le nœud émetteur renvoie les données perdues jusqu'à la réception d'acquiescement. Dans ce travail nous proposons un processus de communication basé sur la prédiction d'énergie des nœuds récepteurs pour un réseau de capteurs sans fil à récolte d'énergie afin d'éviter ces dépenses inutiles et améliorer, de ce fait, les performances de ces réseaux. Ces dernières années, la prédiction faite par des modèles de l'apprentissage automatique présente des performances de précision qui surpassent la majorité des modèles classiques de prédiction. Dans le cadre de cette problématique, nous avons utilisé les architectures neuronales suivantes, LSTM (Réseau de neurones à mémoire court terme et long terme, en anglais long short-term memory), N-BEATS (Analyse de l'expansion de la base neuronale pour les séries chronologiques, en anglais neural basis expansion analysis for time series) et *Transformer*, dans un modèle du réseau de capteurs sans fil composé de plusieurs nœuds. Nos expériences de validation montrent que parmi les modèles proposés, le modèle *Transformer* offre les meilleurs résultats en matière de précision. La prédiction est utilisée par l'émetteur pour estimer la quantité d'énergie des nœuds récepteurs et ainsi pour décider d'émettre ou pas s'il y a suffisamment d'énergie au récepteur et de faire une sélection entre les différents récepteurs dans le cas où plusieurs récepteurs sont aptes à recevoir simultanément. Les résultats obtenus des simulations du processus de communication permettent d'affirmer que ce processus basé sur la prédiction permet d'améliorer les performances du réseau en termes de fiabilité de transmission et de diminuer le temps nécessaire pour la collecte des données.

Mots clés :

Réseaux de capteurs sans fil (RCSF), récolte d'énergie dans les RCSF, Apprentissage supervisé, Modèle de prédiction de séries temporelles, LSTM, *Transformer*, N-BEATS.

TABLE DES MATIÈRES

Résumé.....	III
Liste des figures	VII
Liste des tableaux	IX
Liste des abréviations, des sigles et des acronymes	X
INTRODUCTION	12
CHAPITRE I INTRODUCTION AUX RÉSEAUX DE CAPTEURS SANS FIL A RÉCOLTE D'ÉNERGIE.....	15
1.1. Les différents nœuds d'un réseau de capteurs sans fil	15
1.2. Les composants d'un capteur a récolte d'énergie	16
1.2.1 Module de captation	17
1.2.2 Module de traitement	17
1.2.3 Module mémoire	18
1.2.4 Module de transmission	18
1.2.5 Module de stockage d'énergie	18
1.2.6 Module de récolte d'énergie ambiante	18
1.3. L'énergie renouvelable.....	19
1.3.1 Convertisseur d'énergie solaire.....	19
1.3.2 Convertisseur d'énergie mécanique	20
1.3.3 Convertisseur d'énergie thermique	20
1.4. Domaines d'applications.....	20
1.4.1 Domaine de la santé	21
1.4.2 Domaine militaire.....	21
1.4.3 Domaine industriel	21
1.4.4 Domaine de la surveillance environnementale	21
1.4.5 Domaine du transport.....	22
1.5. Les exigences d'un réseau de capteurs sans fil.....	22
1.5.1 Efficacité énegetique.....	22

1.5.2	Adaptation.....	22
1.5.3	Charge du trafic.....	23
1.5.4	Délai de transmission	23
1.5.5	Débit.....	23
CHAPITRE II PROBLÉMATIQUE, OBJECTIF ET CONTRIBUTIONS ..		24
2.1.	Problématique et motivation	24
2.2.	Objectif.....	26
1.3.	Méthodologie	26
2.4.	Contributions.....	28
CHAPITRE III L'ÉTAT DE L'ART DE LA PRÉDICTION DANS LES		
RCSF-RE.....		29
3.1.	Modèles stochastiques.....	29
3.1.1.	Modèle unifié a deux etats	30
3.1.2.	Modèle Maker	31
3.1.3.	Modèle ASIM (accurate solar irradiance prediction model).....	31
3.2.	Modèles statistiques	32
3.2.1.	Modèle EWMA (exponentially weighted moving average)	32
3.2.2.	Modèle WCMA (weather-conditioned moving average)	33
3.2.3.	Modèle ASEA (accurate solar energy allocation).....	35
3.2.4.	Modèle Pro-Energy (profile energy).....	36
3.2.5.	Filtre NLMS (normalized least mean square).....	38
3.2.6.	Modèle WFBP (weather forecast based prediction)	39
3.2.7.	Modèle SEPAD (solar energy prediction using additive decomposition) ..	39
3.2.8.	Modèle RWMA (real forecast weather moving average).....	41
3.2.9.	Modèle WEP (wind energy predictor)	43
3.2.10.	Filtre de Kalman.....	44
3.3.	Modèles basés sur l'apprentissage automatique	46
3.3.1.	Modèle QL-SEP (Q-learning for solar energy prediction)	46
3.3.2.	Réseaux ANN (réseau de neurones artificiels)	49
3.3.3.	Autres utilisations de l'apprentissage automatique dans les RCSF	52
3.4.	Autres approches.....	53
3.4.1.	Modèle flou.....	53

CHAPITRE IV MODÈLE DU SYSTÈME	55
4.1. Modèle du réseau	55
4.2. Modèles de prédiction d'énergie	58
4.2.1. Long short term memory (LSTM)	58
4.2.2. Le <i>Transformer</i>	60
4.2.3. Le N-BEATS (neural basis expansion analysis for time series).....	62
4.3. Processus de communication	63
CHAPITRE V MODÈLES DE PRÉDICTION: APPLICATION ET SIMULATION.....	66
5.1. L'entraînement des prédicteurs	66
5.1.1. L'entraînement du <i>Transformer</i>	67
5.1.2. L'entraînement du LSTM	69
5.1.3. L'entraînement du N-BEATS	69
5.2. Comparaison entre les différents prédicteurs	71
5.3. Application des prédicteurs sur le processus de communication.....	75
CONCLUSION GÉNÉRALE.....	88
RÉFÉRENCES.....	91

LISTE DES FIGURES

Figure	page
Figure 1.1. Les composants d'un capteur à récolte d'énergie	16
Figure 4.1. Schéma du réseau de capteurs sans fil à énergie renouvelable.....	56
Figure 4.2. Représentation temporelle du fonctionnement d'un émetteur.....	57
Figure 4.3 Architecture d'une cellule LSTM	59
Figure 4.4 Architecture du Transformer	61
Figure 4.5. Architecture du N-BEATS (Oreshkin et al, 2019)	62
Figure 5.1. Variation de la RMSE en fonction du nombre de couches d'encodeur du Transformer.....	68
Figure 5.2 Variation de l'erreur de prédiction en fonction de la longueur d'entrée.....	72
Figure 5.3. Prédiction de l'énergie solaire avec LSTM, Transformer et N-BEATS ..	73
Figure 5.4. Prédiction de l'énergie solaire avec différents prédicteurs	73
Figure 5.5 Comparaisons entre l'erreur de prédiction de différents prédicteurs	74
Figure 5.6 Architecture du modèle de réseaux de capteurs considéré	75
Figure 5.7 Pourcentage de réussite en fonction du nombre de nœuds pour un paquet de 50 kbit	77
Figure 5.8 Pourcentage de réussite en fonction du nombre de nœuds pour un paquet de 100 kbit	78
Figure 5.9 Pourcentage de réussite en fonction de la taille du paquet pour un réseau à 100 nœuds	79
Figure 5.10 Pourcentage de réussite en fonction de la distance moyenne entre les nœuds pour un réseau à 100 nœuds	81

Figure 5.11 Pourcentage de réussite en fonction de la capacité maximale de la batterie pour un réseau à 100 nœuds	82
Figure 5.12 Délai pour transmettre un paquet de données en fonction de la taille du paquet pour un réseau de 100 nœuds	83
Figure 5.13 Délai pour transmettre un paquet de 100 <i>kbit</i> en fonction du nombre de nœuds dans le réseau.....	84
Figure 5.14 Délai pour transmettre un paquet de 100 <i>kbit</i> en fonction de la distance moyenne entre les nœuds pour un réseau de 100 nœuds	85
Figure 5.15 Délai pour transmettre un paquet de 100 <i>kbit</i> et de 50 <i>kbit</i> en fonction de la capacité maximale de la batterie pour un réseau de 100 nœuds.....	86

LISTE DES TABLEAUX

Tableau	page
Tableau 5.1. Variation de la RMSE en fonction du nombre de têtes d'attention du modèle <i>transformer</i>	68
Tableau 5.2. Variation de la RMSE en fonction de la variation du rapport T/H	70
Tableau 5.3. Variation de la RMSE en fonction du nombre de blocs basique par pile d'empilement.....	70
Tableau 5.4. Variation de la RMSE en fonction de la nature des fonctions <i>glf</i> et <i>glb</i>	71
Tableau 5.5. La valeur des hyperparamètres du N-BEATS.....	71

LISTE DES ABRÉVIATIONS, DES SIGLES ET DES ACRONYMES

MAC	Contrôle d'accès au support (en anglais medium access control)
RSCF	Réseau de capteurs sans fil
RSCF-RE	Réseau de capteurs sans fil à récolte d'énergie
LSTM	Réseau de neurones récurrents à mémoire court terme et long terme (en anglais long short-term memory)
RMSE	Racine de l'erreur quadratique moyenne (en anglais root mean square error)
N-BEATS	Analyse de la base d'expansion neuronale pour les séries chronologiques (en anglais neural basis expansion analysis for time series)
ASIM	Modèle de prédiction précis de l'irradiance solaire (en anglais accurate solar irradiance prediction model)
EWMA	La moyenne mobile à pondération exponentielle (en anglais the exponentially weighted moving average)
WCMA	Moyenne mobile conditionnée par la météo (en anglais weather conditioned moving average)
ASEA	Allocation précise de l'énergie solaire (en anglais accurate solar energy allocation)
Pro-Energy	Profil d'énergie (en anglais profile energy)

Pro-Energy VLT	Modèle de profil d'énergie avec des intervalles de temps de longueur variable (en anglais profile energy model with variable-length timeslots)
I Pro-Energy	Modèle de profil d'énergie avec amélioration (en anglais profile energy model and enhancements)
NLMS	Moyenne des moindres carrés normalisé (en anglais normalized least mean square)
WFBP	Prédiction basée sur les prévisions météorologiques (en anglais weather forecast based prediction)
SEPAD	Prédiction de l'énergie solaire par décomposition additive (en anglais solar energy prediction using additive decomposition)
RWMA	Prévisions météo réelles à moyennes mobiles (en anglais real-forecast weather moving average)
WCS	Modèle sélectif selon les conditions météorologiques (en anglais weather-conditional selective)
WEP	Prédicteur de l'énergie éolienne (en anglais wind energy predictor)
QL-SEP	Q-learning pour la prédiction de l'énergie solaire (en anglais Q-learning for solar energy prediction)
ANN	Réseau de neurones artificiels (en anglais artificial neural network)

INTRODUCTION

Le besoin d'automatiser des tâches dans des endroits éloignés ou difficiles d'accès mène au perfectionnement des technologies embarquées qui allient l'informatique et l'électronique dans des systèmes miniaturisés. Les tâches de capture de l'information et sa transmission sont devenues nécessaires pour une surveillance efficace de certains paramètres d'environnements. Les réseaux de capteurs sans-fil font partie des technologies qui ont émergé de ce besoin. Ils sont constitués d'un ensemble de capteurs aptes à capter de l'information et à la transmettre. Dépendamment de la nature du besoin, ces capteurs sont déployés dans des environnements où l'on souhaite recueillir des données tel qu'un corps humain, une installation industrielle, etc. Ces capteurs sont caractérisés par une faible puissance de traitement et une autonomie énergétique assez réduite. Grâce aux récentes avancées technologiques, le recours aux énergies renouvelables a rapidement été envisagé pour permettre une plus grande autonomie d'énergie à ces capteurs. Bien que les sources d'énergie renouvelable soient très profitables vu la nature de ces réseaux, leur caractère aléatoire ajoute son lot de complexité. La bonne gestion de l'énergie demeure le principal enjeu de ces réseaux de capteurs sans fil à récolte d'énergie. Ces capteurs sont de taille limitée et très nombreux au sein d'un réseau, et ne peuvent donc se permettre que peu de capacité de stockage d'énergie comparée à leurs besoins opérationnels. Cette énergie doit être allouée à bon escient entre les différents modules constituant un capteur pour assurer un fonctionnement optimal de l'ensemble du réseau, en réduisant les dépenses inutiles et en mettant en veille les composants inactifs. De nombreuses recherches ont abordé ce problème par le biais de la prédiction de l'état énergétique des nœuds. Lorsqu'un nœud prédit son niveau d'énergie futur, il assure une meilleure allocation d'énergie

entre ses différents modules. Lorsqu'un nœud fait la prédiction de l'énergie du prochain nœud récepteur, il évite les échecs de transmissions dus à une énergie insuffisante pour la réception. Des recherches, présentées dans l'état de l'art, utilisent pour la prédiction différents modèles stochastiques, des modèles statistiques et des modèles de l'apprentissage automatique. Bien que ces recherches aient démontré une certaine amélioration des performances du réseau en ce qui concerne la fiabilité et l'économie d'énergie, la problématique demeure toujours d'actualité. Dans le cadre de ce travail, nous proposons et évaluons l'utilisation des modèles de l'apprentissage automatique réputés être plus performants en matière de prédiction, nommément LSTM, N-BEAT et *Transformer*. L'apprentissage automatique est une sous-discipline de l'intelligence artificielle qui consiste à donner aux ordinateurs la capacité d'apprendre par eux-mêmes, en se basant sur une quantité de données d'apprentissage. Ses domaines d'application sont très variés tels que la vision par ordinateur, la localisation de caractère, la reconnaissance de visage et de la voix, l'analyse d'image médicale, la prédiction financière, la robotique et la détection d'obstacle, etc. Nous utilisons ces modèles pour faire la prédiction de la quantité d'énergie disponible dans les nœuds en aval. Ces modèles sont utilisés afin de définir une meilleure stratégie d'allocation de l'énergie et de routage pour un réseau de capteurs sans fil à récolte d'énergie.

Dans le premier chapitre, nous effectuons une présentation des réseaux de capteurs sans fil à récolte d'énergie, les différents composants d'un nœud, leurs domaines d'application ainsi que les exigences liées à leur exploitation. La première section du deuxième chapitre présente les principaux défis rencontrés dans la gestion énergétique des réseaux de capteurs sans fil. Les sections suivantes présentent respectivement l'objectif de ce mémoire, la méthodologie suivie pour atteindre l'objectif de ce mémoire, et les contributions que peut apporter cette étude à l'amélioration de la gestion énergétique des réseaux de capteurs sans fil à récolte d'énergie.

Le troisième chapitre présente l'état d'art de la prédiction dans les réseaux de capteurs sans fil à récolte d'énergie. Le quatrième chapitre présente en première partie le modèle

du réseau de capteurs sans fil à récolte d'énergie qui sera considéré dans cette étude. La seconde partie de ce chapitre présente les modèles de prédictions issus de l'apprentissage automatique que nous proposons d'utiliser. La troisième partie est consacrée au processus de communication proposé pour mettre en pratique la prédiction de l'énergie des nœuds récepteurs au modèle du réseau de capteurs. Le cinquième chapitre comporte une présentation des procédures d'entraînement des modèles de prédiction, les résultats de simulation ainsi qu'une comparaison entre ces différents modèles de prédiction. La seconde partie de ce chapitre est consacrée à la simulation du processus de communication basé sur la prédiction de l'énergie des prochains nœuds et à l'étude de l'impact de l'utilisation de cette prédiction sur les performances du réseau. Le dernier chapitre est consacré aux conclusions et à une proposition des travaux futurs qui pourront présenter une continuité à ce travail.

CHAPITRE I

INTRODUCTION AUX RÉSEAUX DE CAPTEURS SANS FIL A RECOLTE D'ÉNERGIE

Ce chapitre comporte une présentation générale des réseaux de capteurs sans fil à récolte d'énergie, leurs différents composants, leurs domaines d'application et les exigences liées à leur exploitation.

1.1. Les différents nœuds d'un réseau de capteurs sans fil

Un réseau de capteurs sans fil est constitué de plusieurs nœuds déployés selon le domaine d'application et selon les contraintes de l'environnement de déploiement (Diane, 2014). Ce mémoire considère un simple réseau de capteurs constitué de capteurs, de relais et d'un puits.

1.1.1. Les capteurs

Ce sont les éléments majoritaires dans les réseaux de capteurs sans fil. Ils peuvent être mobiles ou statiques. Ils ont pour rôle de capter de l'information de leur environnement immédiat (par ex. constante corporelle, température, vitesse du courant marin, etc.) et la transmettre en aval de la chaîne de transmission vers le puits. Ils peuvent aussi servir de relais et n'avoir pour tâche que la transmission des données reçues d'un autre capteur.

1.1.2. Le relais

C'est généralement un capteur dont la tâche de captation est mise en veille à des fins de routage. Il peut également jouer le rôle de capteur et de relais. Il est déployé là où l'environnement de captation présente peu d'intérêt à l'utilisateur. Il n'a pour tâche que de retransmettre l'information reçue.

1.1.3. Le puits

Le rôle du puits est de recevoir les données émises par les nœuds en aval. C'est un point de collecte où toutes les données captées et transmises aboutissent avant d'être transmises vers l'interface utilisateur via une connexion filaire, satellite ou sans fil de haut débit. C'est également à travers le puits que l'utilisateur du réseau de capteurs adresse des requêtes aux nœuds. Dû aux tâches complexes qui leur incombent, ainsi qu'à leur fréquence, les puits sont caractérisés par une plus grande capacité de stockage de mémoire et d'énergie que les capteurs.

1.2. Les composants d'un capteur à récolte d'énergie

Un capteur est composé de plusieurs modules (composants) tels que montrés dans la Figure 1.1. Chacun de ces modules effectue une tâche spécifique.

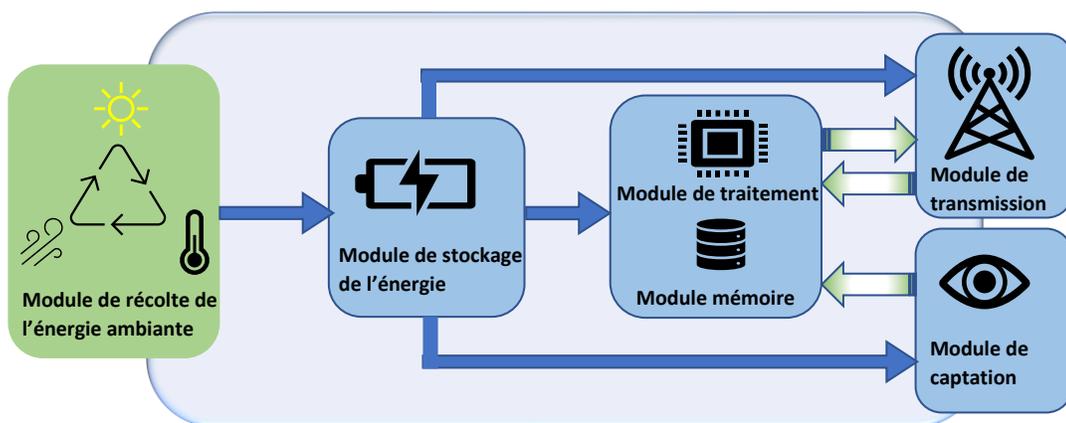


Figure 1.1. Les composants d'un capteur à récolte d'énergie

1.2.1 Module de captation

Il est responsable de la détection des évènements cibles qui environnent le capteur tels que la température, la pression, etc. C'est un dispositif composé de deux sous-unités : (i) le récepteur qui est sensible à l'évènement cible et (ii) le transducteur qui convertit le signal du récepteur en signal électrique analogique. Ce signal est ensuite amené au convertisseur Analogique/Numérique pour qu'il soit compatible à l'entrée du processeur. (Saidi *et al*, 2016)

Selon leurs applications, il en existe plusieurs modèles tels que:

- capteur de température,
- capteur de pression,
- capteur de mouvement,
- capteur de vibration,
- capteur de gaz.

1.2.2 Module de traitement

C'est un processeur qui traite les données reçues par le capteur et le module radio et désigne la tâche à exécuter selon le protocole de Contrôle d'Accès au Support (en anglais Medium Access Control ou MAC) préétabli qu'il doit suivre. Le module de traitement est également le siège des protocoles de routage qui effectuent une sélection du chemin à suivre par les paquets de données pour être transmis du nœud source vers le nœud destination. Le processeur fonctionne à l'aide d'un système d'exploitation spécialement conçu pour ce genre de technologie embarquée tel que TinyOS. C'est ce module qui désigne quel module doit fonctionner et lequel doit être mis en veille au sein du capteur. Toute tâche liée à l'organisation et à la gestion de l'énergie des différents modules se fait à l'aide d'algorithmes implémentés. Notamment la prédiction, sujet de ce mémoire, se fait au niveau de ce module en se basant sur des données reçues par le module de transmission et sauvegardées dans la mémoire.

1.2.3 Module mémoire

C'est une unité de stockage des données captées par le capteur, ainsi que des données à transmettre par le module radio, que ça soit pour une utilisation interne (prédiction par exemple) ou pour la retransmission vers un autre nœud.

1.2.4 Module de transmission

Ce module est responsable de la transmission sans fil de données entre les différents nœuds du réseau. Les réseaux de capteurs sans fil sont caractérisés par des débits faibles avec une fréquence de communication variant entre 433 MHz et $2,4\text{ GHz}$ (Drissi, 2014). Le module de transmission est considéré comme étant le module qui consomme le plus d'énergie. L'énergie consommée pour une transmission entre deux nœuds est dépendante de la distance et de la qualité du canal de transmission qui les sépare.

1.2.5 Module de stockage d'énergie

Un réseau de capteurs est tributaire de son énergie. Le module de stockage d'énergie, dû à sa nature embarquée, offre très peu d'autonomie comparé à son besoin en consommation. La nécessité d'une gestion optimale de l'énergie est rapidement devenue primordiale. Un module de stockage d'énergie est caractérisé par sa taille, sa capacité de stockage et sa durée de vie. Les plus couramment utilisés sont les batteries et les supercondensateurs.

Un supercondensateur est caractérisé par une durée de vie et une densité de puissance beaucoup plus importante que celle d'une batterie. En revanche, une batterie a une capacité de stockage bien plus élevée que celle d'un supercondensateur.

1.2.6 Module de récolte d'énergie ambiante

Ce module assure la conversion de l'énergie ambiante (solaire, éolienne, pression, etc.) en énergie électrique. Cette énergie subit une opération de régulation afin de la préparer

à être stockée dans le module de stockage d'énergie avant d'être consommée par les différents modules du nœud.

1.3. L'énergie renouvelable

Par opposition aux énergies fossiles, dites non renouvelables, les énergies renouvelables représentent toute sorte d'énergie non tarissable. Le principe est de convertir une source d'énergie ambiante (solaire, éolienne, etc.) en une énergie utilisable. L'une des premières utilisations de cette forme de conversion remonte à l'antiquité, les moulins à vent convertissaient l'énergie du vent en énergie mécanique. Le même principe est utilisé aujourd'hui avec les éoliennes, convertissant à leur tour l'énergie mécanique issue de la rotation des palettes en énergie électrique. D'autres sources d'énergie ont rapidement été exploitées, notamment le soleil, qui est considéré comme la source d'énergie la plus abondante. L'effet photovoltaïque a été découvert dès 1839. C'est un effet qui permet de convertir la lumière en électricité grâce à des matériaux semi-conducteurs. Mais ce n'est qu'assez récemment que la technologie permet une exploitation plus accrue de cette source d'énergie. En effet, la modernisation des dispositifs électroniques et leur minimisation ont permis une démocratisation de ces technologies visant à exploiter l'énergie ambiante. Selon le domaine d'application et de son besoin en énergie, il existe plusieurs types de convertisseurs d'énergie ambiante et de toutes les tailles. Pour les réseaux de capteurs sans fil, ces convertisseurs sont représentés par le module de récolte de l'énergie ambiante, et peuvent être classés selon la source d'énergie qu'ils convertissent.

1.3.1 Convertisseur d'énergie solaire

C'est un dispositif équipé de cellules photovoltaïques qui convertit la lumière du soleil en électricité et d'un régulateur qui stabilise la tension générée. L'inconvénient de cette technologie est l'inconstance de la source. En effet, les conditions météorologiques, telles qu'un ciel nuageux, affectent considérablement la disponibilité de l'énergie.

1.3.2 Convertisseur d'énergie mécanique

Ces convertisseurs transforment l'énergie mécanique en énergie électrique de trois manières différentes (Saidi *et al*, 2016).

- La conversion électromagnétique est basée sur un effet d'induction généré par l'interaction entre un aimant et un courant ou un circuit ferromagnétique. C'est le type de conversion utilisé dans les éoliennes par exemple.
- La conversion électrostatique est régie par le mouvement de deux corps chargés électriquement qui crée une différence de potentiel entre les deux. Si ces corps sont raccordés à un circuit électrique, un courant en résulte.
- La conversion piézoélectrique est basée sur la propriété qu'ont certains matériaux de se polariser électriquement sous une contrainte mécanique, une pression par exemple. Raccordée de bout à bout dans un circuit électrique, cette polarisation crée une différence de potentielle et du courant électrique. Ce type de conversion est utilisé par exemple dans des ponts ou des autoroutes.

1.3.3 Convertisseur d'énergie thermique

Lorsqu'il y a une différence de température entre deux métaux reliés par deux jonctions, une tension apparait. C'est l'effet Seebeck. Toutefois, à cause de son ordre de grandeur faible, soient quelques micro-volt par °C d'écart, son utilisation reste peu répandue.

L'horloger Seiko a commercialisé en 1998 la première montre alimentée par la chaleur corporelle en exploitant la différence de température entre la peau et l'air ambiant.

1.4. Domaines d'applications

La diversité des sondes de détection (thermique, optique, vibration, etc.) ainsi que la miniaturisation constante des composants électroniques ont permis aux réseaux de capteurs sans fil d'être utilisés dans plusieurs domaines, particulièrement dans les

endroits où il est plus prudent et moins onéreux de déployer des capteurs plutôt que d'envoyer un opérateur pour faire manuellement une tâche d'échantillonnage.

1.4.1 Domaine de la santé

Ils existent des microcapteurs placés sous la peau, ou autour d'un organe afin de rester informé sur son fonctionnement. Ces dispositifs aident à surveiller l'évolution de l'état de santé de patients et de prévenir la dégénérescence d'organes en ayant un aperçu constant de leur fonctionnement.

1.4.2 Domaine militaire

Évitant à l'homme de s'aventurer dans des zones à risque, les réseaux de capteurs sans fil sont très utilisés pour la surveillance des mouvements dans des zones dangereuses, la surveillance des frontières, la détection de radiation et d'agent chimique.

1.4.3 Domaine industriel

Les réseaux de capteurs sans fil font partie intégrante des infrastructures industrielles. Ils sont très utilisés pour surveiller en temps réel la température de l'appareillage, la pression des conduits ou des pipes acheminant du gaz et les vibrations des infrastructures. Cette surveillance fournit aux opérateurs un moyen concret pour prévenir les bris industriels.

1.4.4 Domaine de la surveillance environnementale

Les réseaux de capteurs sans fil sont largement utilisés pour prévenir des séismes, des activités volcaniques et des feux de forêt, etc. Ainsi, ils permettent de détecter d'éventuelles catastrophes climatiques. Ils sont également utilisés pour étudier les cycles migratoires de certains animaux. Contrairement à la présence humaine, la petite taille des capteurs permet d'étudier la faune d'un environnement sans altérer son comportement.

1.4.5 Domaine du transport

Dans le domaine du transport, surveiller l'état des infrastructures relève de la sécurité de tous. Les réseaux de capteurs sans fil sont employés pour détecter les vibrations des ponts ou des voies ferrées, la présence d'objets ou de personnes sur les lignes de métro, ainsi que l'état du trafic des autoroutes. Ces informations sont nécessaires pour la fluidité du trafic et la sécurité des individus.

1.5. Les exigences d'un réseau de capteurs sans fil

La fiabilité d'un réseau de capteurs sans fil exige le respect de plusieurs contraintes telles que (Diane, 2014) (Drissi, 2014),

1.5.1 Efficacité énergétique

Étant déployés à des endroits difficilement accessibles, là où une intervention humaine se verrait vite onéreuse et contraignante, les réseaux de capteurs doivent opérer une gestion adéquate de la quantité d'énergie à disposition. Les protocoles de transmission et de routage travaillent de concert pour optimiser l'économie d'énergie et ainsi permettre de prolonger la durée de vie des nœuds et du réseau.

1.5.2 Adaptation

Un réseau de capteurs doit être capable de s'adapter en cas de perte de nœuds due à un déficit en énergie ou à un dysfonctionnement du matériel. Ainsi, maintenir une qualité de service adéquate pour son exploitation est primordial.

L'ajout de nouveaux nœuds qui rejoignent le réseau, notamment pour les réseaux de capteurs mobiles, ou plus généralement lors de déploiement de nouveaux nœuds dans un réseau préexistant peut également présenter une certaine complexité pour l'auto-organisation du réseau.

1.5.3 Charge du trafic

La transmission entre les différents nœuds d'un réseau de capteurs sans fil (RCSF) s'opère à travers un canal de transmission. Un nombre important de nœuds qui émettent au même moment peut causer une surutilisation de ce canal et donc les signaux seront en interférence. Afin d'éviter ce problème, des techniques sont utilisées telles qu'une bande passante d'une certaine largeur, ainsi qu'un protocole de mise en veille sélective des nœuds.

1.5.4 Délai de transmission

C'est le délai entre le moment de l'émission d'un paquet et le moment de sa réception par le destinataire. Ce délai est relatif au domaine d'application du RCSF en question. Cependant, réduire ce délai correspond à réduire le nombre de nœuds sollicités pour acheminer ce paquet et ainsi réduire le taux d'erreur, la charge du trafic et la consommation d'énergie.

1.5.5 Débit

Le débit représente la quantité de données transmises d'un émetteur à un récepteur en un temps donné. Il est mesuré en bits par seconde. L'exigence en débit est relative au domaine d'application du réseau. Il se peut que certains réseaux, pour la détection d'évènements par exemple, exigent un faible débit. C'est un avantage, car une transmission à faible débit consomme peu d'énergie comparé à une transmission à haut débit.

CHAPITRE II

PROBLÉMATIQUE, OBJECTIF ET CONTRIBUTIONS

La première section de ce chapitre présente les principaux défis rencontrés dans la gestion énergétique des réseaux de capteurs sans fil. Les sections suivantes présentent l'objectif de ce mémoire, la méthodologie suivie et les contributions de cette étude à l'amélioration de la gestion énergétique des réseaux de capteurs sans fil à récolte d'énergie.

2.1. Problématique et motivation

Afin d'obtenir de meilleures performances, le réseau doit éviter la surconsommation d'énergie lors des transferts de données. Il y'a plusieurs phénomènes qui causent cette surconsommation d'énergie :

- L'écoute à vide : elle représente l'activation du module radio par un capteur récepteur en attente d'éventuelles données à recevoir.
- L'écoute abusive : elle se produit lorsque le nœud est constamment à l'écoute du canal et intercepte des données qui ne lui sont pas destinées.
- Les collisions : lorsqu'un nœud reçoit plusieurs données en même temps, les nœuds qui ne reçoivent pas d'acquittement renvoient les mêmes données.
- La transmission abusive : c'est un phénomène assez fréquent lorsqu'un nœud émetteur ignore si le nœud récepteur est apte à recevoir ou non. Lors

d'un envoi infructueux, en attente d'acquittement, le nœud émetteur renvoie les données perdues à intervalle régulier jusqu'à la réception d'acquittement.

Pour amoindrir le coût énergétique de l'écoute à vide et de l'écoute abusive, des techniques ont été mises en place telles que le cycle de service, qui consiste à mettre le module radio en mode veille lorsqu'il n'est pas censé opérer, et doivent être prêts à fonctionner s'il y'a une donnée à recevoir. Divers protocoles existent, notamment le Sommeil/Réveil, qui synchronise les périodes de sommeil et de réveil afin d'assurer la coopération des nœuds. Dans ce travail, nous allons utiliser l'une des catégories du protocole Sommeil/réveil qui consiste à se réveiller en même temps après un intervalle de temps prédéfini. Les méthodes les plus utilisées pour résoudre le problème des collisions sont des protocoles au niveau de la couche MAC. Ils effectuent un ordonnancement des nœuds en se basant sur un Cycle de service, l'estimation de l'activité du canal et la densité de nœuds dans le voisinage. Divers protocoles ont vu le jour tel que le B-MAC, le S-MAC et le Z-MAC où chacun a une approche particulière pour résoudre le problème (Diane, 2014).

Depuis plusieurs années, la recherche s'efforce de remédier au problème de la dépense inutile de l'énergie par le biais de la prédiction. En effet, il a été établi que lorsqu'un nœud a une estimation de son état d'énergie future, il génère une meilleure politique d'allocation de son énergie entre ces différents modules. En extrapolant de la même hypothèse basée sur la prédiction, il est intéressant de proposer un protocole au réseau où le nœud émetteur prédit l'énergie du nœud récepteur. Ainsi le nœud émetteur peut savoir si le nœud récepteur est apte ou non à recevoir des données, et évite ainsi la transmission abusive. Le nœud émetteur peut donc ajuster la taille des données ou simplement différer l'émission. Cette aptitude permet de générer une économie d'énergie considérable et d'éviter la saturation du canal en l'allégeant des transmissions infructueuses.

Dans ce travail, nous proposons un modèle de prédiction basé sur l'apprentissage automatique. Ce modèle améliore considérablement la justesse de l'allocation de

l'énergie des nœuds et donc assure une meilleure performance au niveau de tout le réseau.

2.2. Objectif

L'objectif de ce travail est de proposer une meilleure gestion de l'énergie basée sur la prédiction de la quantité d'énergie des prochains nœuds dans un réseau de capteurs sans fil à récolte d'énergie (RCSF-RE). La littérature désigne les algorithmes de prédiction issus de l'apprentissage profond comme étant les plus performants. Nous proposons l'utilisation de ces algorithmes de prédiction comme prédicteur, le modèle LSTM, le modèle *Transformer* et le modèle N-BEATS. Nous concevons un processus de communication pour un RCSF-RE basé sur la prédiction de l'énergie des prochains nœuds. L'évaluation des performances du RCSF-RE avec prédiction se fait selon plusieurs métriques. Cette évaluation nous permet d'étudier les effets de prédiction sur un RCSF-RE et de déduire l'influence que peuvent avoir certaines variables sur le RCSF-RE telles que le nombre de nœuds, la distance moyenne entre les nœuds, la longueur des paquets de données à transmettre, etc. Ce travail permet de comprendre l'impact de la prédiction sur un RCSF-RE et de proposer des stratégies d'allocation d'énergie et de routage plus économiques en matière d'énergie, plus robuste aux variables caractérisant les RCSF-RE et plus performantes en temps d'exécution.

2.3. Méthodologie

Afin d'atteindre l'objectif principal de ce projet, nous procédons selon les étapes suivantes. Nous commençons par concevoir un modèle de RCSF-RE et établir un processus de communication représentatif de la dynamique d'un réseau de capteurs opérationnels. On fait ensuite l'étude des performances du modèle sans prédiction en utilisant comme métriques le rapport entre le nombre paquets arrivés au puits et le nombre de paquets émis par le premier nœud, appelé pourcentage de réussite, et le nombre d'intervalles de temps nécessaire pour la transmission d'un paquet de données

de la source au puits, le délai. Ces deux métriques permettent d'avoir une vue détaillée sur la gestion de l'énergie par le réseau et caractérisent ses performances en matière d'efficacité et de rapidité de transmission. L'utilisation de métriques telle que l'âge des données et l'intervalle des mises à jour ne sont pas nécessaires dans ce cas d'application. Les métriques classiques sont suffisantes pour représenter les performances du réseau. On propose ensuite des modèles de prédiction issus de l'apprentissage profond et on étudie leurs performances en matière de prédiction de données météorologiques susceptibles de représenter une source d'énergie ambiante aux nœuds (les radiations solaires pour l'énergie solaire). Ces modèles de prédiction sont le LSTM, le *Transformer* et le N-BEATS. Les réseaux de neurones récurrents, étant des machines à états, possèdent l'aptitude de prendre en compte les relations entre les différents éléments d'une série chronologique. Cette aptitude fait défaut aux réseaux de neurones à propagation avant et cela se traduit par des performances moindres que les réseaux de neurones récurrents. Cependant, à cause d'un phénomène appelé l'évanouissement du gradient, cette aptitude est limitée par la distance dans le temps de ces éléments, plus un élément utile à la prédiction est loin dans le passé plus le modèle aura du mal à être performant. Les modèles basés sur LSTM résolvent partiellement ce problème. Ils permettent de diminuer cet effet d'évanouissement sans l'éradiquer complètement. Ainsi, le LSTM reste limité par la profondeur de sa mémoire. Le *Transformer* utilise la notion d'attention qui met l'accent sur la relation entre les éléments de l'entrée. Cette notion résout le problème de l'évanouissement du gradient mais génère en contre coût une grande complexité computationnelle. Le N-BEATS fait un compromis entre le LSTM et le *Transformer*. Il est moins limité que le LSTM, d'où une meilleure précision, mais moins précis que le *Transformer*. Cette caractéristique se traduit par un moindre besoin en calcul, d'où un temps d'exécution dérisoire comparé au *Transformer*. La dernière étape de ce travail consiste à appliquer la prédiction par apprentissage profond au modèle RCSF-RE proposé et comparer les performances obtenues par le modèle du réseau entre une simulation sans prédiction et une simulation avec prédiction par apprentissage profond.

2.4. Contributions

Cette étude propose et évalue des solutions pour améliorer la gestion de l'énergie dans les réseaux de capteurs sans fil à récolte d'énergie en étudiant l'effet de la prédiction des niveaux d'énergie des prochains nœuds avant la transmission de données. Cette prédiction évite la perte de paquets et la mauvaise consommation de l'énergie résultante des retransmissions. Cette étude apporte une nouvelle approche à la prédiction d'énergie dans les réseaux de capteurs sans fil à récolte d'énergie en utilisant des algorithmes issus de l'apprentissage profond. Ces algorithmes sont, le modèle LSTM (Long Short-Term Memory), le modèle *Transformer* et le modèle N-BEATS (Neural Basis Expansion Analysis For Time Series). Nous avons évalué et comparé leurs performances de prédiction aux performances des modèles utilisés traditionnellement pour les RCSF-RE. Nous avons également évalué l'impact de ces algorithmes sur les performances d'un RCSF-RE. Les performances élevées de ces algorithmes de prédiction en matière de précision pourraient grandement améliorer la stratégie d'allocation d'énergie et du routage basé sur le niveau d'énergie du prochain nœud et permettre une économie d'énergie plus conséquente que celle obtenue par d'anciens modèles de prédiction.

CHAPITRE III

L'ÉTAT DE L'ART DE LA PRÉDICTION DANS LES RCSF-RE

Ce chapitre présente l'état de l'art des techniques utilisées pour la prédiction dans les RCSF-RE. La grande majorité de la littérature concernant ce sujet d'étude aborde ces modèles de prédiction par rapport à leur performance en précision des prédictions ainsi que de leurs besoins en calcul et mémoire. Peu d'articles abordent l'effet de cette prédiction sur les performances des RCSF-RE. Cet état de l'art comporte quelques exemples de modèles de prédiction que nous avons sélectionné afin de présenter les différentes catégories des modèles existants. Ces modèles peuvent être classés en trois catégories : stochastiques, statistiques et ceux issus de l'apprentissage automatique (Mughal *et al*, 2017) (Ghuman *et al*, 2015).

3.1. Modèles stochastiques

Les modèles stochastiques incorporent plusieurs types de processus stochastique pour modéliser des systèmes et des phénomènes qui semblent varier de manière aléatoire. Au début des années 2000, la plupart des modèles stochastiques dédiés à la prédiction de l'énergie solaire utilisaient une chaîne de Markov. Dans (Shamshad *et al*, 2005) un modèle de Markov du premier et second ordre a été utilisé pour générer des séries chronologiques représentant la vitesse du vent. Les modèles suivants sont également des modèles de la chaîne de Markov, avec des améliorations significatives ou avec un ordre plus élevé.

3.1.1. Modèle unifié à deux états

Un modèle de chaîne de Markov à deux états (actif et passif) a été présenté dans (Seyedi et Sikdar, 2008) considérant l'état actif et inactif des capteurs d'un réseau de capteurs sans fil. Dans cet article, le modèle considère à la fois l'état du processus de récupération d'énergie, la quantité d'énergie stockée dans un nœud et le trafic des nœuds pour déterminer l'état du nœud. En considérant un modèle de trafic simple où un seul événement se produit dans chaque intervalle de temps avec une probabilité P , les auteurs présentent quatre cas différents pour chaque tranche de temps :

- Si le nœud est à l'état inactif et qu'un événement se produit, le niveau d'énergie dans le nœud diminuera, sauf si le nœud est déjà à court d'énergie.
- Si l'appareil est dans l'état inactif et qu'aucun événement ne se produit, le niveau d'énergie dans le nœud ne changera pas.
- Si l'appareil est à l'état actif et qu'un événement se produit, le niveau d'énergie dans le nœud ne changera pas.
- Si l'appareil est à l'état actif et qu'aucun événement ne se produit, le niveau d'énergie dans le nœud augmentera, à moins qu'il n'ait atteint son maximum, lorsque la batterie est pleine.

Le modèle fait face au problème de prédiction non pas en estimant la quantité d'énergie qui sera disponible, mais en estimant la probabilité qu'un événement, tel que la transmission et la captation, échoue du fait que le nœud est en déficit d'énergie. Les résultats obtenus démontrent la relation entre les paramètres du système tel que l'énergie récoltée moyenne, le taux de trafic moyen (ratio entre les périodes d'activité et d'inactivité) et la capacité maximale de la batterie et aident à définir les exigences des nœuds à énergie renouvelable dans les réseaux de capteurs sans fil. Dans (Susu et al, 2008) une étude similaire basée également sur la modélisation du réseau par une chaîne de Markov, met en évidence l'importance du choix de la source d'énergie, la

capacité de la batterie et le ratio entre périodes d'activité et d'inactivité des nœuds sur les performances du réseau.

3.1.2. Modèle Maker

Ventura et Chowdhury (2011) présentent le modèle Maker. C'est un modèle de la chaîne de Markov pour les nœuds à énergie renouvelable à sources multiples dans les réseaux de capteurs corporels sans fil. Ce sont des réseaux où le nœud possède la capacité de récolter de l'énergie sur plusieurs cartes, de la même source ou de sources différentes. Le modèle Maker prend en compte à la fois le nombre de cartes de récolte attachées au nœud et la quantité d'énergie restante de la batterie pour déterminer l'état du nœud. Il permet une prédiction détaillée de la probabilité qu'un nœud ne parvienne pas à détecter un événement en raison d'un manque d'énergie. Les auteurs comparent d'abord la probabilité de perte d'événement dans le cas de deux cartes de récolte, en faisant varier le temps de récolte nécessaire pour avoir une quantité d'énergie suffisante à un événement. Une autre simulation compare également la probabilité de perte en faisant varier la quantité d'énergie résiduelle dans la batterie à l'intervalle de temps actuel. Ce modèle met en évidence les exigences pour les réseaux de capteurs avec de nombreuses cartes de récolte d'énergie ambiante, telles que la capacité de la batterie et la gestion des sources dans le cas de cartes de récolte multiples.

3.1.3. Modèle ASIM (Accurate Solar Irradiance Prediction Model)

En 2015, les auteurs de (Ghuman et al, 2015) présentent le modèle ASIM qui incorpore des chaînes de Markov d'ordre élevé, au-delà du deuxième ordre, pour prédire les séries chronologiques d'irradiance solaire à utiliser pour l'allocation d'énergie dans des réseaux de capteurs sans fil. Cet article montre que le modèle ASIM est capable de prédire la valeur de l'irradiance solaire avec une précision raisonnable. Il démontre également que la précision du modèle augmente avec une augmentation de l'ordre de la chaîne de Markov jusqu'au 10^{ème} ordre. Une augmentation au-delà du 10^{ème} ordre a

un impact nul sur la précision de la prédiction mais fait accroître considérablement la complexité de calcul.

En 2017, Mughal *et al* effectuent une comparaison entre le modèle ASIM et des modèles statistiques que nous présentons dans la prochaine section (WCMA, IPro-Energy et Pro-Energy). Il a été observé que le modèle ASIM donne des meilleures performances ces modèles en termes de temps d'exécution minimum. Cela indique que le modèle ASIM a des besoins computationnels moins élevés que d'autres méthodes couramment utilisées. Cette comparaison est présentée après la présentation des modèles WCMA et Pro-Energy en Section 3.2.4.

3.2. Modèles statistiques

Les modèles statistiques utilisent des techniques telles que la moyenne, la variance, la régression et la moyenne mobile. De nombreux travaux de recherche ont étudié l'application de ces modèles aux réseaux de capteurs sans fil à récolte d'énergie. Les quelques modèles suivants sont les modèles statistiques les plus cités dans la littérature.

3.2.1. Modèle EWMA (Exponentially Weighted Moving Average)

Paru en 1961(Cox, 1961), cet algorithme est utilisé pour prédire l'énergie solaire. La méthode repose sur l'hypothèse selon laquelle le schéma énergétique des jours les plus similaires reste inchangé sur des petits intervalles de temps. Cette considération augmente la précision de la prédiction dans une variété de conditions météorologiques telles que pluvieux, ensoleillés ou mélangés. Cependant, plus les changements météorologiques seront brusques, plus l'algorithme perdra de son efficacité. Les auteurs de (Koşunalp, 2016) utilisent cet algorithme pour la prédiction d'énergie solaire dans un réseau de capteurs sans fil. La journée de 24 heures est divisée en intervalles de temps de longueur égale. L'énergie dans chaque intervalle de temps est prédite sur la base d'une règle exponentiellement donnée par :

$$E(d, n) = a E(d - 1, n) + (1 - a)R(d - 1, n), \quad (3.1)$$

où E est l'énergie estimée, R est l'énergie réellement récoltée, d représente le jour présent, n représente l'intervalle de temps et a est le coefficient de pondération. Ce coefficient est déterminé expérimentalement en le faisant varier tout en mesurant les performances de l'algorithme sur des données réelles. Une valeur élevée de α correspond à donner moins d'importance à la dernière énergie récoltée.

La prédiction se fait en additionnant l'énergie récoltée et l'énergie estimée au jour précédent avec une pondération visant à accorder plus ou moins d'importance à l'une des deux quantités énergie : l'estimée ou la récoltée. Comme mentionné précédemment, plus les changements météorologiques seront brusques plus l'algorithme sera moins précis dans ses prédictions. Bien que l'algorithme ait plusieurs avantages notamment d'un point de vue computationnel et de mémoire, il reste néanmoins tributaire d'une pondération peu adaptative et nécessitant une mise au point manuelle. Cela est très désavantageux pour une utilisation embarquée en un réseau de capteurs sans fil à récolte d'énergie.

3.2.2. Modèle WCMA (Weather-Conditioned Moving Average)

Pour effectuer une prédiction à l'intervalle de temps suivant, le WCMA prend en compte la quantité d'énergie recueillie à l'intervalle de temps actuel et la moyenne des quantités d'énergie capturées de plusieurs jours passés du même intervalle de temps que l'on veut prédire (Koşunalp, 2016a). Un nouveau facteur de pondération GAP est ajouté pour incorporer à l'équation les changements météorologiques.

$$E(d, n + 1) = \alpha E(d, n) + (1 - \alpha)M(d, n + 1)GAP, \quad (3.2)$$

où M est la valeur moyenne des énergies capturées sur plusieurs jours. Elle est calculée ainsi :

$$M(d, n + 1) = \frac{\sum_{i=1}^D E(i, n + 1)}{D}, \quad (3.3)$$

où GAP est un nouveau facteur de pondération introduit afin de refléter les conditions météorologiques actuelles. Il est calculé ainsi :

$$GAP = \frac{V P}{\sum P}, \quad (3.4)$$

où $V = [V_1, V_2, \dots, V_i]$ est un vecteur dont les éléments sont les échantillons précédents du même jour. Chaque élément représente le rapport de l'énergie récoltée à la valeur moyenne. Par conséquent, une valeur inférieure à 1 signifie que l'énergie récoltée est inférieure à la moyenne :

$$V_i = \frac{E(d, n-k+i)}{M(d, n-k+i)}, \quad k \text{ étant le nombre d'échantillons utilisés} \quad (3.5)$$

où $P = [P_1, P_2, \dots, P_i]$ est un vecteur dont les éléments sont une pondération des éléments de V en fonction de leur distance par rapport à l'échantillon réel. Ils donnent plus d'importance aux échantillons proches et moins d'importance aux échantillons éloignés,

$$P_i = \frac{i}{k}. \quad (3.6)$$

Compte tenu de la mémoire limitée dans les nœuds d'un réseau de capteurs, la taille de la matrice contenant les échantillons de plusieurs jours doit être soigneusement sélectionnée. Ainsi que la valeur de k , qui est le nombre d'échantillons passés à considérer, doit être soigneusement ajustée. Il doit être suffisamment grand pour observer les conditions météorologiques actuelles, mais également suffisamment petit pour ne pas prendre en compte certains échantillons qui n'ont aucun impact sur les conditions actuelles, comme les valeurs nocturnes. Le WCMA vient combler les lacunes du EWMA dans l'incorporation des conditions météorologiques, mais augmente considérablement le besoin computationnel de la prédiction, ainsi qu'un besoin en mémoire conséquent proportionnel au choix de k et de la taille de la matrice. Ces deux paramètres sont calculés expérimentalement.

3.2.3. Modèle ASEA (*Accurate Solar Energy Allocation*)

Basé sur le modèle EWMA, il introduit un nouveau paramètre ψ dans l'équation (3.1) qui reflète les conditions solaires actuelles (Koşunalp, 2016b). L'équation modifiée peut être donnée comme suit:

$$\hat{E}(d, n) = E(d, n) \psi \quad \text{Où } \psi = \frac{H(d, n-1)}{E(d, n-1)}, \quad (3.7)$$

où ψ représente le rapport entre la quantité réelle d'énergie récoltée et l'énergie estimée par EWMA sur la base de l'intervalle de temps précédent. La valeur de ψ est calculée au début de chaque intervalle de temps. Le modèle ASEA ne prend en compte que l'intervalle de temps précédent, ce qui pourrait introduire des erreurs de prévision importantes pour des conditions météorologiques variables à court terme. Un changement climatique temporaire dans l'intervalle de temps actuel entraînerait des prévisions inexactes pour l'intervalle de temps suivant.

Les auteurs de (Koşunalp, 2016) ont effectué des simulations de prédiction en utilisant le WCMA, le EWMA et le ASEA pour diverses périodes de l'année reflétant ainsi les cas où les conditions météorologiques sont stables en juillet et changeantes en avril. Les résultats obtenus montrent l'effet significatif du coefficient de pondération a sur la précision de la prédiction. Pour $0 < a \leq 0,4$, lorsque les conditions météorologiques sont changeantes, en avril par exemple, le WCMA, grâce au GAP, performe mieux que le EWMA et le ASEA. Cependant lorsqu'on augmente la valeur de a , $0,4 < a \leq 0,9$, le EWMA et le ASEA démontrent une plus grande précision. Pour des conditions météorologiques stables, en juillet, les modèles de prédiction ont approximativement les mêmes performances lorsque $0,8 < a \leq 0,9$. En conclusion, le WCMA démontre de meilleures performances que le ASEA et le EWMA, que les conditions météorologiques soient stables ou changeantes, à condition que le coefficient de pondération reste inférieur à 0,2.

3.2.4. Modèle Pro-Energy (Profile Energy)

Ce modèle a la particularité de diviser une journée en 48 intervalles de temps de 30 minutes et d'enregistrer en sa mémoire différents profils énergétiques représentant plusieurs types de jours, tel qu'ensoleillés, nuageux, pluvieux, etc. (Cammarano *et al*, 2012). Afin de prédire l'énergie future, le modèle doit déterminer parmi les modèles qu'il a en sa mémoire, lequel correspond le mieux à la journée à prédire. Ensuite, la valeur prédite est calculée en tenant compte de la valeur actuelle de l'énergie capturée et la valeur de l'instant futur dans le profil choisi. La prédiction se fait selon cette équation :

$$\hat{E}(n + 1) = \alpha E(n) + (1 - \alpha)E^d(n + 1), \quad (3.8)$$

où $E(n)$ est la valeur de l'énergie capturée à l'instant n , $E^d(n + 1)$ est la valeur de l'énergie à l'instant $n + 1$ du profil énergétique similaire au jour actuel et α est le coefficient de pondération. La sélection du profil le plus similaire au jour actuel se fait par le biais de la recherche du minimum de l'erreur moyenne absolue entre les valeurs d'énergie du jour actuel et celles des profils enregistrés. Le profil pour qui l'erreur est moindre sera sélectionné.

$$E^d = \min_{E^d \in P} \sum_{i=n-k}^n \frac{1}{k} |E(i) - E^d(i)|, \quad (3.9)$$

où P est une matrice de taille $(D \times N)$ contenant les profils enregistrés, D étant le nombre de jours, et N le nombre d'échantillons par jour, et k est le nombre d'échantillons enregistrés du jour actuel.

En 2013, dans l'article (Cammarano *et al*, 2013), les mêmes auteurs ont apporté une amélioration à leur modèle qui devint le Pro-Energy-VLT. L'amélioration consiste à remplacer la durée des intervalles de temps de 30 minutes par des intervalles variables (30, 60 et 90 minutes) calculés par un algorithme. Toutefois, malgré sa complexité accrue et ses intervalles de temps variable, il ne présente pas d'amélioration

significative de l'erreur de prédiction. Pro-Energy-VLT a signalé une erreur de prédiction jusqu'à 12,33% inférieure à l'erreur rapportée par Pro-Energy.

Les auteurs de (Mughal *et al*, 2017) proposent une autre amélioration du Pro-Energy, le IPro-Energy, pour améliorer la précision de la prédiction en modifiant la technique de mise en œuvre. Le modèle IPro-Energy a deux caractéristiques distinctives. Premièrement, il ne classe pas les jours typiques en fonction de leurs caractéristiques. Contrairement à Pro-Energy, il ne stocke pas les données d'une journée en se basant sur le fait qu'elle est purement ensoleillée, nuageuse, pluvieuse ou mixte. Pour compenser les variations météorologiques il utilise la technique du profil pondéré (WP), également utilisée dans (Cammarano *et al*, 2012). Deuxièmement, il minimise le nombre de jours combinés les plus similaires en ne considérant que les deux jours enregistrés précédemment les plus similaires. La combinaison d'un plus grand nombre de jours pourrait avoir un impact en augmentant l'erreur de prédiction. Un procédé de mise à jour actualise les entrées de la matrice à la fin de la journée en supprimant les plus anciennes entrées et en les remplaçant par celles du jour le plus récent. D'après les auteurs, les profils les plus similaires au jour actuel se trouvent dans les 20 à 30 derniers jours. Une étude de simulation est menée pour comparer les performances du modèle IPro-Energy comparées aux performances à l'ASIM, Pro-Energy et WCMA.

Leurs résultats indiquent que le modèle IPro-Energy surpasse les autres modèles en termes de précision de prédiction de 78% pour les prévisions à court terme et de 50% pour les prévisions à moyen terme. Pour les prévisions à long terme, sa précision de prédiction est comparable au modèle Pro-Energy mais surpasse les autres modèles de 64% (Mughal *et al*, 2017). De plus, il a été observé que le modèle ASIM domine WCMA, IPro-Energy et Pro-Energy en termes de temps d'exécution minimum. Ceci indique que les modèles basés sur Pro-Energy ont des besoins computationnels très élevés, en plus du besoin conséquent en mémoire pour le stockage des profils énergétiques des jours. Bien que le modèle IPro-Energy tente de soulager ce besoin en mémoire, il augmente le besoin en calculs.

3.2.5. Filtre NLMS (Normalized Least Mean Square)

C'est un algorithme adaptatif qui minimise l'erreur de prédiction en adaptant les coefficients de pondération à chaque pas de temps. La prédiction se fait ainsi.

$$\hat{e}(n + 1) = H(n) E(n), \quad (3.10)$$

où $\hat{e}(n + 1)$ est l'énergie à prédire, $E(n)$ est le vecteur dont les éléments sont les valeurs d'énergie capturées dans le passé et $H(n)$ est le vecteur des coefficients des filtres de prédiction mises à jour à l'instant n . L'erreur de prédiction est ensuite calculée en comparant la valeur prédite à la valeur réelle $e(n + 1)$

$$err(n + 1) = e(n + 1) - \hat{e}(n + 1). \quad (3.11)$$

La partie adaptative de l'algorithme est représentée à cette étape. En effet, après prédiction et calcul de l'erreur de prédiction, le filtre ajuste son vecteur de coefficients de pondération et met à jour ses composants avec l'opération suivante

$$H(n + 1) = H(n) + \mu \frac{err(n+1)E(n)}{|E(n)|^2}, \quad (3.12)$$

où μ est le pas d'adaptation de l'algorithme.

Par son caractère adaptatif, le filtre NLMS présente l'avantage que le choix du coefficient n'est plus un problème. Cependant, le choix de l'ordre du vecteur $E(n)$ et du pas d'adaptation μ reste à faire. Il implique à faire un compromis entre rapidité de convergence et fluctuation de l'algorithme.

Les résultats de simulation de l'article démontrent que le modèle NLMS est plus performant que le modèle EWMA mais moins performant que le modèle WCMA. Cependant le modèle NLMS est moins gourmand en mémoire et en calcul, ce qui est très avantageux pour un système embarqué.

3.2.6. Modèle WFBP (weather forecast based prediction)

Les auteurs de (Li *et al*, 2014) avancent l'hypothèse selon laquelle une prédiction basée sur des prévisions météorologiques issues d'organismes spécialisés serait plus performante que les prédictions faites par les modèles axés sur les valeurs d'énergie passées. Ceci contre-argumente les modèles présentés précédemment. La prédiction de l'énergie solaire se fait ainsi,

$$Power_{current} = Maxpower (1 - CloudIndex), \quad (3.13)$$

où *CloudyIndex* représente le pourcentage de nuages signalés par les prévisions météorologiques et *MaxPower* représente la puissance solaire maximale estimée à un moment donné de la journée et de l'année.

$$MaxPower = a (t + b)^2 + c, \quad (3.14)$$

où *a*, *b* et *c* sont des paramètres relatifs à la position du soleil par rapport à l'emplacement de la prédiction. Les auteurs présentent des résultats de simulation qui comparent les performances du WFBP aux performances du WCMA et du EWMA.

Les auteurs affirment qu'un réseau de capteurs sans fil est 35 % plus performant avec une prédiction faite à l'aide du WFBP qu'un réseau de capteurs utilisant le EWMA ou le WCMA. Les performances sont représentées par le nombre de tâches accomplies par le réseau. En plus du besoin en mémoire, la dépendance de ce modèle à une actualisation constante des conditions météorologiques implique une communication additionnelle, ce qui se traduit en consommation d'énergie.

3.2.7. Modèle SEPAD (Solar Energy Prediction using Additive Decomposition)

Les auteurs de (Hassan et Bermak, 2012) présentent ce modèle comme étant destiné à la prédiction d'énergie solaire. Le modèle peut être résumé comme suit :

$$E_{est}(d, n) = E_{ce}(d, n) + E_{se}(d, n) + E_{de}(d, n), \quad (3.15)$$

où $E_{est}(d, n)$ est la prédiction d'énergie estimée à l'instant n du jour d , $E_{ce}(d, n)$ est un terme qui représente le cycle diurne du soleil à l'instant n du jour d . Ce terme se calcule ainsi :

$$E_{ce}(d, n) = \alpha E(d - 1, n) + (1 - \alpha) E_{ce}(d - 1, n). \quad (3.16)$$

Le terme $E(d - 1, n)$ représente la valeur d'énergie réelle capturée au jour $d - 1$ à l'instant n et α un coefficient de pondération. $E_{se}(d, n)$ représente la variation saisonnière à l'instant n du jour d et se calcule en se basant sur la différence pondérée, β , entre les valeurs capturées aux jours précédents ($d - 1, d - 2$) au même instant n . Dans ce cas, la variation saisonnière peut être donnée par :

$$E_{se}(d, n) = \beta (E(d - 1, n) - E(d - 2, n)) \quad (3.17) \\ + (1 - \beta)(E(d - 2, n) - E(d - 3, n)),$$

Le terme $E_{de}(d, n)$ caractérise les changements des conditions météorologiques qui peuvent exister dans le jour courant. Il est donné comme suit :

$$E_{de}(d, n) = \gamma [E(d, n - 1) - (E_{ce}(d, n - 1) + E_{se}(d, n - 1))] + \quad (3.18) \\ (1 - \gamma)[E(d, n - 2) - (E_{ce}(d, n - 2) + E_{se}(d, n - 2))],$$

où γ est un coefficient de pondération.

Les auteurs ont effectué des simulations qui démontrent que le modèle SEPAD a de meilleures performances dans des conditions météorologiques changeantes. Dans un climat où les changements météorologiques sont moins brusques, les performances du modèle SEPAD sont très proches de celle du modèle WCMA et du modèle EWMA. Les faiblesses de ce modèle peuvent se résumer dans le fait que tous les coefficients de pondération doivent être fixés manuellement ainsi qu'un fort besoin en mémoire de stockage.

3.2.8. Modèle RWMA (Real Forecast Weather Moving Average)

C'est un modèle de prédiction de l'énergie solaire fondée sur le WCMA (Ren *et al*, 2018). En y introduisant la notion du temps réel, ce modèle remédie au défaut des EWMA et WCMA en s'adaptant mieux aux changements climatiques. Le modèle peut défini comme suit :

$$A(d + 1, i) = \begin{cases} (\bar{E}(d + 1, i)) \cdot (1 + GAP_x(i)) & |WCS| \geq \omega_t \\ (\bar{E}(d + 1, i)) & |WCS| < \omega_t \end{cases} \quad (3.19)$$

où $A(d + 1, i)$ est la quantité d'énergie solaire à prédire, $\bar{E}(d + 1, i)$ est la quantité d'énergie prédite par le WCMA, ω_t est le seuil d'occurrence de changements brusques de temps et WCS (Weather-Conditional Selective) est utilisé pour refléter les changements de temps pour le jour prévu et le jour précédent. Il est calculé ainsi,

$$WCS = \sum_{t=t_1}^{t_2} W(d + 1, i) - \sum_{t=t_1}^{t_2} W(d, i), \quad (3.20)$$

où t_1 et t_2 représentent le temps et $W(d, i)$ représente les conditions météorologiques du jour d à l'intervalle de temps i .

On distingue deux cas :

- $WCS > 0$ lorsque la quantité d'énergie solaire augmente considérablement lorsque le temps passe de mauvais à bon
- $WCS < 0$ lorsque la quantité d'énergie solaire a considérablement diminué lorsque le temps passe de bon à mauvais

En raison des conditions météorologiques changeantes, le calcul du facteur d'ajustement météorologique GAP doit être envisagé sous de nombreux aspects. L'idée apportée par cette méthode est de distinguer deux facteurs d'ajustement, l'un pour les changements météorologiques drastiques, GAP_x , l'autre pour les changements non significatifs, GAP_u .

$$GAP_x = \begin{cases} \frac{WC(i)}{a} & WCS > 0 \\ \frac{WC(i)}{b} & WCS < 0 \end{cases}, \quad (3.21)$$

Soit $WC(i)$ qui représente le changement météorologique dans les deux jours avant et après l'instant i .

$$WC(i) = \frac{WF \cdot P}{\sum P}, \quad (3.22)$$

où $P = [P_1, P_2, \dots, P_i]$ sont les coefficients de pondération tels que pour le WCMA. WF est une matrice $(1 \times k)$ utilisée pour stocker les changements météorologiques de l'intervalle de temps à prédire et de l'intervalle de temps précédent. Elle est définie comme suit :

$$WF = [Wf_1, Wf_2, \dots, Wf_k],$$

$$Wf_i = \frac{W(d+1, i+j-k) - W(d, i+j-k)}{W(d, i+j-k)}. \quad (3.23)$$

L'algorithme peut être décrit ainsi

$$WCS = \sum_{t=t_1}^{t_2} W(d+1, i) - \sum_{t=t_1}^{t_2} W(d, i)$$

Si $|WCS| < \omega_t$ **alors**

$$A(d+1, i) = (\bar{E}(d+1, i))$$

Sinon

$$WF = [Wf_1, Wf_2, \dots, Wf_k]$$

$$Wf_i = \frac{W(d+1, i+j-k) - W(d, i+j-k)}{W(d, i+j-k)}$$

$$WC(i) = \frac{WF \cdot P}{\sum P}$$

Si $WCS > 0$ alors

$$GAP_x = \frac{WC(i)}{a}$$

Sinon

$$GAP_x = \frac{WC(i)}{b}$$

$$A(d + 1, i) = (\bar{E}(d + 1, i)) \cdot (1 + GAP_x(i))$$

Les comparaisons faites par les auteurs démontrent les performances accrues de ce modèle à temps réel. On voit clairement que le RWMA surpasse le WCMA et le EWMA en matière de précision. Cependant, la paramétrisation des coefficients de pondération reste à faire expérimentalement. La présence de la matrice WF qui stock les changements météorologiques vient alourdir le besoin en mémoire et la complexité de l'algorithme vient s'ajouter au besoin computationnel initial du WCMA.

3.2.9. Modèle WEP (Wind Energy Predictor)

C'est un modèle de prédiction de l'énergie éolienne pour les réseaux de capteurs sans fil (Kosunalp, 2017). Contrairement à l'énergie solaire, l'énergie éolienne peut être générée à tout moment tant qu'il y a du vent. L'estimation de l'énergie éolienne est généralement une tâche plus difficile, car la vitesse moyenne du vent à un endroit dépend de nombreux facteurs environnementaux, tel que les arbres, les bâtiments, etc. Le modèle WEP se concentre sur les dernières valeurs d'énergies capturées en calculant une moyenne de l'énergie capturée sur N intervalles de temps précédents, en accordant plus de poids à l'intervalle de temps le plus récent, ainsi que sur l'erreur de prédiction entre les quantités d'énergie capturées et les quantités d'énergie prédites aux intervalles de temps précédents.

$$\hat{E} = \frac{\sum_{i=1}^N H(i) \times i}{\sum i} + \frac{\sum_{i=1}^N H(i) - P(i)}{N}, \quad (3.24)$$

où $P(i)$ est la valeur d'énergie prédite à l'intervalle de temps i , $H(i)$ est la valeur d'énergie capturée à l'intervalle de temps i et N est le nombre d'intervalles de temps.

Les résultats obtenus dans l'article comparent les performances du WEP à celles du Pro-Energy et du EWMA. Ils montrent clairement que le WEP les surpasse en matière de précision. Le WEP réduit le taux d'erreur de prédiction à 8,6%, contre 55,9% pour le EWMA et 17,9% pour le Pro-Energy. Le WEP n'est pas tributaire du cycle diurne et nocturne, tel que sont les modèles spécifiques à l'énergie solaire, et de ce fait il n'a pas besoin de considérer les jours précédents. Ceci se traduit par une diminution du besoin en mémoire, ce qui est très avantageux pour ces systèmes embarqués

3.2.10. Filtre de Kalman

Il existe aussi d'autres approches telles que l'autorégression, l'autorégression à moyenne mobile et la régression linéaire. Ils ont généralement une bonne précision dans les prédictions de l'énergie solaire (Ji *et al*, 2009). Un processus autorégressif (AR) est un processus où l'on écrit une observation au temps t comme une combinaison linéaire des observations passées plus un certain bruit blanc.

$$E(n) = \sum_{i=1}^P a_i E(n-1) + w(n), \quad (3.25)$$

où $w(n) = N(0, \sigma_w^2)$ est un bruit blanc gaussien et a_i constitue les coefficients de pondération du modèle.

Le problème de prédiction d'énergie capturée devient alors un problème d'estimation des coefficients a_i . Il existe plusieurs méthodes dédiées à l'estimation des coefficients et leurs mises à jour. Saidi *et al* (2016) utilisent le Filtre de Kalman. Pour caractériser l'évolution temporelle des coefficients du modèle AR, ils utilisent le modèle Markovien suivant

$$a_i(n) = a_i(n-1) + v_i(n), \quad i = 1, \dots, p \quad (3.26)$$

où $v_i(n)$ est un bruit blanc Gaussien de distribution $N(0, \sigma^2)$. Le problème d'estimation des coefficients $a_i(n)$ est décrit à travers la représentation d'état suivante

$$A_p(n) = I_p A_p(n-1) + V(n) : \text{Équation de transition d'état} \quad (3.27)$$

$$E(n) = B(n)^T A_p(n) + \omega(n) : \text{Équation observation} \quad (3.28)$$

où $A_p(n) = [a_1(n), \dots, a_p(n)]^T$ est le vecteur d'état, $V(n) = [v_1(n), \dots, v_p(n)]^T$ est le bruit d'état, $B(n) = [E(n-1), \dots, E(n-p)]^T$ est le vecteur contenant les mesures d'énergie précédentes et $\omega(n)$ est le bruit blanc gaussien.

Le filtrage de Kalman se fait en deux étapes. La première étape est celle de la prédiction et la deuxième étape est celle de mise à jour.

- L'étape de prédiction :

Le modèle fait l'estimation des coefficients. Cette estimation est basée sur les valeurs de l'énergie $[E(0), E(1), \dots, E(n)]$ et correspond donc aux coefficients prédits selon

$$\hat{A}_p(n+1 | n) = I_p \hat{A}_p(n | n). \quad (3.29)$$

La prédiction de l'énergie à l'instant $n+1$, $\hat{E}(n+1)$, se fait en générant l'observation prédite selon :

$$\hat{E}(n+1) = B(n+1) \hat{A}_p(n+1 | n). \quad (3.30)$$

- L'étape de mise à jour :

À l'intervalle de temps suivant, $n+1$, après avoir capturé la valeur d'énergie réelle, le modèle met à jour les coefficients estimés selon :

$$\hat{A}_p(n+1 | n+1) = \hat{A}_p(n+1 | n) + K(n) (E(n+1) - \hat{E}(n+1)), \quad (3.31)$$

où $K(n)$ le gain du filtre de Kalman et est calculé par

$$K(n) = \hat{P}(n+1 | n) B(n)^T \hat{F}(n+1 | n)^{-1}, \quad (3.32)$$

où $\hat{P}(n+1 | n)$ est la matrice de covariance de l'erreur de prédiction

$$\hat{P}(n + 1 | n) = I_p \hat{P}(n | n) I_p^{-1} + \sigma_v^2 I_p. \quad (3.33)$$

$\hat{F}(n + 1 | n)$ représente la covariance de l'erreur de prédiction de cette observation prédite

$$\hat{F}(n + 1 | n) = B(n + 1) \hat{P}(n + 1 | n) B(n + 1)^T + \sigma_w^2. \quad (3.34)$$

Finalement la mise à jour de la matrice de covariance de l'erreur de mise à jour qui sera utilisée pour calculer $K(n + 1)$ se détermine ainsi

$$\hat{P}(n + 1 | n + 1) = \left(I_p - K(n)B(n + 1) \right) \hat{P}(n + 1 | n). \quad (3.35)$$

Les auteurs ont effectué des simulations comparant la prédiction faite par le filtre de Kalman et des prédictions faites par EWMA et NLMS. Les résultats démontrent que le filtre de Kalman présente de meilleures performances que le EWMA et le NLMS en matière d'erreur absolue moyenne. La prédiction par le filtre de Kalman présente l'avantage d'être adaptative et de surmonter le problème des coefficients de pondération qui constituent les problèmes majeurs des prédicteurs existants.

3.3. Modèles basés sur l'apprentissage automatique

Les modèles basés sur l'apprentissage automatique sont catégorisés selon trois approches : l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage par renforcement. Les modèles suivants sont quelques exemples de modèles de l'apprentissage automatique utilisés pour faire de la prédiction dans des réseaux de capteurs sans fil à récolte d'énergie :

3.3.1. Modèle QL-SEP (Q-Learning For Solar Energy Prediction)

L'auteur de (Koşunalp, 2016) introduit une approche de la prédiction de l'énergie solaire basée sur l'apprentissage par renforcement qui exploite les informations historiques de la capture d'énergie des derniers jours et les conditions météorologiques les plus récentes à l'heure actuelle. QL-SEP est basé sur les prédictions du EWMA, en

mettant à jour l'équation (3.1) avec un nouveau paramètre appelé Le Rapport Quotidien (en anglais daily report ou DR),

$$E_{QL-SEP} = E_{EWMA} \cdot (1 + DR), \quad (3.36)$$

Le DR représente la tendance de la disponibilité d'énergie solaire actuelle, en se basant sur le comportement de l'énergie solaire dans les intervalles de temps les plus récents. Il peut être considéré comme la moyenne des rapports d'augmentation ou de diminution de l'énergie dans les intervalles de temps précédents. Par exemple, s'il y a une augmentation de 20% en moyenne dans les intervalles de temps précédents, le DR a une valeur de 0,2.

Lors de la prédiction de l'énergie dans un intervalle de temps particulier, la précision de la prédiction dans les intervalles de temps précédents est une information importante. Chaque intervalle de temps dans QL-SEP possède un niveau de précision de prédiction qui représente sa fiabilité de prédiction. Cela conduit à combiner les rapports d'augmentation ou de diminution et la fiabilité de la prédiction afin de doter de manière significative les prédictions d'une grande fiabilité. Le DR se calcule selon :

$$DR = \frac{\sum_{i=1}^n P_e(i)R(i).i}{\sum i}, \quad (3.37)$$

où $P_e(i)$ représente l'erreur de prédiction, $R(i)$ est le niveau de fiabilité et i est un indice croissant utilisé pour la pondération. Le DR donne plus d'importance aux éléments les plus récents. Il est évident que le choix de la fiabilité R est un défi fondamental. Par conséquent, l'exploitation de l'expérience à long terme des prédictions fournit un niveau suffisamment robuste de R . Cela se fait par le moyen de l'apprentissage par renforcement. Le Q-learning est un moyen efficace d'explorer le comportement actuel d'une action à partir de l'expérience déjà acquise. Il permet de déterminer une solution optimale à l'aide d'une fonction de récompense représentée par une valeur numérique. La solution indique la désirabilité de l'action sous la forme de valeurs numériques, appelées valeur Q qui est calculée ainsi :

$$Q_{t+1}(s) = Q_t(s) + \gamma(r - Q_t(s)), \quad (3.38)$$

où s indique l'intervalle de temps considéré, γ est le taux d'apprentissage, similaire à celui du facteur de pondération α . Le taux d'apprentissage contrôle la vitesse d'augmentation ou de diminution de la valeur Q . r est la fonction de récompense actuelle. Il prend une valeur de +1 pour une rétroaction positive et -1 pour une rétroaction négative. Une rétroaction positive consécutive augmentera la valeur Q pour converger vers une valeur très proche de +1, tandis qu'une séquence de rétroaction négative réduit la valeur Q associée à -1. QL-SEP utilise le Q-learning dans lequel chaque intervalle de temps est initié avec une valeur Q qui lui est propre pour indiquer son niveau de fiabilité. La valeur Q de chaque intervalle de temps est initialisée à +1 au démarrage, car les intervalles de temps n'ont eu aucune action jusqu'à présent et ils ont la même fiabilité. L'étape suivante consiste à définir les conditions de mise à jour de la valeur Q , positive ou négative. La valeur Q d'un intervalle de temps est mise à jour à la fin de l'intervalle de temps en association avec le taux d'erreur de prédiction global (en anglais overall prediction error rate ou OPER) dans 24 intervalles de temps. Un taux d'erreur de prédiction dans un intervalle de temps (prediction error rate ou PER) est comparé à OPER. Si PER est inférieur à OPER, r prend une valeur positive (+1), sinon r prend une valeur négative (-1). Par conséquent, un PER supérieur à OPER est considéré comme une mauvaise prédiction.

Un autre paramètre important à définir est le taux d'apprentissage, qui est généralement fixé à une valeur constante, ce qui n'est pas une solution pratique. Les auteurs ont introduit une nouvelle modification de la valeur du taux d'apprentissage qui permet de réduire la valeur Q de manière plus agressive lorsque le PER est élevé. Dans cette stratégie, le taux d'apprentissage modifié est obtenu en multipliant le taux d'apprentissage initial par le PER, si r a pris la valeur négative. Le PER pour un seul intervalle de temps est calculé comme suit

$$PER = \left| \frac{H - P}{P} \right|, \quad (3.39)$$

où H est l'énergie capturée à l'intervalle de temps actuel et P est l'énergie prédite par le modèle QL-SEP. Finalement, la valeur de R pour un intervalle de temps dans l'équation (3.37) est affectée à la valeur Q de cet intervalle de temps. La prédiction se fait ainsi :

$$E_{QL-SEP} = E_{EWMA} \cdot \left(1 + \frac{\sum_{i=1}^n \left| \frac{H - P}{P} \right| \cdot Q(i) \cdot i}{\sum i} \right), \quad (3.40)$$

Les auteurs ont procédé à des simulations comparant leur modèle aux modèles déjà cités, le EWMA, le ASEA et le Pro-Energy. Les résultats montrent que le QL-SEP présente de meilleures performances en termes d'erreur de prédiction. Cependant, étant tributaire du EWMA, il vient d'accroître son besoin computationnel et en hérite ses inconvénients, notamment pour le coefficient de pondération a qui nécessite toujours une mise au point manuelle.

3.3.2. Réseaux ANN (Réseau de Neurones Artificiels)

Le réseau de neurones artificiels est une technique de l'apprentissage automatique. Il permet de modéliser des fonctions linéaires et non linéaires reliant une sortie souhaitée à l'ensemble des entrées. En analogie aux neurones biologiques, les réseaux de neurones artificiels se caractérisent par une interconnexion entre plusieurs éléments (neurones) en une architecture complexe représentant un lien mathématique appris par le réseau, par le biais de pondération w_i , entre des sorties et leurs entrées.

$$y = g \left(b + \sum_{n=1}^N w_n x_n \right),$$

où b est le biais, w_i sont les poids du réseau, N est le nombre d'entrées et g est la fonction d'activation qui introduit la non-linéarité.

Les différents types de réseaux de neurones, classification ou régression, se distinguent par la nature de leur fonction d'activation. Les principaux types sont

- Sigmoides $g(x) = \frac{1}{1+e^{-x}}$
- ReLU $g(x) = \max(0, x)$
- Softmax $g(x)_j = \frac{e^{x_j}}{\sum_{k=1}^K e^{x_k}}$, utilisée lorsqu'on veut obtenir une probabilité
- La tangente hyperbolique $g(x) = \tanh(x)$

Les modèles linéaires, sigmoïdaux, ReLU, softmax sont bien adaptés aux algorithmes d'apprentissage impliquant une rétropropagation du gradient, car leur fonction d'activation est différentiable ; ce sont les plus utilisés.

Les auteurs de (Al-Omary *et al*, 2019) présentent une application des réseaux de neurones artificiels pour la prédiction d'énergie récoltée dans les nœuds des réseaux de capteurs sans fil. Le réseau de neurones utilisé par les auteurs est un réseau de neurones à propagation avant. Ce sont des réseaux où chaque couche est en fonction de la précédente. La première couche effectue d'abord une opération affine sur les entrées x ,

$$z^{[1]} = w^{[1]}x + b^{[1]}, \quad (3.41)$$

Puis on calcule une fonction non-linéaire du résultat à l'aide d'une fonction d'activation,

$$a^{[1]} = g(z^{[1]}), \quad (3.42)$$

La $K_{i\text{ème}}$ couche s'écrit alors en fonction de la précédente comme suit :

$$a^{[k]} g(z^{[k]}) = g^{[k]}(w^{[k]}a^{[k-1]} + b^{[k]}), \quad (3.43)$$

et ainsi de suite jusqu'à la sortie l ,

$$\hat{y}(x, w, b) = g^{[l]}(w^{[l]}a^{[l-1]} + b^{[l]}). \quad (3.44)$$

Le processus de calcul est effectué de manière itérative pour minimiser la fonction de perte du réseau qui est décrite par la fonction de perte quadratique suivante :

$$L(w) = \frac{1}{2} \sum_{n=1}^m \|\hat{y}(x^m, w) - y^m\|^2, \quad (3.45)$$

où $\hat{y}(x^m, w)$ est la sortie estimée et y^m est la sortie réelle. Cette minimisation se fait par l'algorithme de la descente du gradient. D'abord, les poids w sont initialisés aléatoirement, ensuite le gradient de la fonction de perte par rapport aux poids du réseau est calculé comme suit :

$$\nabla L = \left\{ \frac{\partial L}{\partial W_{ji}^{[k]}} \right\}_{i,j,k}. \quad (3.46)$$

Pour un pas de descente $a > 0$, le poids est ajusté comme suit :

$$W_{ji}^{[k]} \rightarrow W_{ji}^{[k]} - a \frac{\partial L}{\partial W_{ji}^{[k]}} \quad (3.47)$$

Puis la deuxième étape est effectuée jusqu'à convergence. Pour calculer efficacement le gradient ∇L , l'algorithme de rétropropagation est utilisé. Cet algorithme part de l'erreur de prédiction et la repropage à l'envers dans le réseau vers les valeurs d'entrée pour calculer les dérivées par rapport à chaque poids.

Afin d'étudier la précision du réseau de neurones artificiels par rapport aux autres algorithmes de prédiction (EWMA, WCMA et Pro-Energy). Les auteurs de (Al-Omary *et al*, 2019) ont utilisé l'énergie réellement récoltée pour mettre en œuvre la prédiction dans les algorithmes de prédiction tandis que des données environnementales et l'irradiation solaire globale ont été utilisées pour l'algorithme ANN. Toutes ces données ont été obtenues pour la ville de Chemnitz en Allemagne sur une période de cinq ans à partir du centre de données climatiques. La prédiction est faite pour une semaine de données météorologique en été et une semaine de donnée météorologique en hiver.

Les moyennes des erreurs de prédiction ont été calculées à 0,50%, 0,40%, 0,29% et 0,03%, respectivement pour l'EWMA, la WCMA, Pro-Energy et ANN pendant une semaine d'été. Pour une semaine en hiver, des pourcentages de 0,32%, 0,22%, 0,20% et 0,02% ont été obtenus. Ainsi, ANN montre un comportement significativement plus précis. La paramétrisation automatique des coefficients de pondération offre un avantage majeur comparé aux autres méthodes. Une fois le modèle est entraîné et embarqué, il ne nécessite que très peu de données en entrée, dépendamment de la nature de son entraînement, ce qui amoindrit considérablement le besoin en mémoire. Cependant la complexité computationnelle demeure élevée.

3.3.3. Autres utilisations de l'apprentissage automatique dans les RCSF

Les auteurs de (Aram *et al*, 2014) utilisent un perceptron multicouche (en anglais multilayer perceptron ou MLP) pour décider de la taille des échantillons de données nécessaires et pour réduire le temps passé dans les transmissions et, par conséquent, la quantité d'énergie consommée. Un exemple d'application est fourni à travers la surveillance des conditions climatiques (température et humidité) d'un environnement fermé. Les auteurs de (Vinutha *et al*, 2017) proposent une approche pour contrôler et optimiser une puissance de communication dans le réseau de capteurs sans fil. L'échantillonnage intelligent est également utilisé ainsi qu'une méthode de routage basée sur un réseau de neurones à propagation arrière (en anglais back propagation neural network ou BPNN) pour trouver le chemin le plus court entre la source et la destination en prédisant les meilleurs nœuds du chemin. Cela réduit la perte de paquets et les retransmissions ultérieures qui pourraient consommer l'énergie de la batterie. Les auteurs de (Khan *et al*, 2016) présentent un protocole de routage hiérarchique, un clustering basé sur un vecteur de support (en anglais support vector machine ou SVM) qui attribue efficacement les nœuds de capteur au cluster le plus proche tout en équilibrant la dissipation d'énergie. En effet, pour une meilleure utilisation de l'énergie, les réseaux de capteurs sans fil se divisent en un certain nombre de clusters ayant une tête de cluster et plusieurs nœuds de capteurs. De cette manière, la puissance de

traitement des nœuds de capteurs individuels peut être minimisée. Les SVM sont également utilisés pour la détection de panne de communication, panne de batterie, de pannes matérielles et logicielles. Pour surmonter le problème de la détection des pannes dans les réseaux de capteurs sans fil une autre technique d'apprentissage est utilisée, la méthode des K plus proches voisins (KNN) (Praveen Kumar *et al*, 2019), (Almi'ani *et al*, 2010).

L'apprentissage automatique est utilisé de diverses façons dans les réseaux de capteurs sans fil (Kaur *et al*, 2020), notamment pour pallier aux problèmes qui affectent les performances telles que l'énergie (ANN (Al-Omary *et al*, 2019)), l'autogestion, la localisation (K-mean (Ongsulee, 2017), ANN), la synchronisation, la sécurité (K-means, KNN, Regression, Arbre de décision (Lee et Choi, 2008)), les problèmes de couche MAC, le routage (SVM (Geng *et al*, 2016)), la qualité des services (QoS), la collecte et la transmission de données (Régression, Arbre de Décision, ANN, KNN).

3.4. Autres approches

On note aussi qu'une autre approche de l'intelligence artificielle, l'intelligence symbolique, a également été envisagée pour la prédiction dans les RCSF-RE. Le modèle suivant est un modèle de prédiction basé sur la logique floue.

3.4.1. Modèle Flou

Les auteurs de (Katkhar et Ghorpade, 2016) proposent un protocole de routage pour un réseau de capteurs mobiles sans fil axé sur un modèle de prédiction basée sur la logique floue. À l'image des modèles stochastiques présentés au début de ce chapitre, ce modèle n'est pas déterministe. Il prédit l'état énergétique du nœud, en d'autres mots, s'il est apte à opérer ou pas, et non la quantité d'énergie dont il pourrait disposer. La prédiction de l'état énergétique aide à choisir les nœuds à haute énergie pour le routage. La sélection du nœud à énergie maximale garantit une stabilité élevée du chemin. Les nœuds avec une énergie minimale ne sont pas sélectionnés. En conséquence, la rupture

de chemin due à un manque d'énergie est évitée, ce qui minimise le taux de perte de paquets de données.

Le système flou permet des degrés d'appartenance dans l'intervalle [0, 1]. Chaque fonction d'appartenance chevauche uniquement la fonction d'appartenance voisine. La sortie du contrôleur flou est dérivée des fuzzifications des entrées et des sorties à l'aide des fonctions d'appartenance associées. L'énergie est spécifiée par une fonction d'appartenance triangulaire utilisant trois paramètres a, b et c comme suit :

$$(x : a, b, c) = \begin{cases} 0 & x < a \\ \frac{x-a}{b-a} & a \leq x \leq b \\ \frac{c-x}{c-b} & b \leq x \leq c \\ 0 & x > c \end{cases} \quad (3.48)$$

Les auteurs ajoutent à la prédiction de l'état énergétique du nœud, la prédiction de sa mobilité. La prédiction de mobilité est l'estimation de l'emplacement futur des nœuds. La mobilité est représentée par la fonction d'appartenance à l'aide de quatre paramètres a, b, c et d comme suit :

$$(x : a, b, c, d) = \begin{cases} 0 & x < a \\ \frac{x-a}{b-a} & a \leq x \leq b \\ 1 & b \leq x \leq c \\ \frac{d-x}{d-c} & c \leq x \leq d \\ 0 & x > d \end{cases} \quad (3.49)$$

Chaque variable d'entrée a trois états linguistiques, les variables linguistiques sont associées à des variables d'entrée qui sont définies comme Faible (L), Moyen (M), Élevé (H). Un total de $3 * 3 = 9$ règles conditionnelles sont trouvées.

Les résultats de simulation d'un réseau de capteurs mobiles sans fil avec prédiction et sans prédiction montrent clairement que le taux de perte de paquets du réseau sans prédiction est supérieur à celui du réseau qui utilise la prédiction. La logique floue est une approche efficace pour sélectionner un chemin stable, la rupture de chemin due au manque d'énergie a été évitée, ce qui a minimisé le taux de perte des paquets.

CHAPITRE IV

MODÈLE DU SYSTÈME

Ce chapitre est organisé en trois sections. La première présente le modèle du RCSF-RE que nous considérons afin d'évaluer l'effet de la prédiction sur les performances. La seconde section présente trois modèles de prédiction issus de l'apprentissage automatique que nous utilisons pour prédire l'énergie disponible au niveau des nœuds récepteurs avant chaque tentative de transmission. La dernière section présente le processus de communication proposé pour mettre en pratique la prédiction de l'énergie des prochains nœuds au modèle du réseau de capteurs. Ce processus comporte une modélisation de la dynamique du réseau et les contraintes énergétiques liées aux capacités de stockage des nœuds ainsi qu'à la capacité du canal de communication.

4.1. Modèle du réseau

Le modèle du réseau considéré pour notre étude est constitué de N nœuds alimentés de batteries rechargeables à l'énergie renouvelable. Le premier nœud est un émetteur de l'information captée. Le dernier nœud est restreint à la fonction de réception, comme un puits. Le reste des nœuds intermédiaires servent de relais. La figure 4.1 représente le modèle du système considéré.

Cette étude sera restreinte à l'énergie allouée au module radio, considérant l'énergie de tout autre module, le microprocesseur et le module de captation, comme négligeable.

Nous avons limité l'espace d'interaction des nœuds afin que chaque nœud ne puisse interagir qu'avec les nœuds qui lui sont immédiatement proches. L'utilisation du terme « prochains nœuds » par rapport à un nœud désigne les nœuds qui lui sont immédiatement proches en direction du puits.

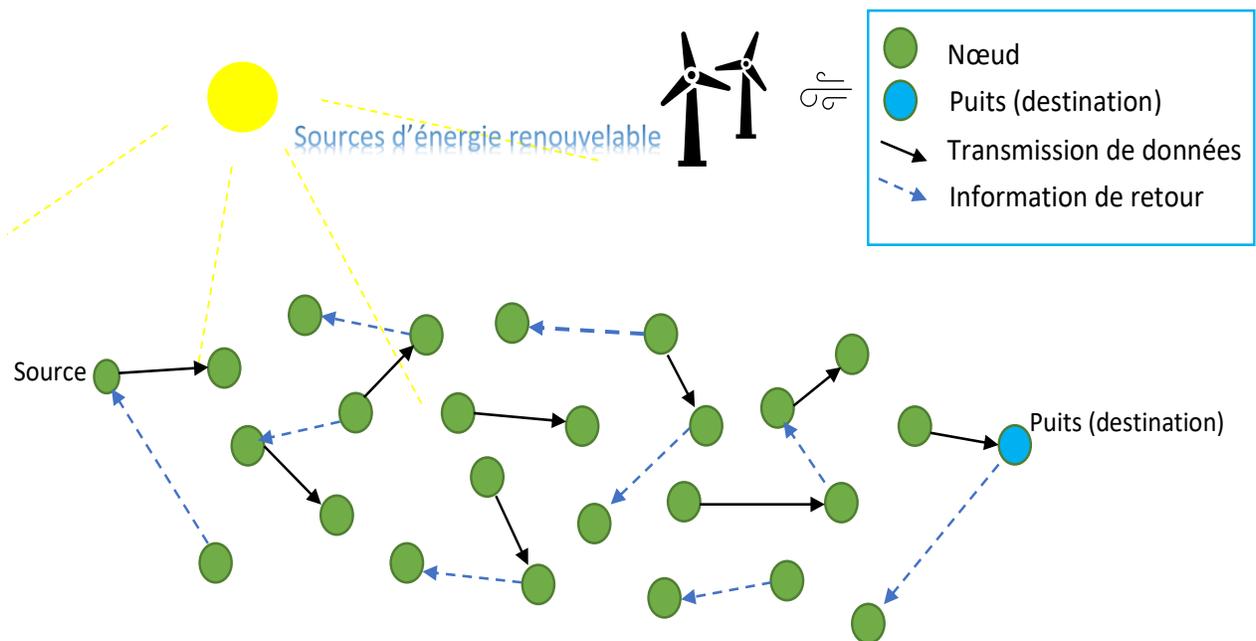


Figure 4.1. Schéma du réseau de capteurs sans fil à énergie renouvelable

À la fin de chaque intervalle de temps, chaque nœud informe les nœuds qui le précèdent de l'état de charge de sa batterie, de la quantité d'énergie capturée durant l'intervalle de temps actuel, de la qualité du canal le reliant à eux et de son statut : émetteur ou récepteur. Si un nœud a reçu un paquet à l'intervalle de temps actuel n , il aura donc le statut d'émetteur à l'intervalle de temps suivant $n + 1$, sinon il aura le statut de récepteur. Ces informations permettront à chaque nœud (possiblement émetteur) de prévoir si le prochain nœud sera apte à recevoir des données. Ainsi, un nœud émetteur sera en mesure de faire une sélection parmi les prochains nœuds en se basant sur leur disponibilité, le niveau d'énergie estimé et la qualité du canal le reliant à eux.

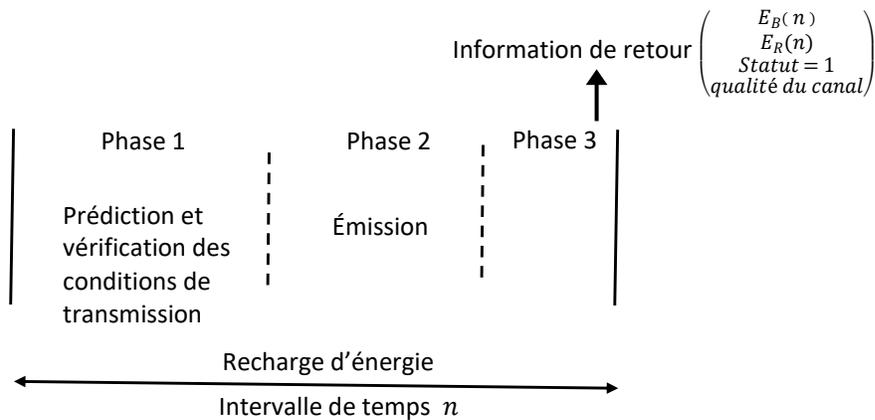


Figure 4.2. Représentation temporelle du fonctionnement d'un émetteur

On désigne par $E_B(n)$ l'état d'énergie de la batterie à l'intervalle de temps n , $E_R(n)$ l'énergie renouvelable récoltée durant l'intervalle de temps n et $Statut$ le statut du nœud prévu à l'intervalle de temps $n + 1$. Si le $statut$ est égale à 1, cela signifie que le nœud est un émetteur. Si le $statut$ est égale à 0, cela signifie que le nœud est un récepteur.

Le fonctionnement d'un émetteur est représenté dans la figure 4.2. Un intervalle de temps est divisé en trois phases :

Phase 1 : Durant cette phase, le microprocesseur effectue les calculs nécessaires à la prédiction de l'énergie du prochain nœud et vérifie les conditions de transmission.

Phase 2 : Durant cette phase, si les conditions sont réunies, le nœud émet un paquet de données.

Phase 3 : Durant cette phase, chaque nœud reçoit l'information de retour (en anglais feedback) du nœud récepteur.

On suppose que la durée de la phase 1 et de la phase 3 ainsi que l'énergie de transmission de l'information de retour sont négligeables.

Lorsque le nœud a le statut de récepteur, un intervalle de temps est divisé en deux phases, une phase de réception et une phase de transmission de l'information de retour.

4.2. Modèles de prédiction d'énergie :

L'apprentissage profond est un ensemble de techniques issu de l'apprentissage automatique. La notion de profondeur vient du fait qu'un réseau de neurones contient plus de deux couches cachées. La motivation derrière cette multiplication de couches est que chaque couche encode un niveau d'abstraction différent, ce qui permet au réseau une plus grande capacité de représentation et d'approximation de modèles très complexes. Cette multiplication de couches apporte son lot de désagrément. Le nombre élevé de couches amène le gradient à s'approcher du zéro-machine lors de la rétropropagation pour le calcul de ∇L , phénomène connu sous le nom de l'évanouissement du gradient (en anglais Gradient Vanishing). Ce phénomène est très présent dans les réseaux de neurones récurrents par exemple. Un réseau de neurones récurrent est un réseau de neurones qui contient au moins un cycle. Les plus connus sont les réseaux d'Elman, de Jordan et les LSTM.

4.2.1. Long Short Term Memory (LSTM)

La nature des données utilisées dans la recherche pour la traduction linguistique présente de fortes similitudes à la nature des données des séries temporelles. Une séquence de mots présentée en entrée à l'algorithme d'apprentissage est vectorisée en un vecteur similaire à une série temporelle. Cette forte similitude a poussé les chercheurs dans le domaine de la prédiction de séries temporelles à s'approprier cet algorithme. Les LSTM font partie de ses modèles. Le LSTM est un réseau de neurones récurrent proposé en 1995 par S. Hochreiter et J. Schmidhuber. (Hochreiter et Schmidhuber,1995).

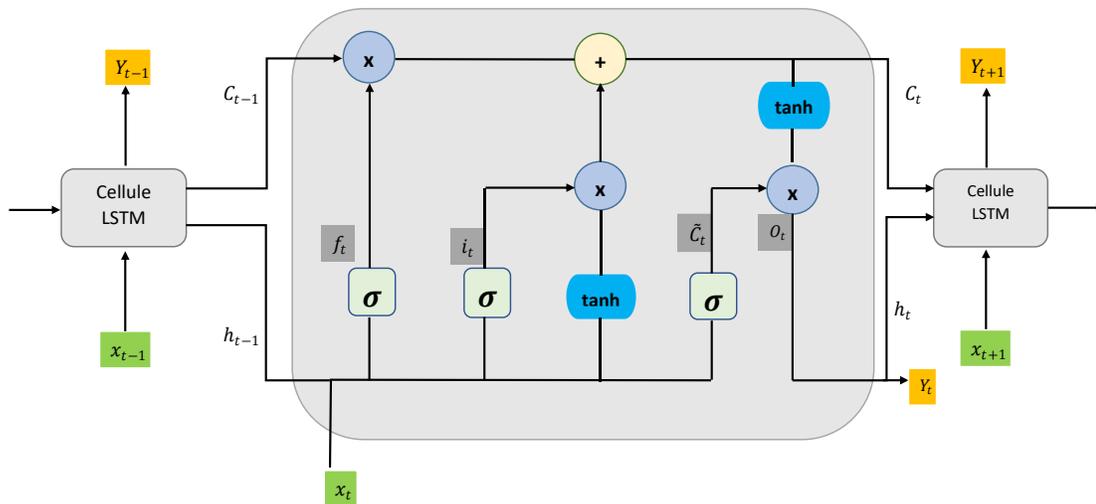


Figure 4.3 Architecture d'une cellule LSTM

Pour éviter l'évanouissement du gradient, des portes logiques multiplicatives sont introduites afin de conserver et d'accéder à l'information pertinente sur de longs intervalles (Glorot, 2014). Une couche LSTM (Figure 4.3) est composée de quatre couches RNN. Trois d'entre elles sont une fonction logistique (sortie entre 0 et 1). La quatrième couche est une couche RNN standard. La porte d'oubli définit à l'aide de pondération quelle information est utile à la prédiction et doit être sauvegardée, et quelle information n'est pas nécessaire à la prédiction et doit être oubliée. La porte d'entrée contrôle la quantité d'information qui entre dans la cellule actuelle. Elle sélectionne parmi les informations de l'entrée actuelle et de l'état caché de la cellule précédente les informations qui sont susceptibles d'être utiles. L'état de la cellule est une couche RNN standard qui alimente l'état interne de la cellule via les portes d'entrée. Elle se comporte comme une mémoire contenant l'information à mémoriser. La porte de sortie contrôle la quantité d'informations qui sort de la couche. Elle opère une sélection des informations qui caractériseront le prochain état caché qui sera utilisé à la cellule suivante. L'objectif principal de ces portes est de filtrer les informations à l'aide de pondération afin de ne conserver que les informations jugées pertinentes pour la prédiction.

4.2.2. Le *Transformer*

Également issus des recherches sur la traduction linguistique, les réseaux de neurones récurrents avec un mécanisme d'attention proposés dès 2014 ont amélioré considérablement les performances d'apprentissage. Cependant leur nature séquentielle a très vite été considérée comme un handicap, même pour les LSTM réputés surpassant le problème de l'évanouissement du gradient. Pour pallier ce problème, Google propose dès 2017 le *Transformer* dans l'article *Attention Is All You Need* (Vaswani *et al*, 2017). L'innovation qui l'a rendu célèbre vient du fait qu'il effectue ses opérations avec parallélisme, ce qui lui a valu la réputation d'être plus puissant. Depuis, plusieurs modèles basés sur celui de Google ont vu le jour, tels que le modèle BERT développé en novembre 2018 et le modèle Turing-NLG en février 2020.

Le *Transformer* proposé par Google en 2017 (Vaswani *et al*, 2017) se compose d'une pile de six couches d'encodeur suivie d'une pile de six couches de décodeur (figure 4.8). Chaque couche apprend des caractéristiques particulières et les transmet à la couche suivante (Guillou, 2020). Le nombre de six couches est arbitraire, depuis 2017 plusieurs modèles ont vu le jour avec un nombre de couches d'encodeur et de couches de décodeur plus conséquent. Néanmoins, la logique derrière son architecture demeure plus ou moins inchangée.

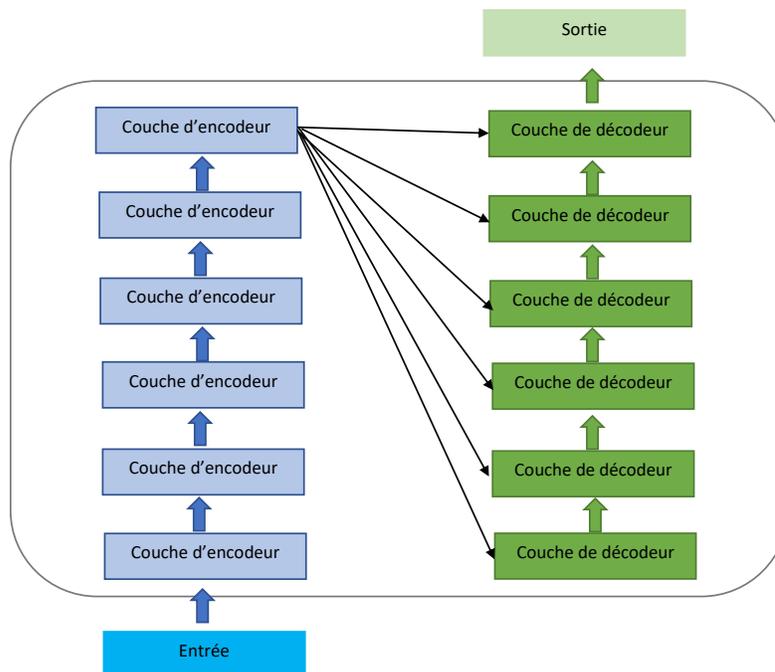


Figure 4.4 Architecture du Transformer

Chaque couche d'encodeur est composée de deux couches, une couche d'auto-attention et une couche à propagation avant. Grâce à des matrices de pondération, ces couches d'auto-attentions permettent au modèle de se concentrer sur les parties importantes de la série temporelle pour effectuer la prédiction, ou à regarder d'autres mots dans la phrase d'entrée lorsqu'il est utilisé pour la traduction. En traduction linguistique, afin de rendre compte de l'ordre des mots dans la séquence d'entrées, un vecteur de position est ajouté à l'entrée de la première couche d'encodeur. Ces vecteurs suivent un modèle spécifique que le modèle apprend, ce qui l'aide à déterminer la position de chaque mot ou la distance entre différents mots dans la séquence (Schmidt, 2020). Selon les auteurs, pour le cas d'une prédiction de série temporelle, plutôt qu'un vecteur de position, un vecteur de temps est plus adapté à la nature du problème. Sans cela, le *Transformer* ne recevrait aucune information sur l'ordre temporel des données. Par conséquent, une valeur récente peut exercer la même influence sur la prévision qu'une valeur beaucoup plus ancienne (Schmidt, 2020). Pour ce cas, l'utilisation d'un vecteur temps décrit dans l'article (Kazemi *et al*, 2019) est recommandée.

La sortie de la couche d'encodeur supérieure est transformée en un ensemble de vecteurs qui aide le décodeur à se concentrer sur les endroits appropriés dans la séquence d'entrée. Pour le cas de prédiction de série temporelle, l'article (Schmidt, 2020) présente l'inutilité d'utiliser une pile de couches de décodeur. Il est remplacé par une couche de régression en sortie du *Transformer*.

4.2.3. Le N-BEATS (Neural basis expansion analysis for time series)

Le modèle N-BEATS est un réseau de neurones profond basé sur des liens résiduels en amont et en aval et un empilement très profond de couches entièrement connectées. Son architecture est présentée dans la figure (4.5). (Oreshkin *et al*, 2019)

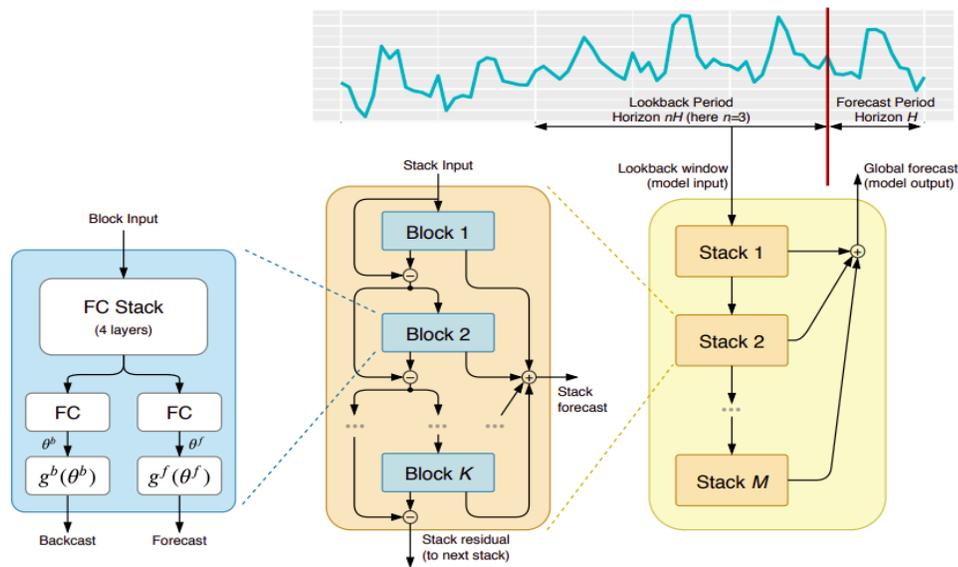


Figure 4.5. Architecture du N-BEATS (Oreshkin *et al*, 2019)

Chaque pile du N-BEATS est constituée de blocs dont l'entrée est liée au bloc précédent. Grâce à des matrices de pondération qui éliminent les composants des entrées qui sont inutiles à la prédiction, chaque bloc produit une prédiction partielle des prochaines données (appelée en anglais Forecast) et une estimation des données en entrée (appelée en anglais Backcast). Un bloc n prend en entrée l'entrée du bloc $n - 1$ à laquelle on soustrait le Backcast du bloc $n - 1$. De cette manière, l'entrée devient un

vecteur qui n'incorpore que les apprentissages insuffisamment appris par le bloc précédent, ce qui facilite la prédiction pour les blocs en aval et la rétropropagation du gradient. La sortie du dernier bloc de la pile servira d'entrée à la pile suivante. Les prédictions partielles de chaque bloc sont additionnées élément par élément pour donner une prédiction de sortie de la pile. Les sorties des piles sont à leurs tours additionnées pour donner la prédiction finale. Les auteurs (Oreshkin et al, 2019) proposent deux configurations de l'architecture du modèle selon le choix de paramètre, soient l'architecture générique qui est indépendante de toute connaissance préalable de la série temporelle et l'architecture interprétable qui modélise la tendance et la saisonnalité.

4.3. Processus de communication

Le processus de communication se déroule ainsi,

- 1- À la fin de l'intervalle de temps précédent, $n - 1$, chaque nœud reçoit l'information de retour des prochains nœuds.
- 2- Au début de l'intervalle de temps n , le microprocesseur effectue les calculs nécessaires pour faire une estimation de la quantité d'énergie des prochains nœuds. Cette estimation se fait grâce aux données reçues en information de retour à la fin de l'intervalle de temps précédent $n - 1$,

$$\hat{E}_B^{i+1}(n) = E_B^{i+1}(n - 1) + \hat{E}_R^{i+1}(n), \quad (4.1)$$

où $\hat{E}_B^{i+1}(n)$ est la quantité d'énergie estimée de la batterie du prochain nœud à l'intervalle de temps n , $E_B^{i+1}(n - 1)$ est la quantité d'énergie stockée dans la batterie du prochain nœud à la fin de l'intervalle de temps $n - 1$ et $\hat{E}_R^{i+1}(n)$ est l'estimé de la quantité d'énergie renouvelable emmagasinée par le prochain nœud à l'intervalle de temps n .

Il y'a également une contrainte due à la limitation de la capacité de la batterie. En effet, selon la quantité restante d'énergie dans la batterie $E_B^{i+1}(n - 1)$, l'accumulation de

l'énergie ne peut dépasser la capacité maximale de stockage de la batterie. Cette condition s'exprime ainsi :

$$E_B^{i+1}(n-1) + \hat{E}_R^{i+1}(n) \leq E_B^{max}, \quad (4.2)$$

où $E_B^{i+1}(n-1)$ est la quantité d'énergie stockée dans la batterie à la fin de l'intervalle de temps $n-1$, $\hat{E}_R^{i+1}(n)$ est l'estimé de la quantité d'énergie qui sera emmagasinée à l'intervalle de temps n , et E_B^{max} est la capacité de stockage maximale de la batterie.

3- Une fois l'estimation faite, le nœud émetteur compare la quantité d'énergie stockée dans sa batterie à la quantité d'énergie requise pour une transmission. Si son niveau d'énergie est suffisant, il compare ensuite l'estimation faite du niveau d'énergie de chacun des prochains nœuds récepteurs à l'énergie requise pour une transmission. Cette condition est une limite qui indique si le nœud récepteur est capable de transmettre à l'intervalle de temps suivant. Si ces deux conditions sont réunies, le nœud émetteur tentera une transmission.

$$\begin{cases} E_{Emetteur}(n) \geq E(n) \\ \hat{E}_{Récepteur}(n) \geq E(n) \end{cases}, \quad (4.3)$$

où $\hat{E}_{Récepteur}(n)$ est l'énergie estimée d'un des prochains nœuds à l'intervalle de temps n , $E_{Emetteur}(n)$ est l'énergie du nœud émetteur à l'intervalle de temps n et $E(n)$ est l'énergie nécessaire pour la transmission à l'intervalle de temps n . Cette énergie est calculée en prenant en compte le débit maximal auquel les informations peuvent être transmises sur le canal de communication selon l'équation de Shannon-Hartley (Saidi *et al*, 2016) :

$$c = B * \log_2\left(1 + \frac{|h|^2 * E(n)}{\delta^2 * B * T_s * Gap}\right), \quad (4.4)$$

où c est le débit de transmission du canal, $B = 1$ MHz est la largeur de la bande passante, $\delta^2 = -174$ dBm/Hz est la densité spectrale de puissance du bruit, $|h|^2$ est le gain du canal, $E(n)$ est l'énergie nécessaire pour la transmission d'un paquet de données, $T_s = 10$ ms est le temps de transmission et $Gap = 1$ dB est un terme de

compensation afin d'adapter l'équation aux erreurs du canal. Le gain du canal $|h|^2$ est calculé à chaque intervalle de temps en suivant le modèle de Rayleigh avec la moyenne étant l'atténuation de propagation avec ombrage (en anglais, Log-distance path loss) et l'écart type est égale à 1.

4- En se basant sur les quantités d'énergie prédites, ainsi que sur l'état des nœuds destinataires (émetteur ou récepteur) selon l'indication reçue à la dernière Information de retour, le nœud émetteur effectue une sélection entre les prochains nœuds en utilisant comme métrique le coût énergétique de la transmission.

5- Le nœud émetteur envoie le paquet de données au nœud sélectionné. Si aucun des nœuds ne remplit les conditions nécessaires à la transmission, le nœud émetteur s'abstient d'émettre et revérifiera ces conditions à l'intervalle de temps suivant.

À partir de cet instant, on peut aisément deviner la dynamique du réseau. Au début de chaque intervalle de temps, une prédiction et une estimation de l'énergie sont faites. Ensuite, un envoi et une réception s'effectuent par deux nœuds qui se succèdent si les niveaux d'énergie le permettent. À la fin de chaque intervalle de temps chaque nœud envoie l'information de retour aux nœuds qui précèdent. Cette topologie nous permet de mettre à l'épreuve ce protocole de prédiction de l'état d'énergie du prochain nœud, et donc de faire un choix de routage entre les différents itinéraires.

CHAPITRE V

MODÈLES DE PRÉDICTION: APPLICATION ET SIMULATION

Dans la première partie de ce chapitre, nous présentons les procédures d'entraînement des modèles de prédiction, les résultats de simulation ainsi qu'une analyse de ces résultats. Nous effectuons également une comparaison entre ces différents modèles de prédiction pour la prédiction de données météorologiques. Dans la seconde partie, nous effectuons une simulation du processus de communication basé sur la prédiction de la quantité d'énergie des prochains nœuds et nous étudions l'impact de l'utilisation de cette prédiction sur les performances du réseau.

5.1. L'entraînement des prédicteurs

Dans cette partie nous présentons les procédures d'entraînement du LSTM, du *Transformer* et du N-BEATS avec des données capturées toutes les trente minutes du 1^{er} janvier 1998 au 31 décembre 2019, à Montréal. Un total de 385 440 données représentant l'énergie solaire disponible en $watt/m^2$. De ces 385 440 données, 70% sont utilisés pour l'entraînement et 30 % pour le test d'où est calculée la racine de l'erreur quadratique moyenne. L'entraînement se fait par lot de 32 (batch-size = 32). L'optimisation se fait avec Adam, une extension de la descente du gradient stochastique. L'évaluation se fait par le calcul de la racine de l'erreur quadratique moyenne (en anglais root mean square error ou RMSE) sur la prédiction des données tests entre la valeur prédite \hat{y} et la valeur réelle y .

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2}, \quad (5.1)$$

où n est le nombre de données, y est la valeur réelle et \hat{y} est la valeur prédite.

Chacun de ces modèles de prédiction utilise plusieurs hyperparamètres. Ils doivent être fixés de manière expérimentale. Afin de les distinguer, nous allons faire varier la valeur de ces hyperparamètres sur un intervalle et élire les valeurs pour lesquelles la simulation présente la plus petite erreur moyenne de prédiction.

5.1.1. L'entraînement du *Transformer*

Le premier hyperparamètre considéré du *Transformer* est le nombre de têtes d'attention. Plusieurs têtes d'attention permettent au modèle de se concentrer sur de multiples positions, ce qui évite au modèle d'être dominé par l'élément actuel qu'il traite. Le deuxième hyperparamètre est le nombre de couches d'encodeur. Le troisième hyperparamètre est la taille de la matrice K et de la matrice V . La matrice K représente la relation entre l'élément traité actuellement et le reste des éléments du vecteur d'entrée. La matrice V représente la valeur de chaque élément du vecteur d'entrée. C'est une sorte de pondération des éléments de l'entrée. Plus la taille de ces matrices augmente plus le modèle nécessite un temps de calcul plus grand. Nous avons progressivement testé plusieurs valeurs en suivant une échelle croissante de 1 à 24. Nous avons choisi la valeur de 12 afin de faire un compromis entre précision et temps de calcul. Pour le nombre de têtes d'attention, nous avons effectué plusieurs simulations et nous avons gardé la valeur pour laquelle la RMSE est minimum. Le tableau 5.1 présente les RMSE pour différents nombres de têtes d'attention. Le nombre de têtes d'attention sélectionné est égal à 12.

Tableau 5.1. Variation de la RMSE en fonction du nombre de têtes d'attention du modèle transformer

Nbr de têtes d'attention	1	2	4	6	8	12	18	24
RMSE	14	9,3	10,15	9,48	10	7,89	8,42	10,46

Le nombre de couches d'encodeur a été fixé en effectuant une moyenne sur 10 simulations avec 3, 4, 5 et 6 couches d'encodeur avec différentes longueurs du vecteur d'entrée, de 1 à 90 par palier de 10. Les résultats obtenus montrent que pour différents nombres de couches d'encodeur la précision des prédictions est similaires (figure 5.1)

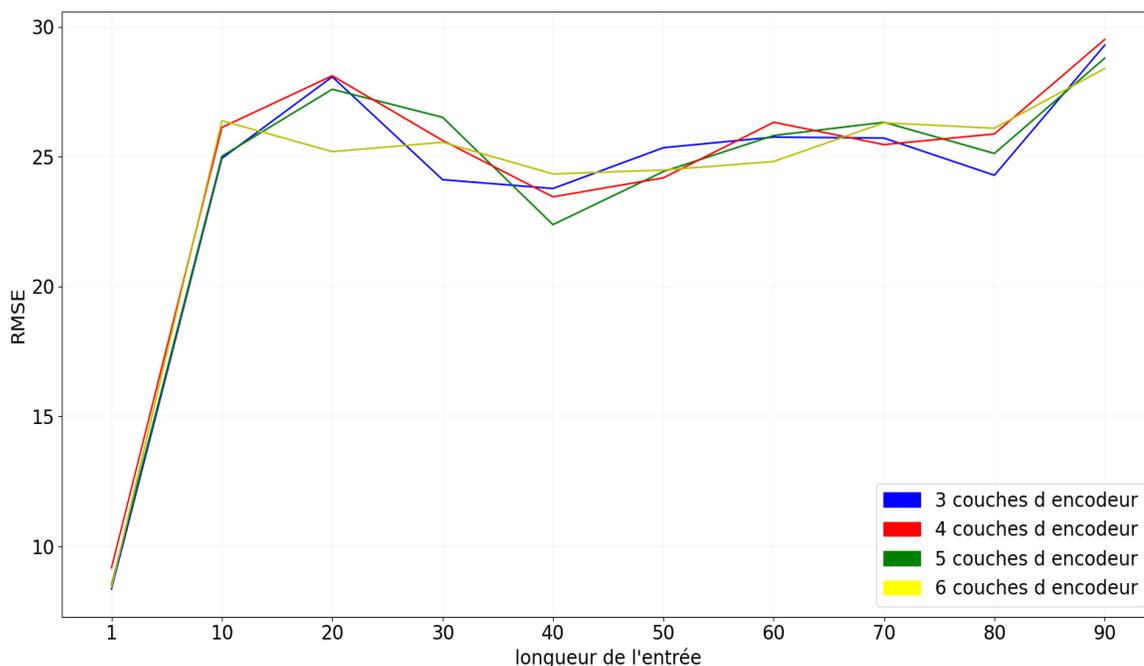


Figure 5.1. Variation de la RMSE en fonction du nombre de couches d'encodeur du Transformer

Vu que ces résultats présentent une précision similaire et pour diminuer la complexité computationnelle, on choisit 3 couches d'encodeur.

5.1.2. L'entraînement du LSTM

Afin de ne pas biaiser les résultats de comparaison, le nombre de couches du LSTM est fixé de manière à garder le nombre de paramètres entraînaibles égal au nombre de paramètres entraînaibles du *Transformer*. Cela se calcule ainsi (Raimi, 2019) :

$$Nbr_para_{Lstm} = 4 * (Nbr_{couche} + taille\ de\ l'entrée) * (Nbr_{couche} + Nbr_{couche}) \quad (5.1)$$

5.1.3. L'entraînement du N-BEATS

Le premier hyperparamètre considéré du N-BEATS est la taille des matrices des coefficients d'expansion avant θ^f et arrière θ^b qui sont des matrices pondérées qui donneront ensuite respectivement la prédiction partielle et l'estimation de l'entrée. Le deuxième hyperparamètre est le rapport entre la longueur de la séquence d'entrée et la longueur de la séquence à prédire, $n = T/H$ où $2 < n < 7$ où T est la longueur de la séquence d'entrée et H est longueur de la séquence à prédire. Le troisième hyperparamètre est le nombre de blocs de base par pile. Le quatrième hyperparamètre est la nature des fonctions g_l^f et g_l^b qui peuvent être apprenables lors de l'entraînement ou des fonctions modélisant la tendance et la saisonnalité de la série temporelle. Le nombre de couches est choisi de manière arbitraire afin d'assurer un nombre de paramètres entraînaibles égal à celui du *Transformer* et du LSTM.

Nous avons fait varier ces paramètres un à la fois dans un intervalle qui correspond à l'ordre de grandeur de chacun, et avons gardé la combinaison qui procure la plus grande précision. La première étape est de fixer les paramètres à une valeur initiale et de remettre en question ces valeurs mises par défaut au fur et à mesure des expérimentations. Pour chacun des paramètres, nous avons effectué 40 simulations et pris une moyenne des 40 RMSE résultantes comme valeur représentative de la précision des prédictions. Pour commencer, nous avons fait varier le rapport entre la longueur de la séquence d'entrée et la longueur de la séquence à prédire, $n = T/H$

avec n variant de 2 à 7 tel que mentionné dans l'article (Oreshkin *et al*, 2019). Les résultats de simulation montrent que le rapport présentant la meilleure précision est $n = T/H$, (tableau 5.2)

Tableau 5.2. Variation de la RMSE en fonction de la variation du rapport T/H

Rapport	$\frac{T}{H} = 2$	$\frac{T}{H} = 3$	$\frac{T}{H} = 4$	$\frac{T}{H} = 5$	$\frac{T}{H} = 6$	$\frac{T}{H} = 7$
RMSE	9,96	9	9,68	10,095	10,63	9,12

L'étape suivante consiste à fixer le nombre de blocs de base dans la pile d'empilement. Nous avons fait varier le nombre de blocs de la pile de 1 à 10. Le tableau 5.3 présente les résultats de simulation. Les résultats montrent clairement que pour 2 blocs de base par pile d'empilement, le modèle présente une meilleure précision.

Tableau 5.3. Variation de la RMSE en fonction du nombre de blocs basique par pile d'empilement

Nbr blocs	1	2	3	4	5	6	7	8	9	10
RMSE	10,26	8,82	9,95	9,73	10,19	10,10	10,23	10,87	11,35	11,84

Nous avons également fait varier la taille des matrices des coefficients d'expansion θ^f et θ^b . Les résultats montrent que la variation de la taille de ces matrices avait une influence non-significative sur la précision telle qu'il n'est pas nécessaire de prendre en considération cette variation. Nous avons fixé la taille de ces matrices à 4 par 4, qui était la valeur par défaut.

L'hyperparamètre restant est la nature des fonctions g_t^f et g_t^b . Nous avons effectué un comparatif entre deux simulations, l'une avec des fonctions apprenables et l'autre avec des fonctions modélisant la tendance et la saisonnalité de la série temporelle (Tableau 5.4). On voit clairement que l'utilisation de fonctions modélisant la tendance et la saisonnalité présente la meilleure précision.

Tableau 5.4. Variation de la RMSE en fonction de la nature des fonctions g_t^f et g_t^b

La nature des fonctions g_t^f et g_t^b	Générique	Tendance et Saisonnalité
RMSE	8,82	7,49

Le tableau 5.5 résume l'ensemble des hyperparamètres fixés après expérimentation.

Tableau 5.5. La valeur des hyperparamètres du N-BEATS

Rapport $n = T/H$	3
Nombre de blocs basique	2 blocs
Taille des matrices θ^f et θ^b	[4 4]
La nature des fonctions g_t^f et g_t^b	Tendance et Saisonnalité
RMSE	7.49

5.2. Comparaison entre les différents prédicteurs

L'objectif de la première simulation est de comparer les prédictions faites par un LSTM, un *Transformer* et un N-BEATS. Cette comparaison est basée sur la RMSE pour différentes longueurs de l'entrée. (figure 5.2)

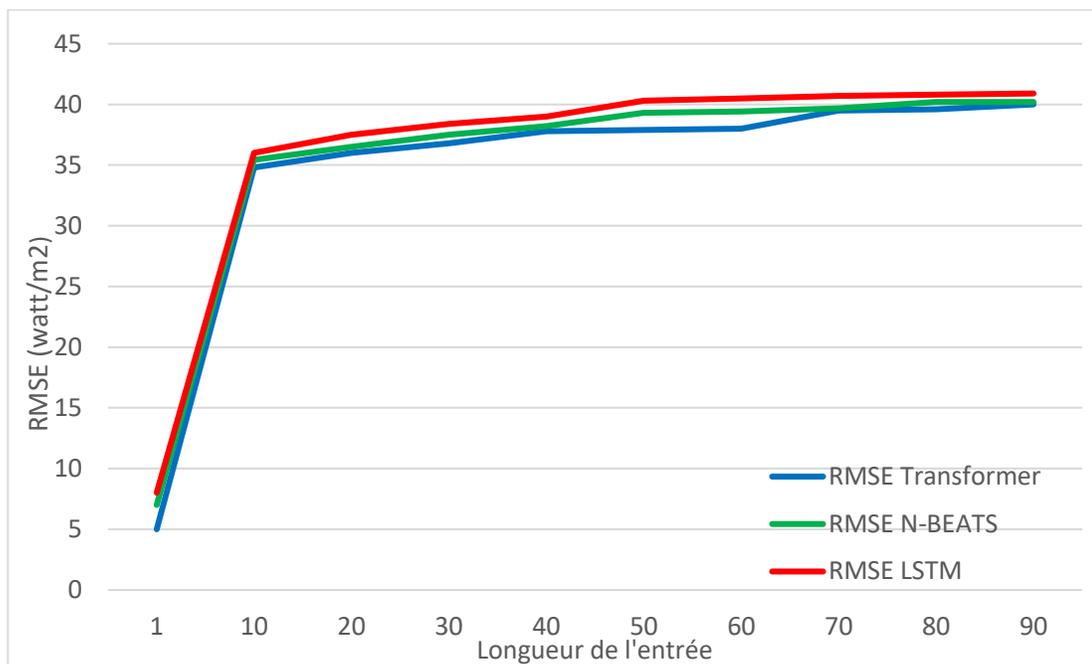


Figure 5.2 Variation de l'erreur de prédiction en fonction de la longueur d'entrée

Les résultats obtenus démontrent clairement les précisions des prédicteurs sont très similaires. Le *Transformer* est 4,84 % plus précis que le LSTM et 2,33 % plus précis que le N-BEATS. Pour les mêmes conditions de puissance de calcul, le *Transformer* a nécessité énormément de temps de calcul comparé aux deux autres modèles. Il est 22 fois plus lent que le N-BEATS. À cause de ce besoin computationnel, la courbe du *Transformer*, en bleu, a été obtenue avec une moyenne sur 10 simulations seulement contre 100 pour le LSTM et 40 pour le N-beats. On constate aussi que pour une longueur d'entrée égale à 1 pas, les prédicteurs présentent la plus petite erreur de prédiction. C'est cette longueur d'entrée qui sera prise lors de l'application des prédicteurs au processus de communication.

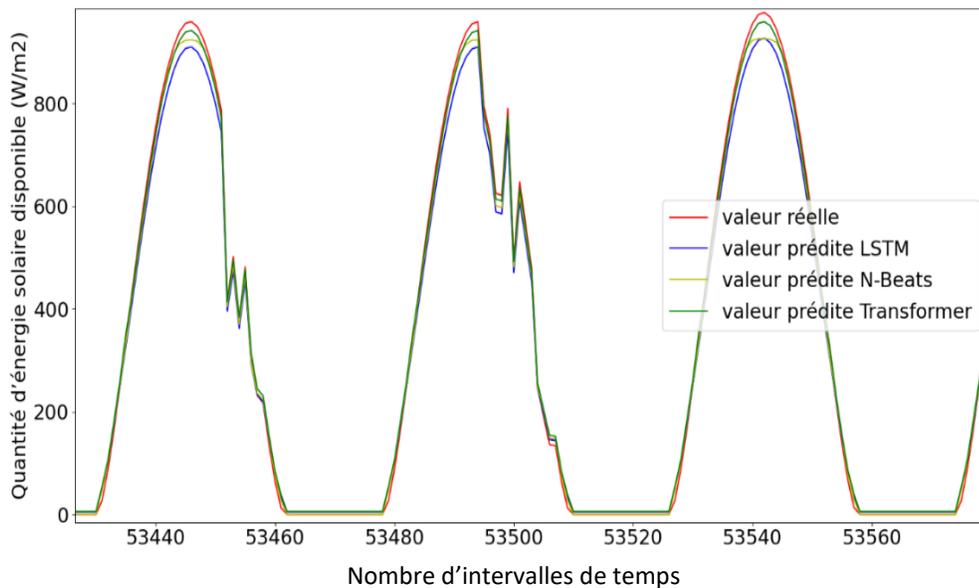


Figure 5.3. Prédiction de l'énergie solaire avec LSTM, Transformer et N-BEATS

La figure 5.3 présente la courbe de l'énergie solaire comparée à celles prédites par les prédicteurs que nous avons implémentés. Par souci de clarté, ces courbes ne représentent que trois jours de capture de l'énergie solaire.

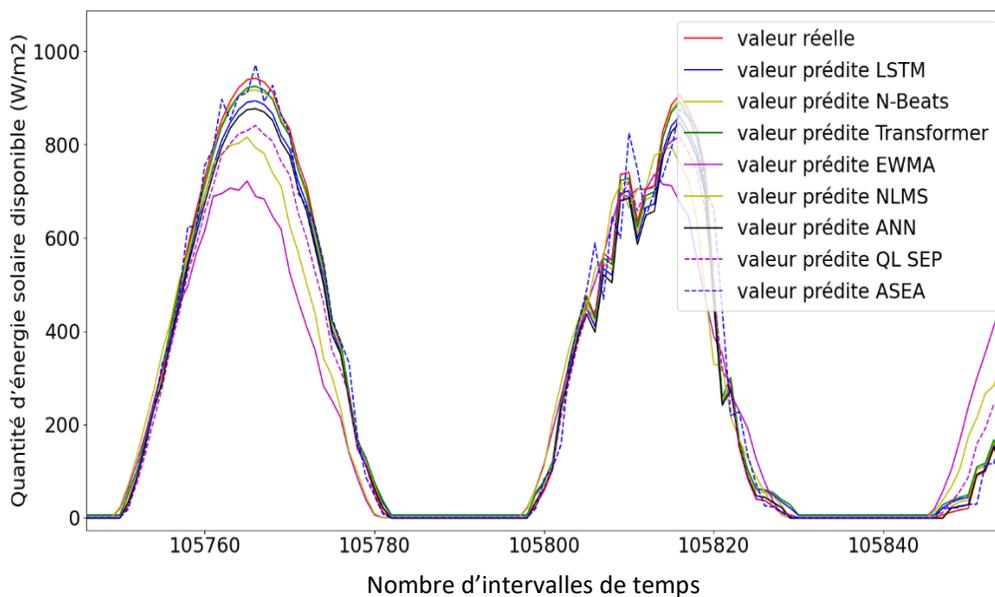


Figure 5.4. Prédiction de l'énergie solaire avec différents prédicteurs

La figure 5.4 présente la courbe de l'énergie solaire comparée à celle des prédicteurs considérés, ainsi que quelques prédicteurs mentionnés dans l'état d'art, tel que le EWMA, le NLMS, le ASEA, le ANN et le QL-SEP. On remarque que le modèle *Transformer* performe mieux en matière de prédiction que le reste des prédicteurs.

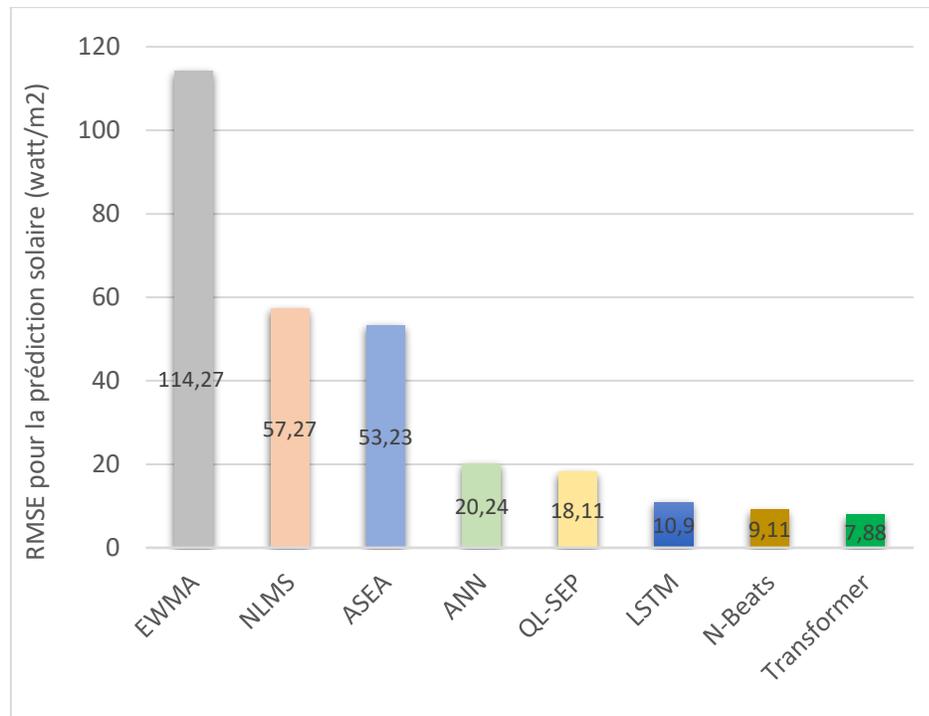


Figure 5.5 Comparaisons entre l'erreur de prédiction de différents prédicteurs

La figure 5.5 représente la RMSE de la précision de prédiction pour les différents prédicteurs. On remarque nettement la supériorité des modèles basés sur l'apprentissage automatique. On remarque aussi que les modèles statistiques, EWMA, NLMS et ASEA, atteignent des erreurs de prédiction de $114,27 \text{ watt/m}^2$, $57,27 \text{ watt/m}^2$ et $53,52 \text{ watt/m}^2$. Bien que l'utilisation de la prédiction dans les RCSF-RE apporte un gain considérable en économie d'énergie, l'erreur de prédiction de ces modèles statistiques demeure élevée et pourrait impliquer des pertes considérables de données. L'utilisation de batteries avec une plus grande capacité de stockage d'énergie ou favoriser des débits de transmission moins élevés avec des cycles

de recharge plus longs pourrait être des solutions à envisager. Ce sont en réalité des contraintes qui pénalisent les performances du réseau. Des prédictors plus précis tels que les modèles d'apprentissage automatique pourraient éliminer ces contraintes.

5.3. Application des prédictors sur le processus de communication

Le processus de communication proposé est basé sur la prédiction de l'énergie des prochains nœuds afin de savoir s'ils ont assez d'énergie pour recevoir un paquet de données et de faire une sélection entre les prochains nœuds aptes à recevoir. Tel que montré à la figure 5.6, les nœuds intermédiaires sont distribués en rangée de nœuds. Chaque rangée peut recevoir un paquet de donnée de la rangée précédente et la retransmettre vers la rangée suivante en direction du puits. La distance moyenne entre deux nœuds est d . La capacité maximale de la batterie est représentée par une échelle allant de 2 fois l'énergie nécessaire à la transmission jusqu'à 10 fois cette énergie. $B_{max} = j \times E_{transmission}$, Avec $j \in \{2,3,4,5,6,7,8,9,10\}$. Afin de ne pas biaiser les résultats, $E_{transmission}$ utilisée pour le calcul de la capacité maximale de la batterie est calculée à partir de l'équation (4.4) et reste fixe pour toutes les simulations suivantes.

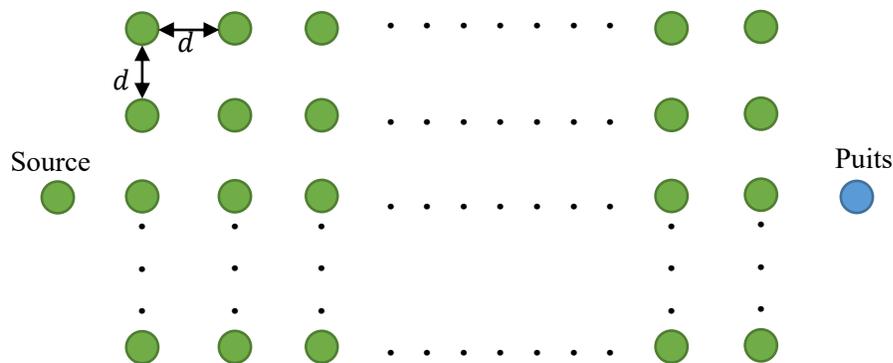


Figure 5.6 Architecture du modèle de réseaux de capteurs considéré

Nous avons varié plusieurs paramètres du réseau : le nombre de nœuds du réseau, la taille des paquets de données, la distance moyenne entre les nœuds et la capacité maximale de la batterie. Pour chaque variation d'un paramètre, on utilise deux

métriques pour mesurer les performances de ce réseau : le pourcentage de réussite et le délai. Afin de prendre en compte l'effet de la prédiction de la quantité d'énergie des prochains nœuds, on effectue une comparaison entre les performances avec prédiction et sans prédiction. Le réseau sans prédiction tentera de transmettre un paquet de données à chaque intervalle de temps, toutes les 10 millisecondes, à condition que le nœud émetteur possède assez d'énergie pour émettre. La quantité d'énergie du destinataire est ignorée.

Dans toutes les simulations suivantes, la durée du temps de transmission est de $T_s = 10 \text{ ms}$, la largeur de la bande passante est de $\beta = 1 \text{ MHz}$, la densité spectrale du bruit du canal est de $\sigma^2 = -50 \text{ dbm}$, le terme de compensation est $Gap = 1 \text{ db}$. Le gain du canal $|h|^2$ est calculé à chaque intervalle de temps en suivant le modèle de Rayleigh avec la moyenne étant l'atténuation de propagation avec ombrage (en anglais, Log-distance path loss) et l'écart type est égale à 1.

Les données représentant les quantités d'énergie des nœuds sont les quantités d'énergie réelles dans la région de Montréal calculées à partir d'une base de données représentant l'irradiation horizontale globale (GHI, en anglais, Global Horizontal Irradiance) disponible sur le lien <https://nsrdb.nrel.gov/>. Ces données GHI en Watt/m^2 ont été normalisées à la surface moyenne du panneau solaire d'un nœud du réseau (10 cm sur 10 cm). Les panneaux solaires ont en moyenne un rendement de 14% de conversion entre l'énergie solaire disponible et l'énergie électrique utilisable. Chaque donnée a été donc multipliée par 0,14. Afin de prendre en compte la variabilité des conditions météorologiques, les données ont été redimensionnées de manière à ne prendre en compte que 10 secondes de données (1000 données) toutes les trente minutes. Une plus large période (7 jours) peut être ainsi prise en compte tout en soulageant la charge computationnelle des intervalles de temps similaires en quantité d'énergie disponible. Les prédictions sont faites avec un *Transformer*, un N-BEATS et un LSTM.

Pour la première métrique, le pourcentage de paquets de données émis par le premier nœud qui ont atteint le puits, on fait varier le nombre de nœuds dans le réseau, la taille du paquet à transmettre, la distance moyenne entre les nœuds et la capacité maximale de la batterie et on calcule dans chaque cas le rapport entre les données arrivées au puits et les données émises par le premier nœud.

La figure 5.7 représente l'effet de la variation du nombre de nœuds dans le réseau sur le pourcentage de paquets émis par le premier nœud ayant atteint le puits. Pour cette simulation, la capacité maximale de la batterie est $B_{max} = 3 \times E_{transmission}$, la taille du paquet est de 50 kbit et la distance moyenne entre les nœuds est $d = 100 \text{ m}$.

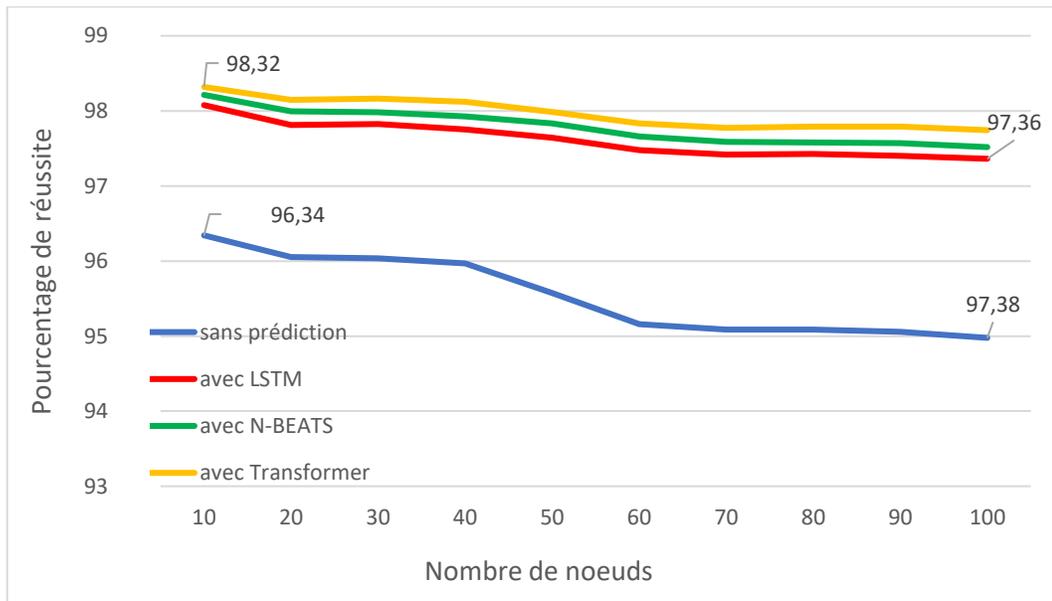


Figure 5.7 Pourcentage de réussite en fonction du nombre de nœuds pour un paquet de 50 kbit

La figure 5.7 montre que le réseau sans prédiction (courbe bleue) présente un pourcentage de réussite de $94,98 \%$ pour un réseau à 100 nœuds. Les réseaux avec prédiction (courbe verte, jaune et rouge) présentent de meilleures performances que le réseau sans prédiction avec un pourcentage de $97,74 \%$ pour un réseau à 100 nœuds. Le réseau utilisant la prédiction faite avec *Transformer* produit un meilleur pourcentage de réussite que les réseaux avec LSTM et N-BEATS. Selon l'architecture du modèle du réseau considéré, l'augmentation du nombre de nœuds augmente le nombre de

tentatives de transmissions et donc augmente également la probabilité d'échec de transmissions. Les réseaux avec prédiction (courbe verte, jaune et rouge) demeurent plus robustes avec l'augmentation du nombre de nœuds qu'un réseau sans prédiction.

Afin de mieux voir l'écart des performances, nous avons effectué la même simulation de la variation du nombre de nœuds dans le réseau sur le pourcentage de réussite mais avec une taille du paquet de 100 kbit , les paramètres restants demeurent inchangés, la capacité maximale de la batterie est $B_{max} = 3 \times E_{transmission}$, la distance moyenne entre les nœuds est $d = 100 \text{ m}$ (Figure 5.8).

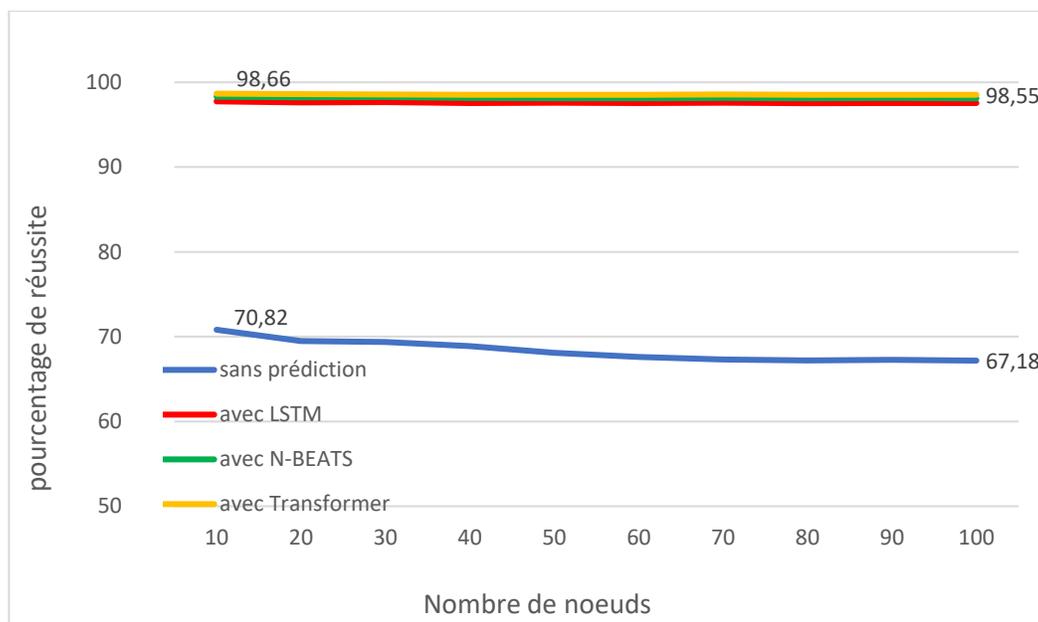


Figure 5.8 Pourcentage de réussite en fonction du nombre de nœuds pour un paquet de 100 kbit

La figure 5.8 montre que le réseau sans prédiction (courbe bleue) présente un pourcentage de réussite de 70.82% pour un réseau à 10 nœuds et un pourcentage de réussite de 67.18% pour un réseau à 100 nœuds. Les réseaux avec prédiction (courbe verte, jaune et rouge) présentent de meilleures performances que le réseau sans prédiction avec un pourcentage de 98.55% pour un réseau à 100 nœuds. Le nombre de transmissions augmente avec le nombre de nœuds que contient le réseau, plus le réseau sera grand plus la probabilité de perdre des paquets sera grande. Le réseau avec

prédiction diminue cette probabilité en prédisant si le nœud récepteur est apte à recevoir et s'abstient d'émettre lorsque l'énergie du récepteur est insuffisante. Dans le réseau sans prédiction, l'émetteur transmet sans prendre en compte l'état énergétique du nœud récepteur, d'où la diminution plus importante du pourcentage de réussite. En augmentant la taille du paquet de données à transmettre, de 50 *kbit* à 100 *kbit*, on augmente la quantité d'énergie nécessaire à la transmission. Cela a pour effet de d'augmenter l'écart entre les performances du réseau lorsqu'il utilise la prédiction et lorsqu'il ne l'utilise pas. Cet effet est observé à la figure 5.9.

La figure 5.9 représente l'effet de la variation de la taille du paquet de données sur le pourcentage de paquets émis par le premier nœud ayant atteint le puits. Pour cette simulation, la capacité maximale est $B_{max} = 3 \times E_{transmission}$, le nombre de nœuds dans le réseau est $n = 100$, la distance moyenne entre les nœuds est $d = 100$ m.

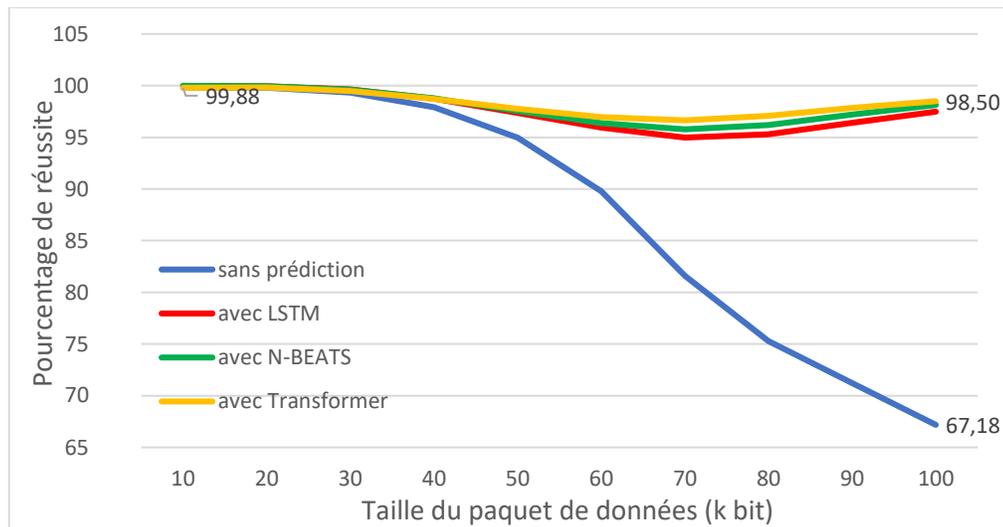


Figure 5.9 Pourcentage de réussite en fonction de la taille du paquet pour un réseau à 100 nœuds

La figure 5.9 montre que pour le réseau sans prédiction (courbe bleue), le pourcentage de réussite diminue avec l'augmentation de la taille du paquet, de 99,88 % pour une taille du paquet de 10 *kbit* à 67,17 % pour un paquet de 100 *kbit*, soit une diminution de 32,62 %. Le pourcentage de réussite d'un réseau avec prédiction (courbe verte,

rouge et jaune) baisse de 0,3 % entre une transmission d'un paquet de 10 *kbit* et d'un paquet de 100 *kbit*. On constate que les courbes (courbe verte, rouge et jaune) présentent une forme de cloche autour d'une taille du paquet de 70 *kbit*. Au-delà de 70 *kbit*, la quantité d'énergie nécessaire à la transmission devient assez grande pour limiter le nombre de tentatives de transmissions lorsque le réseau utilise la prédiction. Cette diminution du nombre de transmissions réduit donc la probabilité de perdre des paquets de données, d'où l'augmentation du pourcentage réussite à partir de ce point. Le réseau avec *Transformer* (courbe jaune) présente les meilleures performances, suivi par le réseau avec N-BEAT (courbe verte) et le réseau avec LSTM (courbe rouge). On déduit que plus l'énergie nécessaire à la transmission est grande plus la précision des prédicteurs devient importante.

La figure 5.10 représente l'effet de la variation de la distance moyenne entre les nœuds du réseau sur le pourcentage de paquets émis par le premier nœud ayant atteint le puits. Pour cette simulation, la capacité maximale de la batterie est $B_{max} = 3 \times E_{transmission}$, le nombre de nœuds dans le réseau est $n = 100$, la taille du paquet est de 50 *kbit*.

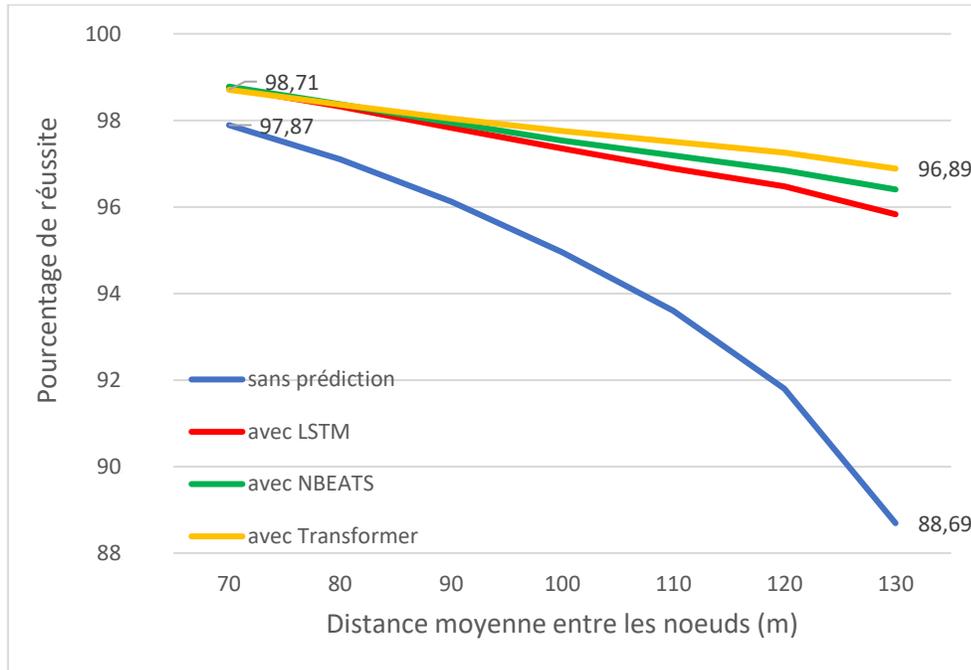


Figure 5.10 Pourcentage de réussite en fonction de la distance moyenne entre les nœuds pour un réseau à 100 nœuds

Selon (eq.4.26) l'augmentation de la distance moyenne entre les nœuds mène à l'augmentation de l'énergie nécessaire à la transmission. Cela a pour effet la diminution du pourcentage de réussite. La figure 5.10 montre un taux de diminution du pourcentage de réussite de 9,2 % pour le réseau sans prédiction (courbe bleue). Les réseaux avec prédiction perdent en moyenne 2 % du pourcentage de réussite.

La figure 5.11 représente l'effet de la variation de la capacité maximale de la batterie sur le pourcentage de paquets émis par le premier nœud ayant atteint le puits. La capacité maximale de la batterie est représentée par une échelle allant de 2 fois l'énergie nécessaire à la transmission jusqu'à 10 fois cette énergie. $B_{max} = j \times E_{transmission}$, Avec $j \in \{2,3,4,5,6,7,8,9,10\}$. Pour cette simulation le nombre de nœuds dans le réseau est $n = 100$, la taille du paquet est de 50 kbit , la distance moyenne entre les nœuds $d = 100 \text{ m}$.

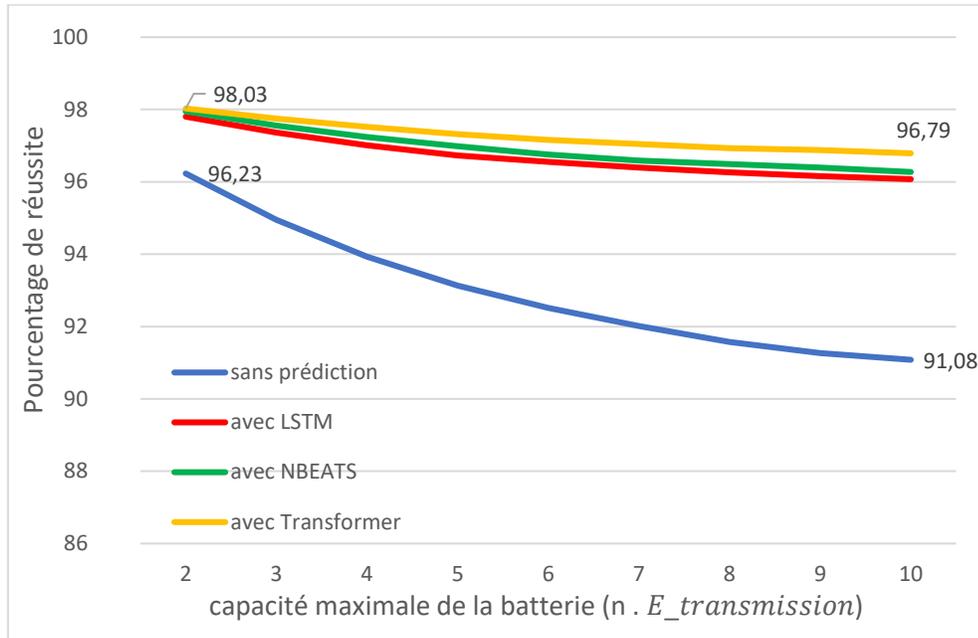


Figure 5.11 Pourcentage de réussite en fonction de la capacité maximale de la batterie pour un réseau à 100 nœuds

La figure 5.11 montre qu'une plus grande capacité de la batterie diminue le pourcentage de réussite de 6 % pour le réseau sans prédiction (courbe bleue) et de 1,5 % en moyenne pour les réseaux avec prédiction (courbe verte, rouge et jaune). Bien que le pourcentage de réussite diminue avec l'augmentation de la capacité maximale de la batterie, le réseau, avec ou sans prédiction, présente un plus grand nombre de paquets de données reçus par le puits. Une augmentation de 7 600 paquets de données reçus en moyenne lorsque le réseau utilise la prédiction entre une capacité stockage d'énergie à $2 \times E_{transmission}$ et une capacité à $10 \times E_{transmission}$. La diminution du pourcentage de réussite peut donc être expliquée par l'augmentation du nombre de tentatives de transmissions qui augmente la probabilité d'échec.

Pour la deuxième métrique, le délai pour envoyer un paquet de données de la source au puits, on fait varier la taille du paquet à transmettre, le nombre de nœuds dans le réseau, la distance moyenne entre les nœuds et la capacité maximale de la batterie et on calcule

dans chaque cas le nombre d'intervalles de temps nécessaire pour la transmission d'un paquet de données de la source au puits.

La figure 5.12 représente l'effet de la variation de la taille du paquet de données sur le délai. Pour cette simulation, la capacité maximale est $B_{max} = 3 \times E_{transmission}$, le nombre de nœuds dans le réseau est $n = 100$, la distance moyenne entre les nœuds est $d = 100 m$.

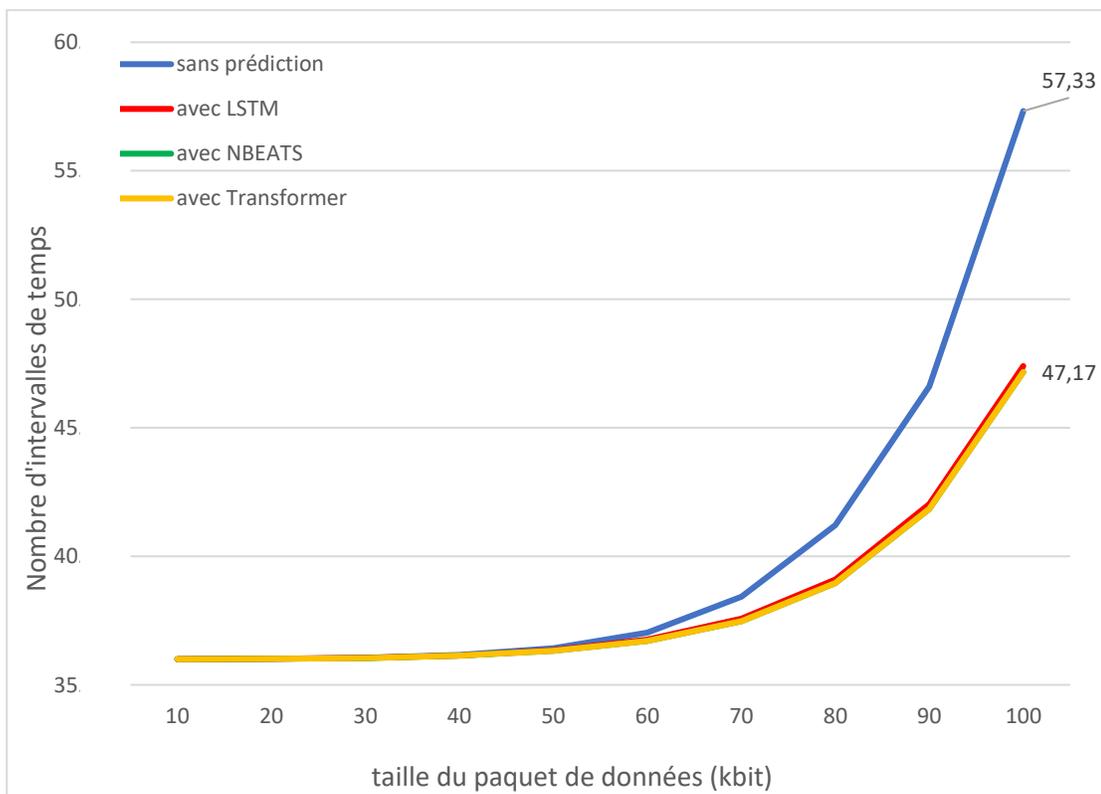


Figure 5.12 Délai pour transmettre un paquet de données en fonction de la taille du paquet pour un réseau de 100 nœuds

La figure 5.12 montre que le temps nécessaire pour transmettre un paquet de données augmente avec l'augmentation de l'énergie nécessaire à la transmission. Cela se traduit par des abstentions de transmettre dues à une énergie insuffisante pour les réseaux avec prédiction (courbe jaune, verte et rouge) et par des échecs de transmission pour le réseau sans prédiction (courbe bleue). Les deux réseaux, avec et sans prédiction,

présentent des performances approximativement identiques pour une taille du paquet en dessous de 50 *kbit*. Au-delà de ce point, les réseaux avec prédiction (courbe jaune, verte et rouge) sont beaucoup plus performants.

La figure 5.13 représente l'effet de la variation du nombre de nœuds dans le réseau sur le délai. Pour cette simulation, la capacité maximale de la batterie est $B_{max} = 3 \times E_{transmission}$, la taille du paquet est de 100 *kbit*, la distance moyenne entre les nœuds est $d = 100 \text{ m}$.

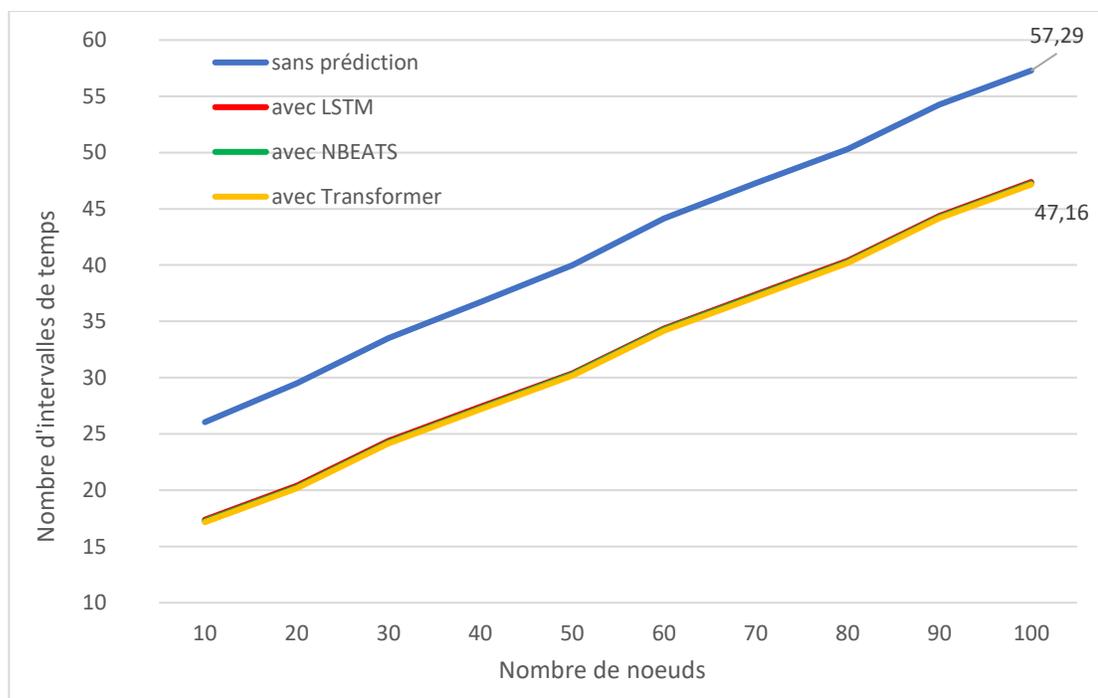


Figure 5.13 Délai pour transmettre un paquet de 100kbit en fonction du nombre de nœuds dans le réseau

La figure 5.13 montre le réseau sans prédiction (courbe bleue) nécessite beaucoup plus de temps pour transmettre un paquet de données que les réseaux avec prédiction (courbe rouge, verte et jaune). Le retard du réseau sans prédiction revient aux pertes de données liées aux échecs de transmission.

La figure 5.14 représente l'effet de la variation de la distance moyenne entre les nœuds du réseau sur le délai. Pour cette simulation, la capacité maximale de la batterie est $B_{max} = 3 \times E_{transmission}$, le nombre de nœuds dans le réseau est $n = 100$, la taille du paquet est de 100 kbit .

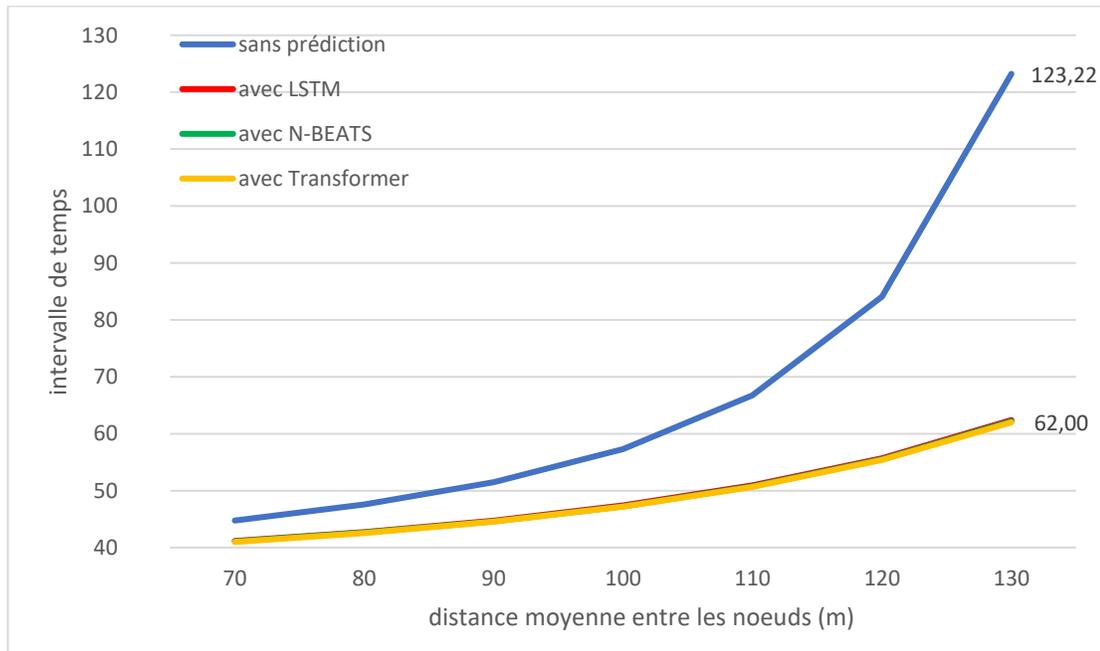


Figure 5.14 Délai pour transmettre un paquet de 100 kbit en fonction de la distance moyenne entre les nœuds pour un réseau de 100 nœuds

Les figures 5.14 montre que les deux réseaux nécessitent plus de temps pour transmettre lorsque la distance moyenne entre les nœuds est plus grande. Plus la distance moyenne entre les nœuds est grande plus l'énergie nécessaire à la transmission d'un paquet de données augmente. Le réseau avec prédiction (courbe jaune, verte et rouge) nécessite moins de temps pour transmettre que le réseau sans prédiction (courbe bleue).

La figure 5.15 représente l'effet de la variation de la capacité maximale de la batterie, $B_{max} = j \times E_{transmission}$, avec $j \in \{2,3,4,5,6,7,8,9,10\}$, sur le délai. Pour cette simulation le nombre de nœuds dans le réseau est $n = 100$, la distance moyenne entre

les nœuds $d = 100 m$. Nous avons effectué deux simulations, avec une taille de paquet de données de $50 kbit$ et une taille de paquet de données de $100 kbit$

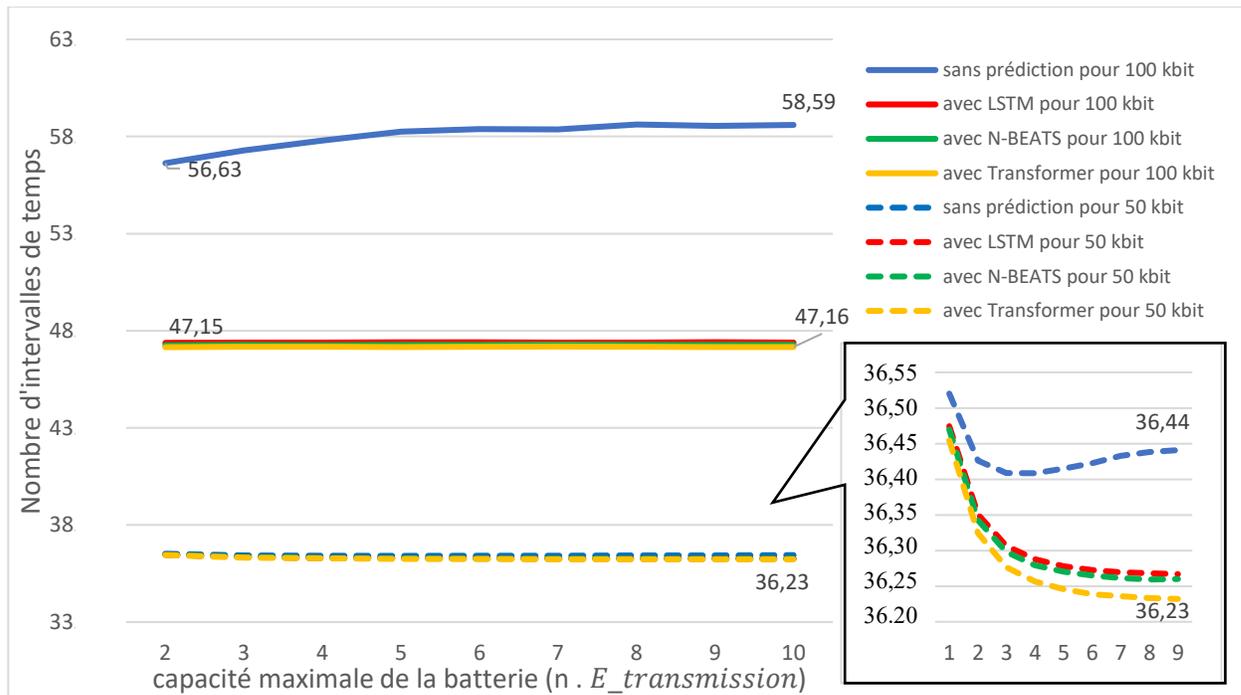


Figure 5.15 Délai pour transmettre un paquet de $100 kbit$ et de $50 kbit$ en fonction de la capacité maximale de la batterie pour un réseau de 100 nœuds

La figure 5.15 montre que pour la transmission d'un paquet, le réseau sans prédiction (courbe bleue, continue et discontinue) nécessite 24,23 % plus d'intervalles de temps que les réseaux avec prédiction (courbes continues et discontinues vertes, rouges et jaunes). On remarque que pour un paquet de $100 kbit$, le réseau sans prédictions (courbe continue bleue) nécessite plus de temps de transmission avec l'augmentation de la capacité maximale de la batterie. Ceci peut être expliqué par le fait que le débit du réseau est assez élevé pour ne pas laisser le temps aux batteries de se recharger suffisamment pour la transmission d'un paquet de $100 kbit$. Les réseaux avec prédiction (courbes continues vertes, rouges et jaunes) présentent une infime augmentation du temps nécessaire à la transmission d'un paquet.

Pour la transmission d'un paquet de 50 *kbit*, l'écart des performances entre les réseaux avec et sans prédiction (courbes discontinues) est de 0.58 %. L'énergie nécessaire à la transmission n'est pas assez grande pour que l'écart des performances soit important. Lors de la transmission d'un paquet de 50 *kbit*, on remarque que les réseaux avec prédiction (courbes discontinues verte, rouge et jaune) présentent une diminution du délai avec l'augmentation de la capacité maximale de la batterie. On peut en déduire qu'une plus grande capacité de la batterie permet d'emmagasiner suffisamment d'énergie pour assurer les transmissions lorsque la récolte de l'énergie solaire est suffisamment rapide par rapport au débit de transmission d'un paquet de 50 *kbit*.

5.4. Conclusion

Dans ce chapitre, nous avons présenté les résultats de simulations de prédiction et de l'application de la prédiction de la quantité d'énergie du prochain nœud à un RCSF-RE. Nous avons fait varier quelques paramètres du réseau afin d'étudier l'effet de cette prédiction sur les performances du réseau selon plusieurs métriques. Ces résultats ont démontré qu'un système de communication basé sur la prédiction présente de meilleures performances en matière de fiabilité de transmission, d'économie d'énergie et de gain de temps comparé à un système sans prédiction. Ces résultats pourraient être aussi des recommandations aux concepteurs de RCSF-RE.

CONCLUSION GÉNÉRALE

Dans ce mémoire, nous étudions l'effet de la prédiction des quantités d'énergie des prochains nœuds sur les performances des réseaux de capteurs sans fil à récolte d'énergie. En premier lieu, nous effectuons une présentation des réseaux de capteurs sans fil à récolte d'énergie, les différents composants d'un nœud, leurs domaines d'application ainsi que les exigences liées à leur exploitation. Ensuite, nous définissons les principaux défis rencontrés dans la gestion énergétique des réseaux de capteurs sans fil. Les problèmes qui altèrent les performances de ces réseaux de capteurs sont principalement liés à une consommation excessive de l'énergie récoltée due à des transmissions infructueuses entre différents nœuds du réseau. Cette surconsommation a pu être réduite en prédisant l'état énergétique des nœuds potentiellement récepteurs. Notre contribution est de proposer et d'évaluer des solutions pour améliorer la gestion de l'énergie dans les RCSF-RE. Nous apportons une nouvelle approche à la prédiction de l'énergie dans les réseaux de capteurs sans fil avec récolte d'énergie en utilisant des algorithmes issus de l'apprentissage profond. Ces algorithmes sont, le modèle LSTM (Long Short-Term Memory), le modèle *Transformer* et le modèle N-BEATS (Neural Basis Expansion Analysis For Time Series). Ces algorithmes issus de l'apprentissage automatique apportent l'avantage de résoudre des problèmes inhérents aux modèles antérieurs tels que les coefficients de pondération et la taille de la mémoire. Nous évaluons et comparons leurs performances de prédiction aux performances des modèles utilisés traditionnellement pour les RCSF-RE. Nous concevons également un modèle de RCSF-RE et établissons un processus de communication représentatif de la dynamique d'un réseau de capteurs opérationnels. Nous évaluons les performances de ce modèle sans prédiction en utilisant comme métriques le rapport entre le nombre de paquets arrivés au puits et le nombre de paquets émit par le premier nœud, et le nombre

d'intervalles de temps nécessaire pour la transmission d'un paquet de données. Nous évaluons également selon les mêmes métriques l'impact de ces algorithmes de prédiction sur les performances du modèle du réseau conçu en faisant varier plusieurs de ces paramètres.

Dans la seconde partie de ce document, nous présentons l'état de l'art de la prédiction dans les réseaux de capteurs sans fil à récolte d'énergie. Ensuite, nous présentons le modèle du RCSF-RE que nous considérons afin d'observer l'effet de la prédiction sur ses performances. Nous présentons également les algorithmes issus de l'apprentissage profond que nous avons utilisé pour faire la prédiction des quantités d'énergie des prochains nœuds. Puis, nous définissons le processus de communication pour mettre en pratique la prédiction de l'énergie des prochains nœuds au modèle du réseau de capteurs.

La dernière partie comporte une présentation des procédures d'entraînement des modèles de prédiction, les résultats de simulation ainsi qu'une comparaison entre ces différents algorithmes de prédiction. Nous remarquons la supériorité des algorithmes issus de l'apprentissage automatique en matière de précision des prédictions. Nous simulons le processus de communication basé sur la prédiction de l'énergie des prochains nœuds et étudions l'impact de l'utilisation de cette prédiction sur les performances du réseau. Les performances élevées de ces algorithmes de prédiction en matière de précision démontrent une amélioration importante des performances du réseau de capteurs sans fil en temps d'exécution, en économie d'énergie et en robustesse. Les résultats obtenus permettent aux concepteurs de RCSF-RE de concevoir des réseaux avec des stratégies d'allocation d'énergie et de routage plus performantes et permettent une économie d'énergie plus conséquente que celle obtenue par d'anciens modèles de prédiction.

Travaux futurs :

De multiples recherches peuvent découler de l'étude faite dans ce travail, notamment l'incorporation de nœuds mobiles au réseau considéré peut être envisagée. La prédiction de l'emplacement de ces nœuds ainsi que de leurs niveaux d'énergie peut être une ligne de recherche à part entière. Un canal de communication présentant des fluctuations plus importantes peut être considéré comme une variable à prédire. Considérer un réseau contenant un nombre variable de nœuds avec des séquences asynchrones d'allumages et d'extinctions des différents nœuds du réseau et la prédiction de collisions pour les réseaux à trafic dense seraient des sujets de recherche au fait des enjeux actuels.

RÉFÉRENCES

- K. Almi'ani, A. Viglas and L. Libman, (2010). *Energy-efficient data gathering with tour length-constrained mobile elements in wireless sensor networks*, Proc. - Conf. Local Comput. Networks LCN, pp. 582-589.
- M. Al-Omary, K. Hassini, A. Fakhfakh and O. Kanoun (2019). *Prediction of Energy in Solar Powered Wireless Sensors Using Artificial Neural Network*. 16th International Multi-Conference on Systems, Signals & Devices (SSD), Istanbul, Turkey.
- S. Aram, L. Mesin and E. Pasero. (2014) *Improving lifetime in wireless sensor networks using neural data prediction*. World Symposium on Computer Applications & Research (WSCAR), Sousse, Tunisia.
- A. Cammarano, C. Petrioli, and D. Spenza. (2012, octobre). *Pro-Energy: A novel energy prediction model for solar and wind energyharvesting wireless sensor networks*. in Proceedings of the 9th IEEE International Conference on Mobile Ad-Hoc and Sensor Systems (MASS '12), pp. 75–83, USA.
- A. Cammarano, C. Petrioli, and D. Spenza. (2013, novembre). *Poster abstract: Improving energy predictions in EH-WSNs with pro-energy-VLT*. in Proceedings of the 11th ACM Conference on Embedded Networked Sensor Systems (SenSys '13).
- Cox, D.R. (1961). *Prediction by Exponentially Weighted Moving Averages and Related Methods*. Journal of the Royal Statistical Society: Series B (Methodological).
- Ibrahima Diane. (2014). *Optimisation de la consommation d'énergie par la prise en compte de la redondance de mesure dans les réseaux de capteurs*. Thèse de doctorat de l'université de Toulouse.
- Oussama Drissi. (2014). *Implémentation d'une stratégie de routage multi-niveau de données d'un réseau de capteurs sans fil dans le domaine ferroviaire*. Thèse de maitrise de l'université du Québec à Trois-Rivières.
- H. Geng, Y. Liang, F. Yang, L. Xu and Q. Pan. (2016). *Model-reduced fault detection for multi-rate sensor fusion with unknown inputs*. Inf. Fusion, vol. 33, pp. 1-14.

- M. F. Ghuman, A. Iqbal, H. K. Qureshi, and M. Lestas. (2015). *Asim: Solar energy availability model for wireless sensor networks*. in Proceedings of the 3rd International Workshop on Energy Harvesting Energy Neutral Sensing Systems, pp. 21–26.
- Glorot Xavier. (2014, février). *Apprentissage des réseaux de neurones profonds et applications en traitement automatique de la langue naturelle*. Thèse présentée à la Faculté des arts et des sciences de l'Université de Montréal en vue de l'obtention du grade de Philosophiæ Doctor en informatique.
- Pierre Guillou. (2020, février). *NLP & Fastai, Transformer Model*. https://medium.com/@pierre_guillou/nlp-fastai-transformer-model-8a28b40f6da
- M. Hassan and A. Bermak. (2012). *Solar Harvested energy prediction algorithm for wireless sensors*. 4th Asia Symposium on Quality Electronic Design (ASQED), Penang, Malaysia, pp. 178-181.
- W. Ji, C. K. Chan, J. W. Loh, F. H. Choo, and L. H. Chen. (2009, décembre). *Solar radiation prediction using statistical approaches*. in Proceedings of the 7th International Conference on Information, Communications and Signal Processing (ICICS '09).
- P. S. Katkar and V. R. Ghorpade. (2016). *Fuzzy approach to predict mobility and energy to prolong the life of Wireless sensor network*. IEEE International WIE Conference on Electrical and Computer Engineering (WIECON-ECE), Pune, pp. 12-15.
- R. Kaur, J. Kaur Sandhu and L. Sapra. (2020). *Machine Learning Technique for Wireless Sensor Networks*. Sixth International Conference on Parallel, Distributed and Grid Computing (PDGC), Wagnaghat, India.
- Seyed Mehran Kazemi, Rishab Goel, Sepehr Eghbali, Janahan Ramanan, Jaspreet Sahota, Sanjay Thakur, Stella Wu, Cathal Smyth, Pascal Poupard et Marcus Brubaker. (2020). *Time2Vec: Learning A Vector Representation Of Time*. In proceeding the conference paper at ICLR 2020.
- F. Khan, S. Memon and S. H. Jokhio. (2016). *Support vector machine based energy aware routing in wireless sensor networks*. 2nd International Conference on Robotics and Artificial Intelligence (ICRAI), Rawalpindi, Pakistan.
- S. Kosunalp. (2016, décembre). *A Performance Evaluation of Solar Energy Prediction Approaches for Energy-Harvesting Wireless Sensor Networks*. International

Journal of Applied Mathematics Electronics and Computers, no. Special Issue-1, pp. 424-427.

- S. Kosunalp (2016). *A New Energy Prediction Algorithm for Energy-Harvesting Wireless Sensor Networks With Q-Learning*. in IEEE Access, vol. 4, pp. 5755-5763.
- Kosunalp, Selahattin. (2017). *An Energy Prediction Algorithm for Wind-Powered Wireless Sensor Networks with Energy Harvesting*. Proceedings of the ICE - Energy 139(2)
- T. N. Le, O. Sentieys, O. Berder, A. Pegatoquet and C. Belleudy. (2013). *Adaptive Filter for Energy Predictor in Energy Harvesting Wireless Sensor Networks*. 26th International Conference on Architecture of Computing Systems, Prague, Czech Republic.
- M. H. Lee and Y. H. Choi. (2008). *Fault detection of wireless sensor networks*. Computer Communications, Volume 31, Issue 14, Pages 3469-3475, ISSN 0140-3664.
- Y. Li, Z. Jia and X. Li. (2014, novembre). *Task Scheduling Based on Weather Forecast in Energy Harvesting Sensor Systems*. in IEEE Sensors Journal, vol. 14, no. 11, pp. 3763-3765.
- Mughal, Muhammad & Qureshi, Hassaan & Saleem, Umber & Saleem, Muhammad & Pitsillides, Andreas & Lestas, Marios. (2017). *Harvested Energy Prediction Schemes for Wireless Sensor Networks: Performance Evaluation and Enhancements*. Wireless Communications and Mobile Computing. 2017.1-14.
- P. Ongsulee. (2017). *Artificial Intelligence, Machine Learning and Deep Learning*. 2017 15th International Conference on ICT and Knowledge Engineering (ICT&KE), 2017, pp. 1-6, doi: 10.1109/ICTKE.2017.8259629.
- Oreshkin, Boris & Carpo, Dmitri & Chapados, Nicolas & Bengio, Yoshua. (2019). *N-BEATS: Neural basis expansion analysis for interpretable time series forecasting*. Published as a conference paper at ICLR 2020
- D. Praveen Kumar, T. Amgoth and C. S. R. Annavarapu. (2019). *Machine learning algorithms for wireless sensor networks: A survey*, Inf. Fusion, vol. 49, pp. 1-25.
- H. Ren, J. Guo, L. Sun and C. Han. (2018). *Prediction Algorithm Based on Weather Forecast for Energy-Harvesting Wireless Sensor Networks*. 17th IEEE International Conference On Trust, Security And Privacy In Computing And

Communications/ 12th IEEE International Conference On Big Data Science And Engineering (TrustCom/BigDataSE), New York, NY, USA, pp. 1785-1790.

- K. Saidi, W. Ajib and M. Boukadoum (2016). *Adaptive transmitter load size using receiver harvested energy prediction by Kalman filter*. 10th International Symposium on Communication Systems, Networks and Digital Signal Processing (CSNDSP), Prague, Czech Republic, pp. 1-5.
- J. Schmidt. (2020, juillet). *Stock predictions with state-of-the-art Transformer and Time Embeddings*. <https://towardsdatascience.com/stock-predictions-with-state-of-the-art-transformer-and-time-embeddings-3a4485237de6>
- A. Seyedi and B. Sikdar. (2008). *Modeling and analysis of energy harvesting nodes in wireless sensor networks*. in Communication, Control, and Computing, 46th Annual Allerton Conference on, pp. 67–71, IEEE.
- A. Shamshad, M. Bawadi, W. W. Hussin, T. Majid, and S. Sanusi. (2005). *First and second order markov chain models for synthetic generation of wind speed time series*. Energy, vol. 30, no. 5, pp. 693–708, 2005
- A. E. Susu, A. Acquaviva, D. Atienza and G. De Micheli. (2008). *Stochastic modeling and analysis for environmentally powered wireless sensor nodes*. 6th International Symposium on Modeling and Optimization in Mobile, Ad Hoc, and Wireless Networks and Workshops, Berlin, Germany, pp. 125-134.
- J. Ventura and K. Chowdhury. (2011). *Markov modeling of energy harvesting body sensor networks*. in Personal Indoor and Mobile Radio Communications (PIMRC) IEEE 22nd International Symposium on, pp. 2168–2172.
- C. B. Vinutha, N. Nalini and B. S. Veeresh. (2017). *Energy efficient wireless sensor network using neural network based smart sampling and reliable routing protocol*. International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET), Chennai, India, pp. 2081-2085.
- S. Hochreiter and J. Schmidhuber, *Long Short-Term Memory*, in Neural Computation, vol. 9, no. 8, pp. 1735-1780, 15 Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
- Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser, Illia Polosukhin, *Attention Is All You Need*, 2017.
- Raimi Karim, (2019, janvier). *Counting No. of Parameters in Deep Learning Models by Hand*. <https://towardsdatascience.com/counting-no-of-parameters-in-deep-learning-models-by-hand-8f1716241889>.