

ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
UNIVERSITÉ DU QUÉBEC

MÉMOIRE PRÉSENTÉ À
L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

COMME EXIGENCE PARTIELLE
À L'OBTENTION DE LA
MAÎTRISE EN GÉNIE MÉCANIQUE
M.Ing.

PAR
CHLYAH, Badr

LA PRÉDICTION STATIQUE ET DYNAMIQUE DES BESOINS ÉNERGÉTIQUES
D'UN BÂTIMENT EN UTILISANT LES RÉSEAUX DE NEURONES ARTIFICIELS

MONTRÉAL, LE 17 JUIN 2008

© Chlyah Badr, 2008

CE MÉMOIRE A ÉTÉ ÉVALUÉ
PAR UN JURY COMPOSÉ DE :

M. Hugues Rivard, directeur de mémoire
Génie de la construction à l'École de technologie supérieure

M. Stanislaw Kajl, codirecteur de mémoire
Génie mécanique à l'École de technologie supérieure

M. Stéphane Hallé, président du jury
Génie mécanique à l'École de technologie supérieure

M. Radu Zmeureanu, examinateur externe
Génie du bâtiment à l'Université Concordia

IL A FAIT L'OBJET D'UNE SOUTENANCE DEVANT JURY ET PUBLIC

LE 29 AVRIL 2008

À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

REMERCIEMENTS

Je tiens à remercier mes directeurs de recherche M. Hugues Rivard et M. Stanislaw Kajl pour la confiance qu'ils m'ont accordée et de m'avoir guidé et donner le soutien technique et moral pour réaliser cette étude. Je tiens également à remercier M. Stéphane Hallé et M. Radu Zmeureanu d'avoir accepter de juger ce mémoire. J'aimerais adresser des remerciements particuliers à M. Javier Beltrand, directeur du service d'équipement, de m'avoir donner le support technique et me fournir toutes les données nécessaires pour réaliser cette étude durant ce projet ainsi que le soutien de la chaire de recherche du Canada en ingénierie assistée par ordinateur pour la conception de bâtiment durable.

Finalement, je dédie ce travail à mes parents qui représentent tout dans ma vie et dont leur dévouement, leurs sacrifices et leurs encouragement, ainsi je tiens à remercier tous les membres de ma famille et mes amis pour leur soutien moral sans lesquels ce mémoire n'aurait jamais vu le jour.

LA PRÉDICTION STATIQUE ET DYNAMIQUE DES BESOINS ÉNERGÉTIQUES D'UN BÂTIMENT EN UTILISANT LES RÉSEAUX DE NEURONES ARTIFICIELS

CHLYAH, Badr

RÉSUMÉ

Plusieurs études présentées dans la littérature essayent de trouver des nouvelles ou d'améliorer des anciennes approches pour estimer et prédire les besoins énergétiques du bâtiment.

Ce mémoire présente les résultats du développement d'un système de prédition pour les prochaines heures des besoins énergétiques appliqué pour le bâtiment de l'École de technologie supérieure (ETS). L'étude est basée sur l'application des techniques des réseaux de neurones artificiels (RNA) pour concevoir et développer le système de prédition. Des bases de données simulées et réelles sont utilisées pour l'apprentissage du réseau et contiennent les valeurs horaires des variables d'entrées nécessaires pour la prédition (températures, humidité, données de temps, charges,...).

Le travail englobe :

- l'analyse des données pour choisir les variables les plus pertinentes, améliorer le rendement et minimiser le bruit.
- la conception du modèle pour trouver l'architecture RNA la plus adaptée au bâtiment en étude, type de réseau, nombre de couches cachées, nombre de neurones, type de fonction de transfert,...
- adopter l'aspect dynamique des réseaux neurones pour ce type de prédition, en développant deux modèles de prédition dynamique : le premier avec une base d'adaptation cumulative et le deuxième à fenêtre glissante.
- le développement et la validation du modèle.

Cette étude a permis de prouver le potentiel des RNA dans le domaine de la prédition en ligne des besoins énergétiques du bâtiment, étant donné que les coefficients de variances (CV) obtenus pour les différentes simulations sont de l'ordre de 8 à 21 %. Aussi, l'étude a révélé quelques problèmes de prédition : par exemple au niveau du démarrage du refroidisseur de l'École.

THE STATIC AND DYNAMIC PREDICTION OF THE ENERGY NEEDS OF A BUILDING USING ARTIFICIAL NEURAL NETWORKS

CHLYAH, Badr

ABSTRACT

Various studies presented in the literature attempted to find new approaches or improve existing approaches for predicting or estimating the energy needs of a building.

This research presents the results obtained through the development of a prediction system for the future hourly energy needs applied to one of the École de technologie supérieure (ÉTS) buildings. This study is based on the application of neural network techniques (NN) for the design and development of a prediction system. Real and simulated databases were used for the development of the neural network. The databases contained hourly values required for the prediction (e.g., temperature, humidity, time data, loads, etc.).

The following tasks were performed:

- Data analysis of various variables in order to pick the most relevant ones, improve the output and minimize the noise.
- Design of a model in order to find the most suitable NN architecture for the studied building, the type of neural network needed the number of hidden layers, the number of neurons needed, the type of transfer function used, etc.
- Development of two dynamic models by adapting the neural network for dynamic prediction. One model had a cumulative base; the second model used a sliding window.
- The development and validation of the model.

The obtained variant coefficients (CV) for the different simulations ranged from 8 - 21%, proving the true potential of using NN in the domain of online prediction for the energy needs of a building. Also, this study has revealed certain problems with this type of prediction such as with the start up of the ETS chiller.

TABLE DES MATIÈRES

| | Page |
|---|------|
| LA PRÉDICTION STATIQUE ET DYNAMIQUE DES BESOINS ÉNERGÉTIQUES D'UN BÂTIMENT EN UTILISANT LES RÉSEAUX DE NEURONES ARTIFICIELS ... IV | |
| INTRODUCTION | 1 |
| CHAPITRE 1 BUT ET MÉTHODOLOGIE | 7 |
| CHAPITRE 2 REVUE DE LITTÉRATURE | 9 |
| 2.1 Modèle de régression | 10 |
| 2.1.1 Modèle de régression simple | 11 |
| 2.1.2 Modèle de régression multivariable..... | 12 |
| 2.2 Modèle de séries de temps | 14 |
| 2.2.1 Modèle Autorégressif (AR) | 14 |
| 2.2.2 Modèles autorégressifs de la moyenne mobile (ARMA) | 15 |
| 2.2.3 Modèles autorégressifs intégraux de la moyenne mobile (ARIMA) | 16 |
| 2.2.4 Modèles autorégressifs de la moyenne mobile avec entrée exogène ARMAX..... | 16 |
| 2.2.5 Modèle des séries de Fourier | 17 |
| 2.3 Réseaux de neurones artificiels..... | 19 |
| 2.4 Les résultats des deux concours de la prédition d'énergie (Shootout I et II) | 37 |
| 2.5 Conclusion | 39 |
| CHAPITRE 3 Les réseaux de neurones artificiels pour la prédition de la consommation énergétique du bâtiment..... | 41 |
| 3.1 Caractéristiques générales..... | 41 |
| 3.2 Les entrées pertinentes | 43 |
| 3.3 Fonctionnement du neurone artificiel | 44 |
| 3.4 L'apprentissage du réseau de neurones..... | 47 |
| 3.5 Ajustement des poids synaptiques | 48 |
| 3.6 Règles d'apprentissage des réseaux de neurones..... | 49 |
| 3.7 Le mode incrémental des réseaux de neurones..... | 51 |
| CHAPITRE 4 Prédiction de la charge électrique du refroidisseur de l'ÉTS baséE sur des données simulées | 53 |
| 4.1 Sélection des données d'entrée avec l'ACP..... | 53 |
| 4.2 Étude préliminaire avec un modèle de régressions multivariables | 59 |
| 4.3 Types de données choisies pour la prédition..... | 62 |
| 4.4 La répartition de la base de données simulée..... | 63 |
| 4.5 Prédiction première par la régression multilinéaire (MLR)..... | 63 |

| | | |
|---|--|-----|
| 4.6 | Prédiction statique via les réseaux neurones artificiels..... | 67 |
| 4.6.1 | Choix du modèle | 67 |
| 4.6.2 | La normalisation des données | 69 |
| 4.6.3 | La formation et le test du modèle statique | 69 |
| 4.6.4 | Résultats et comparaison..... | 75 |
| 4.7 | La prédiction en ligne de la charge basée sur un modèle dynamique des RNA | 76 |
| 4.8 | Sommaire | 86 |
| CHAPITRE 5 Prédiction de la charge électrique totale et de la charge de la réfrigération basée sur des données réelles | | 88 |
| 5.1 | Traitements des données réelles | 88 |
| 5.2 | Apprentissage et adaptation du réseau | 89 |
| 5.3 | Prédiction en ligne de la charge totale de l'école | 90 |
| 5.4 | Prédiction en ligne de la charge totale avec l'ajout du type de jour | 96 |
| 5.5 | La prédiction en ligne de la charge électrique du refroidisseur | 97 |
| 5.6 | Prédiction des charges juste pour les heures de démarrage du refroidisseur..... | 101 |
| 5.7 | Méthode de prédiction simplifiée des charges électriques pour les heures du démarrage (de 6h à 10h) | 104 |
| 5.7.1 | L'apprentissage avec une seule prédiction simplifiée | 105 |
| 5.7.2 | L'apprentissage avec multi prédiction simplifiée | 106 |
| 5.7.3 | Résultats obtenus avec la correction des charges et l'indice de mois | 108 |
| 5.8 | Analyse du CV de la prédiction suivant l'heure du jour..... | 110 |
| 5.9 | L'effet de la variation des variables de l'entrée sur la qualité de la prédiction | 112 |
| 5.10 | Prédiction de la charge du refroidisseur avec ajout de type de jour ou suppression de la fin des semaines | 114 |
| 5.11 | Prédiction de la charge du refroidisseur sans les périodes du démarrage ou du refroidissement tardif..... | 115 |
| 5.12 | L'effet du type de jour sur le CV | 117 |
| 5.13 | Sommaire | 118 |
| CONCLUSION..... | | 121 |
| Sommaire | | 121 |
| Contributions..... | | 124 |
| Recommandations pour travaux futurs | | 125 |
| ANNEXE I Spécifications techniques pour le refroidisseur..... | | 127 |
| ANNEXE II Schéma de structure _ Listes chaînées..... | | 128 |
| ANNEXE III Distribution des charges | | 129 |
| LISTE DE RÉFÉRENCES | | 133 |

LISTE DES TABLEAUX

| | Page |
|---|------|
| Tableau 1 Comparaison entre les résultats d'une prédiction basée sur des données réelles et une prédiction basée sur des données prédites pour un modèle de RNA récurrent [17]..... | 33 |
| Tableau 2 Les méthodes des deux contestants gagnants du concours Shootout I | 37 |
| Tableau 3 Résultats des différentes expériences du concours Shootout II [21] | 39 |
| Tableau 4 Méthodes utilisées par les gagnants du concours Shootout II [21]..... | 39 |
| Tableau 5 Table de corrélation entre les différentes variables de la base de données..... | 55 |
| Tableau 6 Table des valeurs propres..... | 57 |
| Tableau 7 Table des vecteurs propres | 57 |
| Tableau 8 Résultats des simulations de la régression multiple sans inclure la charge électrique des instants précédents | 61 |
| Tableau 9 Résultats des simulations de la régression multiple incluant la charge électrique des instants précédents | 61 |
| Tableau 10 Vecteur des coefficients pour la regression multivariable..... | 65 |
| Tableau 11 Résultats des simulations –régression multilinéaire et RNA | 75 |
| Tableau 12 Comparaison entre les RNA statiques et dynamiques -version 1-..... | 80 |
| Tableau 13 Comparaison entre les RNA statiques et dynamiques -Version 2- | 84 |
| Tableau 14 Comparaison entre la prédiction avec la régression multilinéaire et les RNA statique | 86 |
| Tableau 15 Comparaison entre différents types de RNA basé sur des données simulées | 87 |
| Tableau 16 Résultats des simulations pour la consommation électrique totale de l'ÉTS | 94 |
| Tableau 17 Résultats de la prédiction en tenant compte du type de jour..... | 96 |
| Tableau 18 Les résultats de la prédiction en ligne de la charge du refroidisseur | 99 |

| | | |
|------------|---|-----|
| Tableau 19 | Table de prédiction simplifiée de la consommation (E) selon la température et les heures du démarrage en kW | 104 |
| Tableau 20 | Les CV obtenus pour différents types de simulation | 109 |
| Tableau 21 | Tableau des coefficients de variances pour chaque heure du jour..... | 111 |
| Tableau 22 | Résultats de l'effet de la variation des variables d'entrée sur la prédiction..... | 113 |
| Tableau 23 | Résultats de la prédiction avec type de jour ou sans les jours de fin de semaine . | 115 |
| Tableau 24 | Comparaison entre la prédiction partielle (9h-19h) et la prédiction pour toute la journée | 116 |
| Tableau 25 | L'influence du type de jour sur la qualité de la prédiction | 117 |
| Tableau 26 | Résultats des simulations pour l'appel de puissance totale de l'ÉTS | 119 |
| Tableau 27 | Résultats des simulations pour la charge électrique du refroidisseur de l'ÉTS | 120 |

LISTE DES FIGURES

| | Page |
|---|------|
| Figure 1 <i>Schéma des pavillons A et B.</i> | 4 |
| Figure 2 <i>Structure générale de modèle de prédiction proposé par Zamarreno.</i> | 24 |
| Figure 3 <i>Architecture de base pour un réseau de neurones artificiels non bouclés.</i> | 45 |
| Figure 4 <i>Architecture du fonctionnement d'un neurone artificiel.</i> | 45 |
| Figure 5 <i>Fonction d'activation sigmoïde.</i> | 46 |
| Figure 6 <i>Schéma général pour l'apprentissage des poids synaptiques.</i> | 49 |
| Figure 7 <i>La corrélation entre la consommation électrique du refroidisseur et les variables d'entrée.</i> | 56 |
| Figure 8 <i>La projection de l'ancien repère sur les nouveaux axes.</i> | 58 |
| Figure 9 <i>Schéma de distribution de la population.</i> | 58 |
| Figure 10 <i>Comparaison entre les charges réelles et les charges prédictes par la régression multilinéaire.</i> | 66 |
| Figure 11 <i>Agrandissement de la figure 10 sur la période de 800 à 900 heures.</i> | 66 |
| Figure 12 <i>L'architecture utilisée pour la formation du RNA.</i> | 67 |
| Figure 13 <i>La performance par rapport au nombre d'époques.</i> | 70 |
| Figure 14 <i>Comparaison entre la cible et le rendement du RNA durant l'apprentissage.</i> | 71 |
| Figure 15 <i>La différence entre la cible et le rendement du RNA durant l'apprentissage.</i> | 72 |
| Figure 16 <i>La finesse de la prédiction statique avec les données de validation pour les RNA.</i> | 73 |
| Figure 17 <i>Comparaison entre les charges réelles et les charges prédictes par un RNA statique avec les données de validation.</i> | 74 |
| Figure 18 <i>Agrandissement de la figure 17 entre les heures 800 et 900.</i> | 75 |
| Figure 19 <i>Principe du fonctionnement de la fenêtre glissante.</i> | 77 |

| | | |
|-----------|---|------|
| Figure 20 | <i>Processus du fonctionnement du mode dynamique de la prédition avec les RNA.</i> | .78 |
| Figure 21 | <i>Finesse de la prédition en tenant compte de l'adaptation – version N1 (à fenêtre glissante).</i> | 80 |
| Figure 22 | <i>Qualité de la prédition dynamique avec version N1 et données simulées (Demande électrique vs Heures).</i> | 82 |
| Figure 23 | <i>Finesse de la prédition en tenant compte de l'adaptation –Version N2-.</i> | 84 |
| Figure 24 | <i>Qualité de la prédition dynamique avec version N2 et données simulées (Demande électrique vs Heures).</i> | 85 |
| Figure 25 | <i>Itération de l'apprentissage du réseau de neurones avec les données réelles.</i> | 90 |
| Figure 26 | <i>Comparaison entre la cible et le rendement du RNA durant l'apprentissage sur la période 2004.</i> | 91 |
| Figure 27 | <i>Agrandissement de la figure 26 sur un intervalle de trois jours.</i> | 91 |
| Figure 28 | <i>L'erreur entre la cible désirée et le rendement du RNA durant l'apprentissage (2004).</i> | 92 |
| Figure 29 | <i>La finesse de la prédition statique basée sur les données de validation 2005.</i> | 93 |
| Figure 30 | <i>La finesse de la prédition dynamique basée sur les données de validation 2005.</i> | .93 |
| Figure 31 | <i>Comparaison entre les données réelles et les valeurs prédites par le RNA avec adaptation à fenêtre glissante (données de validation 2005).</i> | 95 |
| Figure 32 | <i>Vue agrandie pour la figure 31 entre les heures 1015 et 1095.</i> | 95 |
| Figure 33 | <i>Distribution de l'appel de puissance électrique totale par rapport au type de jour.</i> | 97 |
| Figure 34 | <i>Evolution de l'apprentissage du réseau neurone.</i> | 98 |
| Figure 35 | <i>La finesse de la prédition basée sur les données de validation 2005 du refroidisseur.</i> | 99 |
| Figure 36 | <i>Comparaison des charges réelles et des charges prédites pour le refroidisseur avec un RNA dynamique à fenêtre glissante.</i> | 100 |
| Figure 37 | <i>Agrandissement de la comparaison sur un intervalle de 4 jours.</i> | 100 |
| Figure 38 | <i>Les prédictions de la charge du refroidisseur à 6h du matin pour une $T > 14^{\circ}\text{C}$.</i> | .102 |

| | | |
|-----------|--|-----|
| Figure 39 | <i>Les prédictions de la charge du refroidisseur à 7h du matin pour une $T > 14^{\circ}\text{C}$.</i> | 102 |
| Figure 40 | <i>Le profil de la charge du refroidisseur en fonction de la température sèche pour les années 2004 et 2005.....</i> | 103 |
| Figure 41 | <i>Corrélation entre la température et la charge électrique corrigée pour un démarrage à 7h ou 9h.</i> | 105 |
| Figure 42 | <i>La distribution des charges du refroidisseur avec une seule correction à 8h00....</i> | 106 |
| Figure 43 | <i>Distribution des charges du refroidisseur avec multiples prédictions simplifiées à 7h00.....</i> | 107 |
| Figure 44 | <i>Les étapes de la prédiction dans le cas de la correction des charges de démarrage.</i> | 108 |
| Figure 45 | <i>Distribution des charges en fonction des températures ($^{\circ}\text{C}$) pour 15h00.</i> | 110 |
| Figure 46 | <i>Distribution des CV en fonction de l'heure du jour sans aucune correction.</i> | 111 |
| Figure 47 | <i>Distribution des CV en fonction de l'heure du jour avec multi correction.</i> | 112 |
| Figure 48 | <i>Réseau incluant 2 températures et 6 charges antérieures.....</i> | 113 |
| Figure 49 | <i>Réseau incluant 6 températures et 2 charges antérieures.....</i> | 114 |

LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

| | |
|------------------|---|
| AR : | Auto régressif |
| ARMA : | Auto régressive de moyenne mobile (<i>Autoregressive moving average</i>) |
| ARIMA : | Auto régressif intégral de moyenne mobile (<i>Autoregressive integral moving average</i>) |
| ARMAX | Auto régressive de moyenne mobile avec entrée exogène |
| ACP : | Analyse en composantes principales |
| CV : | Coefficient de variance |
| CVAC : | Chauffage, ventilation et air conditionné |
| ÉTS : | École de technologie supérieure |
| MLR : | Multi linéaire régression |
| MBE : | Erreur moyenne par différence |
| MA : | Moyenne mobile |
| MSE : | Erreurs moyennes carrées |
| MLP : | Multi layer perceptron |
| RMSE : | Erreur quadratique moyenne (<i>Root-mean-square-error</i>) |
| R ² : | Erreur moyenne |
| RNA : | Réseaux de neurones artificiels |

INTRODUCTION

Durant les dernières décennies, un des principaux objectifs de la société a été l'amélioration de l'efficacité énergétique des bâtiments. C'est dans ce but que des nouvelles technologies ont été mises au point et que des nouvelles méthodes de prédition et d'analyse énergétique fiables et efficaces ont été développées pour permettre de réduire la consommation énergétique des bâtiments.

L'optimisation de la consommation énergétique des bâtiments commerciaux exigée par le plan de développement durable du Québec, le bon fonctionnement des systèmes de CVAC et la protection contre les pénuries sont des problématiques de recherche dans le domaine de l'efficacité énergétique du bâtiment. L'importance de la prédition des besoins énergétiques sur l'économie et la bonne gestion de l'énergie des bâtiments ont mené plusieurs chercheurs à développer des techniques et modèles mathématiques ainsi que numériques avec des potentiels intéressants. En se basant sur les résultats provenant des études précédentes, ce mémoire propose une approche pour prédire les besoins énergétiques du bâtiment pour les prochaines heures.

Plus précisément, le but de ce projet est de développer un modèle pour la prédition en ligne des besoins énergétiques des bâtiments commerciaux et institutionnels en se basant sur l'historique de la consommation énergétique du bâtiment. Le modèle est évalué avec la prédition de la consommation électrique totale et la consommation du refroidisseur de l'École de technologie supérieure de Montréal (ÉTS) pour la période de l'été.

Cette étude a débuté avec la récapitulation et la mise en valeur des modèles existants de prédition provenant de la littérature, et pour lesquels on a proposé une variété de modèles testés et validés sur diverses catégories de bâtiment. Plusieurs articles trouvés dans la littérature expliquent et développent les différentes méthodes utilisées dans le domaine de la prédition des besoins énergétique de différents types de bâtiment. La plupart des modèles

proposés sont mathématiques comme les séries de Fourier, la régression linéaire ou multilinéaire.

La reproduction de l'intelligence humaine représente le but de la recherche en intelligence artificielle. Plusieurs modèles et processus ont été conçus à cette fin. Ces modèles permettent souvent de résoudre plusieurs problèmes dans différents domaines en simulant des processus de raisonnement du cerveau humain. Chaque modèle de l'intelligence artificielle contient des points forts, mais aussi des points faibles. La réalisation d'un système de prédiction des besoins énergétiques basé sur les réseaux de neurones artificiels (RNA) est une approche qui permet de combiner la mécanique du bâtiment, la puissance de l'informatique et le processus de raisonnement du cerveau humain, ceci dans le but d'obtenir des résultats plus performants avec une moindre incidence mathématique ou physique. Cette approche tient à mettre en valeur l'importance des RNA avec la capacité additionnelle de s'adapter et d'acquérir des nouvelles connaissances par une mise à jour continue du système de prédiction pour ainsi le faire évoluer dans le temps.

Les réseaux de neurones artificiels représentent des circuits composés de petites unités de calcul interconnectées pour résoudre des problèmes avec des méthodes inspirées du système nerveux humain. Au début ces derniers ont été surtout appliqués pour l'identification et la classification des modèles. Mais par la suite ils ont démontré leur aptitude à réaliser des régressions non linéaires et aussi à faire des prédictions. C'est dans ce rôle qu'ils ont du potentiel dans des applications liées à la mécanique de bâtiment.

Dans ce mémoire on présente la recherche et le développement d'un modèle pour la prédiction des besoins énergétiques pour les prochaines heures en utilisant les réseaux de neurones artificiels (RNA). La conception d'un modèle statique de prédiction est celui qui est le plus fréquent dans la littérature, pourtant il s'avère être nécessaire de mettre en œuvre un modèle de prédiction dynamique (incrémentale), qui s'adapte à chaque mise à jour de la base de données du système de contrôle du bâtiment. Le modèle dynamique doit être conçu

de façon à inclure un processus d'apprentissage automatique pour l'acquisition et l'apprentissage incrémentale des nouvelles données plus récentes. Le système a été développé et testé sur l'un des bâtiments de l'École de technologie supérieure à Montréal, en utilisant des données simulées et réelles.

Les articles trouvés dans la littérature donnent des indications pour le choix des caractéristiques générales des RNA, de leur mode de fonctionnement, de l'architecture et du type d'apprentissage pour développer un modèle convenant à ce cas d'étude. Le logiciel commercial Matlab est utilisé pour implémenter le RNA dans cette étude. Malgré l'utilisation d'un logiciel commercial, la sélection des paramètres pour la formation, l'apprentissage et l'architecture doivent être définies avec soins comme le choix des performances et les variables d'entrées et sorties. Ainsi, il est important de bien maîtriser le phénomène à modéliser.

Description du bâtiment de l'ÉTS

L'École de technologie supérieure, composante de l'Université du Québec, a été fondée en 1974. Elle est située au coin des rues Peel et Notre-Dame ouest. Le pavillon principal **A** est opérationnel depuis 1997 et occupe l'ancienne usine d'embouteillage de la brasserie Dow, dont le bâtiment a été réaménagé. Au fil du temps, progressivement d'autres bâtiments se sont ajoutés, notamment des résidences d'étudiants, pour constituer un véritable campus.

L'ÉTS a une superficie totale de 127517 m², constituée de deux pavillons **A** (53 852 m²) et **B** (31000 m²). Le premier contient trois étages comprenant différents types de locaux (salles de classes, corridors, bibliothèques, laboratoires, administration, stationnement intérieur, etc....), le deuxième contient quatre étages contenant des salles de cours, des laboratoires et des salles de sport. (Voir figure 1 pour un plan de campus)

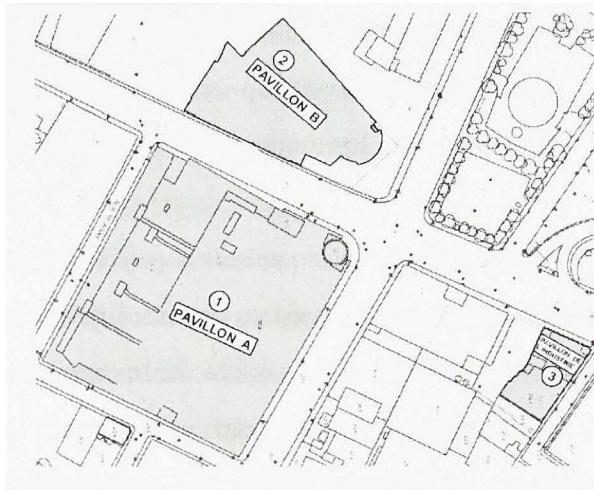


Figure 1 Schéma des pavillons A et B.

(Tiré du service de l'équipement de l'ÉTS)

Type de systèmes et locaux desservis

Le pavillon principal **A** de l'École de technologie supérieure est équipé de :

- 10 systèmes de traitement d'air à volume d'air variable (VAV) qui desservent les zones de bureaux, les salles de conférences, les corridors, les ateliers, la bibliothèque, les vestiaires, la salle à manger et les salles de cours.
- 2 systèmes 100% air neuf pour les salles mécaniques/ ateliers/ cuisine.
- des ventilateurs pour la circulation d'air neuf pour différents locaux techniques. (ateliers peinture, salles électriques, salles mécaniques)
- 4 ventilateurs d'alimentation en 100% air neuf pour les sous-sols (VA-19/20/21/22) qui alimentent les deux étages du sous-sol côté est et ouest avec des aérothermes à la vapeur au bout.

Le nouveau pavillon **B** de l'École de technologie supérieure est équipé de :

- 4 systèmes de traitement d'air à volume d'air variable (VAV), qui desservent les salles de cours, les bureaux, les corridors, les salles d'entraînement et le casse-croûte.

- 2 systèmes de traitement d'air à volume d'air constant (CAV) qui desservent en principal les salles de sport ainsi qu'une salle mécanique.
- 1 système 100% air neuf pour le restaurant et la garderie,

Suivant les séquences de contrôles assurées par le service d'équipement de l'ÉTS, les débits de soufflage des locaux sont pilotés par sondes de température et les points de consigne sont modifiés selon l'état d'occupation établi à l'aide de détecteurs de mouvement et par commande centralisée. Ce système fonctionne à partir d'une unité centrale qui assure différentes fonctions : affectation des zones nécessitant un débit de soufflage ainsi que d'éclairage à une commande ainsi que les heures d'utilisation par local ou par étage, en conformité avec l'horaire. Comme règle générale, le fonctionnement des unités de traitement de l'air (UTA) commence à 6h du matin et dure jusqu'à 23h (17 heures par jour). Pendant le week-end ou les jours fériés, le fonctionnement est de 8h le matin jusqu'à 20h du soir (12 heures par jour). Les évacuateurs sont reliés au fonctionnement des UTA, alors, si les ventilateurs des systèmes de traitement d'air arrêtent, les évacuateurs arrêtent et ils repartent au besoin seulement.

Structure du mémoire

Ce mémoire est structuré comme suit:

Le premier chapitre englobe le but de ce travail et la méthodologie utilisée pour élaborer ce mémoire. Le chapitre 2 est consacré à synthétiser ce qui a été publié dans la littérature précédemment. Il récapitule les différentes méthodes utilisées dans le domaine de la prévision et la prédiction des besoins énergétique du bâtiment, soit des méthodes statistiques, mathématiques ou des méthodes qui se basent sur l'intelligence artificielle. Une courte description de chacune des méthodes de prévision examinée est fournie pour illustrer comment ces modèles de prévision sont employés dans la pratique et le type de prévision réalisé par chaque modèle. Le chapitre présente aussi une comparaison réelle entre ces

différentes méthodes de prédiction grâce aux résultats de deux concours SHOUTOUT I et II de l'ASHRAE.

Le chapitre 3 est consacré à une description sommaire des réseaux de neurones artificiels, leurs modes de fonctionnement, le choix et le traitement des entrées pertinentes. On présente plus particulièrement le processus d'apprentissage ainsi que la justification du recours au RNA. Le chapitre élabore sur deux modes d'apprentissage : statique et dynamique.

Le chapitre 4 est consacré à l'application de l'approche sur des données simulées. Le chapitre compare au début les résultats obtenus par deux méthodes différentes (méthodes de régression multivariables et la méthode de RNA statique) sur les mêmes données de formation et de test. Par la suite, on trouvera les différents résultats de simulations faites sur des données de l'ÉTS simulées par le logiciel DOE-2, on présente aussi les différents scénarios utilisés afin de réaliser le mode incrémentale de la prédiction.

Le chapitre 5 détaille les points forts et faibles des réseaux de neurones artificiels statique et dynamique appliquées sur des données réelles d'un bâtiment de l'ÉTS pour les années 2004 et 2005. Aussi, ce chapitre fait ressortir les différents problèmes auxquels on peut être confrontés au cours du développement d'un système de prédiction et qui sont proportionnellement liées aux conditions thermiques du bâtiment et au manque de données pertinentes.

La conclusion du mémoire résume les différents résultats trouvés, ainsi que les contributions de la recherche et propose des pistes pour des développements futurs sur le sujet.

CHAPITRE 1

BUT ET MÉTHODOLOGIE

La plupart des modèles de RNA présentés dans les références bibliographiques sont basés sur des modèles de prédiction statique, dans lesquels les modèles de prévision ne font l'apprentissage qu'une seule fois avec une base de données historique statique qui ne varie pas.

Le but de ce projet est de développer un modèle pour la prédiction en ligne des besoins énergétiques des bâtiments commerciaux et institutionnels en se basant sur l'historique de la consommation énergétique du bâtiment. En particulier, essayer de développer un modèle RNA dynamique pour prédire la charge électrique totale et la charge du refroidisseur de l'École de technologie supérieure de Montréal (ÉTS). Le modèle qu'on vise à mettre au point est un modèle de RNA qui utilise une base de données dynamique qui se réactualise chaque fois que des nouvelles mesures de la charge électrique associée aux données météorologiques sont disponibles.

Le travail présenté dans ce mémoire contient quatre parties. Dans un premier temps l'on procède à une analyse bibliographique exhaustive qui récapitule les dernières recherches sur la prédiction des besoins énergétique du bâtiment. Une telle tâche s'avère être importante car elle facilitera par la suite la conceptualisation du modèle de prédiction, le choix des paramètres et sa validation.

La deuxième partie se concentre sur la compréhension générale de la technique des réseaux de neurones artificiels, leurs caractéristiques, le fonctionnement, le choix des entrées, leurs apprentissages et les modes des RNA statique et dynamique. Cette partie est la source d'inspiration dans ce développement pour le choix du modèle le mieux adapté à cette étude soit en mode statique ou dynamique.

Après avoir étudié les aspects théoriques des réseaux de neurones artificiels, l'on procède à des simulations numériques. Cette étape est subdivisée en deux phases, la première est expérimentale basée sur des données simulées. La deuxième est basée sur des données réelles.

L'étude basée sur les données simulées débute par le choix et le traitement des données. Cette étape est effectuée par une analyse des composantes principales (ACP), suivi par une étude préliminaire qui détermine le choix des entrées pertinentes dans le temps pour le modèle à concevoir. Dans cette première phase expérimentale, on compare un modèle mathématique basé sur la régression multilinéaire (MLR) et un modèle de prédiction statique basé sur les RNA pour démontrer les atouts et les inconvénients de chacun. Par la suite, on procède à la prédiction dynamique avec ces différents modes (cumulatif ou à fenêtre glissante) pour les mêmes données simulées.

La deuxième phase expérimentale basée sur les données réelles porte sur la prédiction de la charge électrique totale de l'ETS et la charge partielle du refroidisseur. Cette partie tente aussi de mettre en œuvre le mode incrémental des RNA dans la prédiction de la charge électrique totale de l'ETS tout en relevant d'autres types de problèmes pour la prédiction de la charge partiel au niveau de démarrage du refroidisseur. Différentes solutions seront proposées aux divers types de problèmes rencontrés, ceci en s'appuyant plus particulièrement sur les analyses de différents facteurs comme le coefficient de la variance (CV) ou la variation des variables d'entrées du modèle à concevoir.

CHAPITRE 2

REVUE DE LITTÉRATURE

La prévision de la consommation d'énergie d'un bâtiment est un problème complexe. La consommation d'énergie d'un bâtiment dépend de plusieurs facteurs tels que les conditions climatiques, les caractéristiques du bâtiment, et le type d'équipements utilisés pour le chauffage, la ventilation, et air conditionné (CVAC). Les données à prédire peuvent inclure une demande électrique, des charges thermiques (chauffage et refroidissement) ou la consommation d'énergie.

Dans ce chapitre, une revue de littérature est présentée afin de fournir une vue d'ensemble sur les modèles actuellement employés pour prédire la consommation et la demande d'énergie des bâtiments. Ces modèles de prédiction peuvent généralement être groupés dans trois catégories:

- 1) Modèles de régression,
- 2) Modèles de série chronologique,
- 3) Réseaux de neurones artificiels.

Chacune de ces catégories est décrite ci-dessous, avec les concepts de base de chaque modèle ainsi que ses forces et faiblesses. La façon dont chaque modèle a été employé pour faire diverses prédictions de consommation d'énergie de bâtiment est aussi présentée. L'efficacité de chaque modèle rapporté dans la littérature est également discutée.

La plupart des articles examinés dans cette étude utilisent le coefficient de variation (CV) ou l'erreur de la racine moyenne de carré (RMSE) pour mesurer l'exactitude de la prédiction. La valeur de CV et de RMSE d'une prévision sont définies comme suit:

$$CV = \frac{\sqrt{\frac{1}{N} \sum_t (y_t - \bar{y}_t)^2}}{\frac{1}{N} \sum_t y_t} \quad (2.1)$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \bar{y}_t)^2}{n}} \quad (2.2)$$

D'autres méthodes sont aussi utilisées pour définir l'exactitude des prévisions, comme le R² (l'erreur moyenne) et le MBE (l'erreur moyenne par différence):

$$R^2 = (1 - \frac{\sum_{t=1}^n (y_t - \bar{y}_t)^2}{\sum_{t=1}^n (y_t)^2}) \quad (2.3)$$

$$MBE = \frac{\frac{1}{N} \sum_{t=1}^n (y_t - \bar{y}_t)}{\frac{1}{N} \sum_{t=1}^n y_t} \quad (2.4)$$

Avec :

y_t : la valeur estimée à l'instant t .

\bar{y}_t : la valeur réelle à l'instant t .

N ou n : nombre d'entrées utilisées pour le calcul du coefficient.

2.1 Modèle de régression

L'analyse par régression est une technique qui se sert d'une fonction pour modeler un phénomène physique particulier [1]. Une variable indépendante de la fonction est souvent appelée «régresseur». La fonction elle-même s'appelle «modèle de régression». Un modèle de régression contient habituellement un certain nombre de paramètres réglables appelés des coefficients de régression. Ces coefficients sont choisis pour réduire au minimum l'erreur entre les données mesurées (réelles) et les valeurs correspondantes calculées avec le modèle

de régression. Une fois que ces paramètres sont déterminés, le modèle de régression est utilisé pour la prédiction des besoins désirés.

Des modèles de régression ont démontré leur efficacités dans la prédiction de la consommation d'énergie du bâtiment dans un certain nombre d'expériences [1] [2] [3] [4]. Les modèles de régression utilisés peuvent être classifiés dans deux catégories: le modèle de régression simple et le modèle de régression multivariable.

2.1.1 Modèle de régression simple

Un modèle de régression simple dépend seulement d'une variable qui est la température ambiante dans le cas de la prédiction des besoins énergétique du bâtiment, et est décrit en détail dans [3]. On précise que l'utilisation d'un modèle de régression à simple variable comme la température ambiante est préférable a un modèle de régression à multivariable, car la mesure de la température ambiante est plus facile et fiable que d'autres variables comme par exemple l'humidité et la radiation solaire. Aussi ce type de régression peut réduire l'influence du changement brutal des conditions météorologiques sur la consommation d'énergie du bâtiment. Un autre avantage de ce modèle à simple variable est qu'il évite les problèmes de multicolinéarité souvent présent dans les modèles de régression à multivariables. La multicolinéarité se produit quand les régresseurs sont linéairement dépendant et donc la solution à moindre carré (équation 2.5) n'est pas unique.

Les techniques disponibles pour modéliser l'énergie consommée dans les bâtiments commerciaux sont : 1-paramètre, 2-paramètres, 3-paramètres et 4-paramètres; ces modèles sont étudiés dans les articles [2] et [3].

Les auteurs ont précisé que le choix d'une fonction de régression devrait être adapté et basé sur les meilleurs des critères (réduisant au minimum l'erreur des moindres carrés) (Équation 2.5).

$$\begin{aligned}
 E_h &= \beta_{0,h} && 1\text{-P model} \\
 E_h &= \beta_{0,h} + \beta_{1,h} T && 2\text{-P model} \\
 E_h &= \beta_{0,h} + \beta_{1,h}(T - \beta_{3,h})^- + \beta_{2,h}(T - \beta_{3,h})^+ && 4\text{-P model}
 \end{aligned} \tag{2.5}$$

Avec:

β : les coefficients de la régression,

T : la température.

Les symboles $(\cdot)^-$ et $(\cdot)^+$ indiquent que ces quantités sont placées à zéro respectivement si négatives ou positif. Le model 3-P est un cas spécial de model 4-P.

Ces modèles peuvent être appropriés pour modéliser l'utilisation d'énergie dans les systèmes de volume d'air constant avec des cycles d'économiseur, et les systèmes de volume d'air variables.

2.1.2 Modèle de régression multivariable

On propose dans [4] une méthodologie pour développer les modèles multivariables de la régression linéaire (MLR). Un modèle multiple de la régression linéaire (MLR) fournit une meilleure exactitude qu'un modèle à simple variable pour modéliser la consommation d'énergie.

L'article développe d'abord la base fonctionnelle de l'utilisation de l'énergie de refroidissement pour deux systèmes généralement utilisés dans la CVAC: double conduit à volume constant (DDCV) et double conduit à volume d'air variable (DDVAV).

Comparé au modèle à simple variable (modèle de deux paramètres avec la température extérieur à bulbe sec comme seule variable), les modèles de MLR ont montré une diminution de coefficient de variation (CV) entre 10% et 60%, avec une diminution moyenne d'environ 33%, d'où la supériorité du modèle MLR.

Cette méthodologie peut facilement être adaptée à d'autres types de système (simple conduit à volume constant avec le réchauffage, simple conduit à volume d'air variable avec le réchauffage), et à d'autres utilisations finales (chauffage et utilisation d'énergie électrique). L'article récapitule les résultats pour modéliser la consommation d'énergie de refroidissement dans cinq grands bâtiments commerciaux à une échelle de temps journalière.

L'utilisation quotidienne d'énergie de refroidissement dans les cinq bâtiments avec des systèmes DDCV et DDVAV a été modélisé en utilisant l'équation (2.6) dont les coefficients β_x varient d'un système à l'autre.

$$\dot{E}_c = \alpha + \beta_1 T_0 + \beta_2 I + \beta_3 IT_0 + \beta_4 T_{dp}^+ + \beta_5 q_i + \beta_6 q_{sol} \quad (2.6)$$

Avec :

T_0 : la température moyenne de référence

T^+ : température différentielle à T_0

q_{sol} : énergie moyenne de référence

q_i : énergie différentielle à q_{sol}

α, β : facteurs de régression

L'approche proposée dans cet article suggère une voie à suivre pour modéliser la consommation d'énergie de refroidissement dans des grands bâtiments commerciaux avec un système DDCV ou DDVAV. Cette consommation peut être prédite plus précisément avec une analyse par morceaux de la régression multilinéaire qu'avec un modèle linéaire à simple variable. En utilisant un modèle de régression de MLR, qui capture la plupart des interactions physiques ayant lieu dans un système réel de la CVAC, la consommation d'énergie de refroidissement de cinq grands bâtiments commerciaux au Texas (trois avec DDCV et trois avec des systèmes de DDVAV) a été modélisée sur une base mensuelle, quotidienne et horaire. Cette étude a montré les avantages du modèle de MLR (des R^2 plus

élevés qui diminuent le CV) et également les avantages des modèles de HOD (heure de jour) et quotidienne comparés aux modèles mensuels.

2.2 Modèle de séries de temps

Les modèles de séries de temps sont différents des modèles régressifs. Ils sont chronologiques et peuvent dépendre des entrées précédentes du système, des sorties précédentes ou les deux en même temps. Le modèle de séries de temps peut inclure aussi des méthodes intégrales ou des séries de Fourier.

2.2.1 Modèle Autorégressif (AR)

Une approche commune pour modéliser la série chronologique univariable est le modèle autorégressif (AR) [31]:

$$X_t = \delta + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + A_t \quad (2.7)$$

Où X_t représente la consommation d'énergie au moment t et A_t est le bruit, et

$$\delta = (1 - \sum_{i=1}^p \phi_i) \mu \quad (2.8)$$

Avec μ dénotant la moyenne de processus et Φ_i les coefficients de la régression.

Un modèle autorégressif est simplement une régression linéaire de la valeur courante de la série contre une ou plusieurs valeurs antérieures de la série, dont p est l'ordre du modèle.

Des modèles d'AR peuvent être analysés avec diverses méthodes, y compris des techniques des moindres carrés linéaires standards.

2.2.2 Modèles autorégressifs de la moyenne mobile (ARMA)

Un modèle qui dépend seulement des sorties précédentes du système s'appelle un modèle autorégressif (AR), alors qu'un modèle qui dépend seulement des entrées au système s'appelle un modèle moyenne mobile (MA), et naturellement un modèle basé sur les deux entrées et sorties est un modèle autorégressif de la moyenne mobile (ARMA).

L'admission de modéliser une série chronologique est que la valeur de la série X_t au temps t , dépend seulement de ses valeurs précédentes (partie déterministe) et d'une perturbation aléatoire (partie aléatoire). En outre, si on assume que cette dépendance de X_t à l'égard des valeurs précédentes est linéaire, nous pouvons écrire (2.9) qui représente le modèle autorégressif de la moyenne mobile [31]:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \tilde{Z}_t \quad (2.9)$$

Où \tilde{Z}_t est la perturbation au temps t (2.10), et elle est habituellement modélisée comme combinaison linéaire.

$$\tilde{Z}_t = Z_t + \theta_1 Z_{t-1} + \theta_2 Z_{t-2} + \dots + \theta_q Z_{t-q} \quad (2.10)$$

Les constantes ϕ_i et θ_i sont respectivement les coefficients autorégressifs (AR) et les coefficients de la moyenne mobile (MA), pour la raison évidente que l'équation 2.9 est un modèle de régression et l'équation 2.10 à une moyenne mobile. La combinaison (2.9) et (2.10) nous donnent le modèle autorégressifs ARMA complet :

$$X_t - \phi_1 X_{t-1} + \phi_2 X_{t-2} - \dots - \phi_p X_{t-p} = Z_t + \theta_1 Z_{t-1} + \theta_2 Z_{t-2} + \dots + \theta_q Z_{t-q} \quad (2.11)$$

2.2.3 Modèles autorégressifs intégraux de la moyenne mobile (ARIMA)

Rappelons que les modèles ARMA sont applicables à des séries stationnaires. Si le processus n'est pas stationnaire (*i.e.* possède une tendance), il est possible de réécrire l'expression du modèle ARMA mais à l'ordre 1, ou à un ordre plus élevé [31].

Le modèle ARIMA s'écrira :

$$\Delta^d X_t + \phi_1 \Delta^d X_{t-1} + \dots + \phi_p \Delta^d X_{t-p} = Z_t + \theta_1 Z_{t-1} + \dots + \theta_p Z_{t-p} \quad (2.12)$$

Où $\Delta^d X_t$ représente la différence de X_t à l'ordre d .

2.2.4 Modèles autorégressifs de la moyenne mobile avec entrée exogène ARMAX

Le modèle d'ARMAX est une généralisation du modèle d'ARMA qui est capable d'incorporer une nouvelle variable d'entrée, (x). La forme du modèle d'ARMAX est la suivante [31]:

$$\Phi(B)y_t = \Xi(B)x_{t-\alpha} + \Theta(B)\varepsilon_t \quad (2.13)$$

Où $x_{t-\alpha}$ est une variable d'entrée externe, le y_t est la réponse (variable de rendement), ε_t est le bruit, α est le décalage entre l'entrée et la sortie, et B est l'opérateur de décalage et il est donné par $(B)y_t = y_{t-1}$, et les polynômes Φ , Ξ et Θ sont donnés par :

$$\begin{aligned} \Phi(B) &= 1 + \phi_1 B + \phi_2 B^2 + \dots + \phi_{n\phi} B^{m\phi}, \\ \Xi(B) &= 1 + \xi_1 B + \xi_2 B^2 + \dots + \xi_{n\xi} B^{m\xi}, \\ \Theta(B) &= 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_{n\theta} B^{m\theta}. \end{aligned} \quad (2.14)$$

Où Φ_i , ξ_i et θ_i sont les facteurs de régression.

2.2.5 Modèle des séries de Fourier

La modélisation précise de la consommation énergétique horaire du chauffage et du refroidissement dans les bâtiments commerciaux peut être réalisée avec l'approche généralisée de la série de Fourier (GFS) dépendante des variables météorologique comme la température à bulbe sec, l'humidité et le rayonnement solaire horizontal [5].

Cependant, il y a des situations où on dispose seulement des données de température. Les objectifs de cet étude [6] sont: (i) le développement d'une variante de l'approche GFS qui modélise l'énergie horaire du chauffage et du refroidissement utilisée dans les bâtiments commerciaux avec la température extérieure comme seule variable météorologique, (ii) l'illustration de son application avec des données horaires examinées de plusieurs bâtiments situés au Texas.

La première étape dans le processus avant l'identification du modèle est de définir le type-jour, afin d'enlever l'effet des changements principaux de fonctionnement pendant les week-ends, les jours de la semaine, les vacances, ...etc. Bien qu'une seule séparation des données entre les jours de la semaine et les week-ends puisse produire de très bons ajustements [6].

L'utilité du modèle de TFS (approche de la série de Fourier basée sur la température) est illustrée par des exemples : (1) l'utilisation de l'énergie de refroidissement pendant des jours de la semaine et des week-ends fonctionnant de janvier 1992 à juin 1992 dans ZEC, un grand bâtiment institutionnel qui loge des salles de cours, des laboratoires, des bureaux et des installations informatiques sur le campus de l'université du Texas A&M, et (2) l'utilisation de l'énergie de chauffage dans un autre bâtiment institutionnel (salles de cours, halls de conférence, bureaux et salles) sur le campus UT Austin.

Les coefficients de détermination R^2 pour le ZEC sont autour de 84% à 90% selon le type-jour, le CV est de 12% à 15 % [7].

Les techniques existantes de régression sont simples et facile à appliquer. Cependant, ces techniques ignorent : (i) la dépendance entre le temps et l'énergie consommé (ii) le rapport non linéaire qui pourraient exister entre l'énergie consommé et la température ambiante. Le model TFS proposé dans cet article [7], a l'avantage de pouvoir représenter la dépendance non linéaire entre le temps – ou la température- et l'énergie utilisée pour le chauffage et le refroidissement sous une forme fonctionnelle linéaire et compacte.

L'approche de TFS s'avère capable de capturer partiellement l'effet de l'humidité et le rayonnement solaire sur la consommation d'énergie de refroidissement tout en rapportant un meilleur ajustement à la consommation d'énergie de chauffage que l'approche de GFS, qui ne considère pas la dépendance non linéaire de la température.

L'approche de TFS est très efficace pour la prédiction quand les données de la température sont disponibles. Si l'humidité et les données solaires sont également disponibles, on devrait préférer l'approche de GFS pour modéliser la consommation énergétique du refroidissement en raison de la puissance plus élevée de la prédiction que l'approche de GFS offre.

La bonne modélisation de la charge du chauffage dépend du choix entre l'approche GFS et TFS sur lequel la forme fonctionnelle est un meilleur représentant de l'énergie de chauffage pour le bâtiment.

On constate que la nouvelle approche de la série de Fourier (TFS) basée sur la température [7]: (i) a fourni une meilleure approximation à la consommation énergétique du chauffage que l'approche existante GFS, (ii) peut indirectement expliquer l'effet de l'humidité et de la radiation solaire sur la charge du refroidissement, (iii) offre l'aperçu physique sur le fonctionnement d'un système CVAC du bâtiment et (iv) peut être employée pour des buts diagnostiques.

2.3 Réseaux de neurones artificiels

Les réseaux de neurones artificiels (RNA) sont une technique analytique inspirée du fonctionnement du cerveau et du système neural. Comme le prouve la plupart des articles examinés dans le cadre de cette étude, les RNA présentent de nombreux avantages qui leur permettent d'avoir le succès de résoudre différents phénomènes complexes dans différents domaines comme la médecine, les prévisions financières, le contrôle robotique et notamment dans l'ingénierie des bâtiments commerciaux. Toutefois, développer des modèles basés sur les RNA n'est pas simple car aucune méthode n'est communément acceptée.

Afin d'éclairer le lecteur sur le fonctionnement des RNA et justifier leurs utilisations dans ce projet de recherche, cette partie présente les différents résultats obtenus via l'inventaire de différents articles scientifiques traitants la prédition des besoins énergétiques des bâtiments commerciaux en utilisant les RNA.

Plusieurs chercheurs ont basé leurs recherches sur la prédition des besoins énergétiques du bâtiment en utilisant les réseaux de neurones artificiels (Kreider, Curtiss, Krarti, Kawashima et d'autres). Plusieurs modèles de RNA sont décrits dans les différents articles examinés. Chacun de ces articles détaille le type de RNA utilisé, le type de l'énergie à prévoir et les détails de l'environnement de chaque bâtiment.

Parmi les recherches les plus récentes, il y a celle de Yalcintas [8]. Cette étude présente le modèle de réseaux de neurones artificiels (RNA) pour l'usage de prédition des besoins énergétiques du refroidisseur dans des climats tropicaux avec des petites variations saisonnières et quotidiennes. L'erreur absolue moyenne de formation pour le modèle était 9.7% tandis que l'erreur d'essai était 10.0%. Ceci indique que le modèle peut correctement prévoir la consommation d'énergie particulière du refroidisseur dans un climat tropical.

Le bâtiment de multiple service exige que son équipement de CVAC fonctionne 24h/7j avec un système de pilotage automatique (BAS). Pour cette étude, qui a été faite pendant trois semaines, l'utilisation de la consommation électrique par le refroidisseur, le débit et la température d'eau glacée, le débit et la température de l'air de retour, le taux d'occupation, et les données horaires locales du climat ont été employés pour prédire toute la puissance du refroidisseur par la méthode de RNA. Les données considérées étaient spécifiquement : température sèche, température humide, température du point de rosé, humidité relative, vitesse et direction du vent.

Le RNA contient des couches pour entamer le processus de la prédiction. Quand un algorithme de rétro-propagation est utilisé, la formation du modèle RNA est effectuée en alimentant les neurones de la couche d'entrée par des données normalisées [8] (toutes les grandeurs d'entrée sont comprimées à une plage commune de 0.1 et de 0.9). La normalisation des données d'entrée est accomplie par l'intermédiaire de l'équation (2.15) où X_i représente la mesure normalisée, X la valeur réelle du paramètre i , $X_{\min i}$ le minimum du paramètre i de l'entrée et le $X_{\max i}$ le maximum du paramètre i de l'entrée.

$$X_i = 0.1 + 0.9(X - X_{\min i}) / (X_{\max i} - X_{\min i}) \quad (2.15)$$

Le but d'un algorithme de rétropropagation est de réduire au minimum l'erreur, et de calculer sa matrice optimale associée aux poids. Au début, tous les poids ont été initialisés à des valeurs aléatoires entre -1 et 1. Durant l'apprentissage, les poids sont mis à jour pour approcher leurs valeurs optimales.

Dans cette étude [8], un type commun de couches des RNA a été employé. La couche d'entrée, la couche cachée et la couche de sortie contenaient respectivement 7, 6 et 1 neurones. Les neurones de chaque couche sont complètement reliés à chaque neurone dans la couche voisine. Aucun terme de polarisation ou d'impulsion n'a été employé dans la

génération du modèle. Les données originales se sont composées de 121 ensembles chacun avec 7 paramètres d'entrés : ($x_1; x_2; x_3; \dots; x_7$) et 1 paramètre de sortie (y).

Un modèle de RNA à trois couches a été développé comme une étude de cas pour la prédiction de la puissance totale d'énergie du refroidisseur dans un tel bâtiment universel. Les prédictions satisfaisantes de la puissance observée du refroidisseur par le modèle ont prouvé qu'un RNA pourrait être un outil très utile pour modéliser des systèmes de CVAC. Le modèle se prête à l'utilisation par des ingénieurs de CVAC comme guide pour les conditions qui donnent la plus basse charge possible quand une analyse de sensibilité est exécutée pour les effets des facteurs.

Kawashima propose un nouveau modèle de réseau de neurones artificiel, nommé le rétropropagation avec le recuit triphasé [9]. C'est une méthode empirique pour réduire graduellement le taux d'apprentissage (*learning rate*) [9] pendant la période de formation afin d'améliorer l'exactitude dans relativement peu de temps.

Le taux d'apprentissage (α) commence à partir d'une valeur telle que 0.5 et est graduellement réduite en utilisant l'équation (2.16). Pendant la formation, l'ensemble des données de formation est employé à plusieurs reprises. La période nécessaire pour que toutes les données de formation soient utilisées pour le processus de rétropropagation s'appelle une époque. Le taux d'apprentissage est réduit à chaque époque dans toute la formation selon (2.16):

$$\alpha = \frac{C}{\log(1+N)} \quad (2.16)$$

Avec :

α : taux d'apprentissage,

C : valeur constante,

N : nombre d'époque.

Le prétraitement des données est l'une des étapes principales pour obtenir une meilleure exactitude dans la prévision des RNA [9]. La section (2.4) traite les résultats de l'étude [9] réalisée dans le cadre d'une compétition pour la prédiction des besoins énergétiques du bâtiment (SHOOTOUT I).

L'étude s'est basée sur le traitement de deux ensembles de données, ensemble A et B de la compétition. Pour l'ensemble A , la consommation de l'électricité, du refroidissement et du chauffage ont été prévus. Pour l'ensemble B le rayonnement solaire était la variable à prédire. La méthode a pris compte de l'information relative au temps, y compris le mois, jours et heure, ajoutant l'indicateur des fins de semaine qui permet aux RNA d'identifier les jours de travail, des jours de repos. L'analyse des résultats de cette étude pour les deux ensembles de données a donné un CV de l'ordre de 16,58% et un MBE de 10%. S'il y avait plus d'entrées disponibles, comme le nombre de personnes d'occupation, la prédiction pourrait être plus proche des données mesurées.

Des directives pour le développement du modèle RNA basé sur l'expérience, peuvent être divisées en deux catégories [9]. La première considère la structure de réseau et la deuxième catégorie considère le traitement des entrées et des sorties. Pour le coté structure, l'auteur presume qu'une seule couche cachée est suffisante pour une prévision de charge et que le nombre de neurones de la couche cachée (p), devrait être plus que $2n+l$, où n est le nombre d'entrées et d'avoir un seul neurone à la couche de sortie.

Pour le prétraitement des entrées et des sorties, chaque entrée doit être normalisée à partir de ces données originales de 0 à 1, cependant, le rendement de données de formation devrait être normalisé aux données s'étendant de 0 à 1. Aussi jusqu'à quelques heures avant le temps visé, les températures ambiantes devraient être employées comme des entrées. Puisque la charge thermique est affectée par la masse thermique du bâtiment, les données précédentes devraient être employées (habituellement jusqu'à deux ou trois heures avant le temps cible de la prédiction). De même, quelques heures avant le temps de cible, l'insolation

solaire devrait être employée comme entrée pour la même raison et les heures du jour (0-24) peuvent être transformées à un produit de sinus ou de cosinus.

Les directives notées dans cet article sont significatives afin d'obtenir une meilleure exactitude de prédition. Les RNA n'ont pas besoin d'un modèle physique; cependant, un raisonnement orienté vers le modèle physique est recommandé. En d'autres termes, la température d'une heure en avance ou des données solaires d'ensoleillement jusqu'à peu d'heures avant le temps visé devrait également être employée comme entrée. Cependant, malgré le temps additionnel requis pour le processus d'apprentissage, ces valeurs ont presque toujours apportées des meilleurs résultats. La méthode de recuit triphasée réduit le temps de formation sans perdre l'exactitude de prévision. Cela a pris environ 6 à 12 heures pour un cas avec le recuit triphasé et deux à trois jours sans recuit triphasé sur un PC équipé d'une unité centrale de traitement 33-MHz.

Dans l'article [10] une autre méthode est basée sur un genre spécial de réseaux des neurones artificiels qui rétroagit avec une partie de sortie du RNA. Les prédictions à court terme de la charge peuvent prévoir la consommation électrique des régions, bâtiments ou industries pour différentes périodes dans le temps (en minutes, heures, jours ou semaines). Une des approches qui a été étudié durant les dernières années afin de résoudre le problème de STLF (*short-term load forecasting*) avec les RNA a été le choix de la meilleure structure de prédition à employer. Basée sur d'autres études, n'importe quelle topologie multicouche des RNA peut être employée pour soutenir la structure de la rétroaction en employant l'algorithme de la rétropropagation (Backpropagation).

La structure générale de prédition proposée par Zamarreno [10] est montrée sur la figure 2.

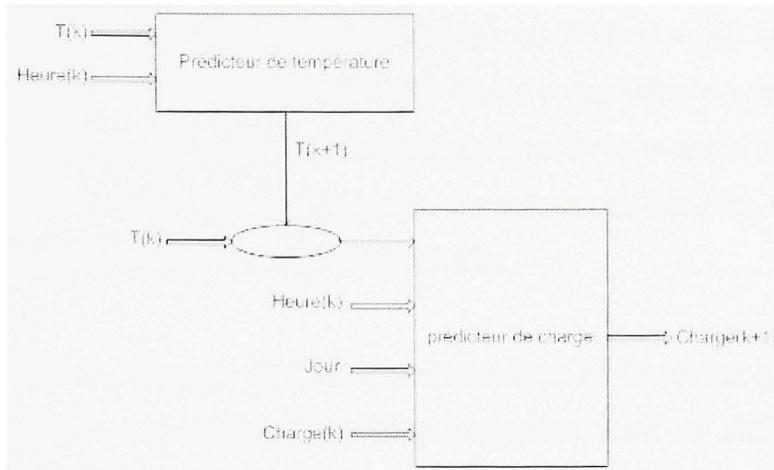


Figure 2 Structure générale de modèle de prédition proposé par Zamarreno.

(Tiré de Zamarreno, 2005)

(La référence complète du document est présentée dans la bibliographie)

On peut remarquer que c'est une cascade de prédicteurs, le premier prédit la température et le ΔT , qui est la variation de la température entre $T(k+1)$ prévue pour la période $k+1$ et le $T(k)$ la valeur mesurée à l'instant k . Ce ΔT qui présente une différence de température, indiquerait si un incrément ou diminution de la température s'est produit entre les instants k et $k+1$, ce qui impliquera un incrément ou une diminution de la charge.

Le deuxième élément de cette base de données est le temps (heure, jour, semaine). A noter, il est bien connu que pendant des week-ends et des vacances, les bâtiments publics et sociaux consomment moins d'énergie. Cela implique d'ajouter un index dans la base de données qui indique aux RNA quel type de jour c'est.

La troisième entrée est, peut-être, la plus importante : $Charge(k)$. Puisque ce prédicteur est conçu pour prévoir la charge à $k+1$, la valeur utilisée pour cette entrée est la valeur réelle de la charge à l'heure k .

En vue d'améliorer les avantages des RNA, chaque information de l'ensemble d'états de rendement de formation a été égalée à la charge dans $k+1$, de sorte que la rétroaction de chaque état ait la plus grande précision pendant la formation.

Avec l'objectif de déterminer l'influence de l'erreur de prédiction de la température, les résultats de cette expérience indiquent que cette erreur a une influence insignifiante sur le prédicteur de l'énergie, ce qui confirme la robustesse de cette conception dans le cas de cette entrée qui pourrait être un composant bruyant. La valeur moyenne de CV calculée était égale à 1.49, alors que la valeur de MBE était 0.0123.

Le nouveau prédicteur d'énergie proposé par Zamarreno et Gonzalez [10], présente une précision comparable aux meilleurs résultats rapportés dans la littérature. La vertu principale de ce système est sa simplicité, qui est basée sur le fait que l'outil développé est très simple et les données nécessaires pour son application sont peu nombreuses et disponibles dans les systèmes de contrôle modernes. Le nombre de neurones qui composent la couche cachée des RNA, la taille optimale de fenêtre de données et d'algorithme de formation, sont tous des paramètres qu'il faut analyser. Des travaux expérimentaux menés, suggèrent que ces éléments devraient être soigneusement étudiés et confirmé qu'un grand nombre de neurones dans la couche cachée n'est pas nécessaires pour obtenir des résultats satisfaisants.

Curtiss, Kreider, Krarti et Cohen [11] dans une étude pour un concours organisé par l'ASHRAE (Shootout II) pour encourager le développement des méthodes innovatrices et précises pour prédire la consommation d'énergie dans des grands bâtiments commerciaux dus aux remplacement d'équipement démontrent de nouveau l'efficacité des RNA dans la prédiction des besoins énergétiques du bâtiment. L'étude a été basée sur des données choisies pour deux bâtiments; un centre universitaire de technologie (ZEC) et un bâtiment d'affaires (BUS).

L'économie d'énergie a été estimée comme étant la différence entre l'énergie réelle (mesurée) utilisée après modification dans le bâtiment et l'énergie prévue par le modèle pour les bâtiments avant modification, avec les conditions météorologiques d'après modification comme référence climatique.

L'objectif spécifique de l'étude était de construire un modèle pour estimer l'utilisation d'énergie avant la modification du bâtiment. Le modèle a été calibré en utilisant des données mesurées avant la modification du bâtiment. Pour chaque variable de sortie à prédire, un réseau a été employé. Tous les réseaux ont eu deux couches cachées de 25 neurones chacune. Les variables d'entrée ont été choisies en utilisant les essais de Wald qu'on discutera après dans ce paragraphe (2.17).

Une analyse des résultats du modèle a montré que les RNA ont estimé l'économie d'énergie d'une façon très acceptable sauf à quelques reprises. Tous les participants au concours ont fourni de bonnes évaluations de l'économie d'énergie pour le bâtiment de ZEC, mais pas pour le bâtiment de BUS. La grande quantité de données de formation disponibles pour le bâtiment de ZEC peut expliquer cette anomalie de prédiction entre les participants [11]. L'article [11] basé sur les valeurs des erreurs moyennes carrées (MSE) pour différents réseaux de RNA montre aussi que la performance du réseau peut s'améliorer en éliminant quelques variables d'entrée inutiles.

Cohen et Krarti [12] proposent une autre approche des RNA pour déterminer l'économie d'énergie due aux modifications de bâtiment. La prétention principale dans cette approche est que les données utilisées pour la prédiction sont disponibles pendant une période donnée avant que la modification soit mise en application. L'économie due à la modification a été estimée en utilisant la différence entre la consommation d'énergie prévue avant modification extrapolée dans la période d'après (employant RNA) et les données réelles mesurées après modification.

L'architecture des RNA choisie est de deux couches cachées chacune avec six neurones. Pour chaque modification, trois valeurs de sortie sont ciblées, chacune de ces valeurs a son propre RNA, représentant: l'économie de la consommation électrique du bâtiment, l'économie d'utilisation de l'eau glacée, et l'économie d'utilisation du chauffage. Pour chaque réseau, sept paramètres d'entrés ont été choisis comprenant l'utilisation d'énergie de

bâtiment avant modification, les indicateurs de temps (heure, jour, année), le taux d'occupation, et des variables climatiques (la température à bulbe sec, la température à bulbe humide et le rayonnement solaire horizontal total).

L'étude compare l'économie prévue et réelle de la consommation de l'eau glacée pour le bâtiment entier. Les RNA estiment exactement l'économie horaire de l'eau glacée pour la semaine entière. Pour la modification du VAV, les résultats indiquent que le modèle des RNA détermine parfaitement l'économie d'eau chaude. Aussi, les crêtes de journée sont bien prévues par le modèle, mais certaines des crêtes de remplissage de soirée ne le sont pas.

Le modèle des RNA utilisé a bien prévu l'économie due à la modification d'éclairage. Pour les deux autres modifications, les résultats de la prédiction étaient proches des données réelles mais avec une certaine faiblesse pour les heures de fin des journées. En général, au cours de la période d'essai le pourcentage de l'économie due aux modifications dans ce bâtiment est estimé aux environs de 10 % par le RNA. Jusqu'ici on peut identifier quelques éléments importants dans l'application des RNA pour prédire l'économie de l'énergie due aux modifications des bâtiments.

- 1) les données réelles mesurées dans le bâtiment avant modification peuvent être aisément employées par le RNA pour cette prédiction.
- 2) les principes physiques de l'enveloppe du bâtiment ainsi de son équipement peuvent faciliter et améliorer l'utilisation des RNA.
- 3) la généralisation d'un cas de bâtiment à d'autres bâtiments semblables dans d'autres climats n'est pas conseillée.

Dodier et Henze [13] en examinant les résultats du concours Shootout II, montrent une autre fois la performance des réseaux neurones. La plupart des participants ont employé les réseaux de neurones. Trois stratégies ont le mieux réussi :

- la première équipe a utilisé un RNA qui comporte la détermination automatique de pertinence –*ARD*- (*Automatic Relevance Determination*). Une méthode pour détecter automatiquement les variables d'entrée appropriées, basée sur l'évaluation bayésienne.
- la deuxième équipe a utilisé un essai statistique pour la corrélation non linéaire, nommée « *Delta essai* » pour choisir les variables d'entrée qui sont pertinentes à prévoir le rendement.
- la troisième équipe a rassemblé un grand nombre de variables d'entrée et puis a employé l'analyse en composantes principales (*ACP*) pour réduire le nombre de variables d'entrées. Une méthode qu'on va détailler ultérieurement dans le chapitre suivant.

Les trois équipes ont identifié une même importance commune : déterminer les variables d'entrées pertinentes du RNA pour avoir une meilleure prédiction en utilisant ce type de réseau.

Face à ce problème sérieux dans les applications des RNA, un essai statistique appelé « *essai de Wald* » a été employé pour évaluer la pertinence de diverses entrées.

A noter que les organisateurs ont effectué, pour les deux premières méthodes (*ARD et Delta essai*), un choix préliminaire des variables d'entrées. Cependant, ils ont gardé un nombre défini de ces variables connus par leurs critères physiques appropriés aux problèmes de la mécanique de bâtiment. Les organisateurs croient que le choix d'un premier ensemble selon des principes physiques sera généralement une technique efficace [13].

Pour le choix des entrées et leurs poids dans le RNA, les participants étaient dans l'obligation d'exclure les entrées non pertinentes du modèle pour réduire le bruit, qui représente un vrai problème. Tous les poids menant à une entrée ou une unité cachée optimale non pertinente, devraient être mis à zéro. Étant donné que le bruit représente un obstacle devant la qualité de la prédiction des RNA, les auteurs ont employé de plus petits réseaux (moins de neurones dans chaque couche cachée).

Dans cette étude, on emploie la statistique de Wald pour identifier les entrées non pertinentes. Si W « *facteur de Wald* » est assez grand pour être statistiquement significatif,

l'entrée est considérée appropriée pour prédire la cible et elle est gardée. Si W n'est pas significatif, la variable d'entrée est enlevée de l'ensemble d'entrées.

En comparant des réseaux ayant une quantité de variables d'entrées non pertinentes à ceux qui ont été réduites par les techniques de choix d'entrée, les résultats confirment que l'essai de Wald peut distinguer les entrées plus appropriées des moins appropriées. Il faut aussi bien choisir la valeur de W . S'il est choisi trop petit, peu d'entrées peuvent être incluses, ce qui peut aussi nuire à la qualité de la prédiction.

Le facteur de Wald W est défini comme suit :

$$W = \frac{1}{SSE/n} \sum_{i=1}^q \sum_{j=1}^q w_i w_j (B^{-1})_{ij} \quad (2.17)$$

Où SSE est la somme d'erreurs carrées.

B : présente la matrice asymptotique de covariance.

Les w_i et w_j sont les poids associés aux entrées.

En comparant les RNA à une méthode de régression multilinéaire, on constate que les modèles non linéaires sont essentiellement plus précis que les modèles multilinéaires. Ainsi la réduction substantielle d'erreur des sommes des moyennes carrées (RMSE) est possible si on emploie un modèle non linéaire au lieu d'un modèle linéaire.

Dans un autre article [14], l'auteur présente des réseaux de neurones qui ont été employés pour prévoir l'utilisation horaire d'énergie thermique et électrique de bâtiment pendant une période d'un jour, une semaine, et également un mois. Typiquement, les données météorologiques, le profil d'occupation et les types de jour ont été considérés comme des paramètres d'entrées pour que les réseaux de neurones prévoient l'utilisation d'énergie de bâtiment.

Pour les applications dans la mécanique de bâtiment, des prévisions de charge à court terme sont exigées pour la commande efficace des systèmes de CVAC. Généralement, des modèles multilinéaires de régression sont employés pour corrélérer entre les consommations électriques (la cible) et les facteurs qui les affectent (entrées) comme les variables météorologiques et le type de jour. Cependant, puisque le rapport d'entrée-sortie pour la plupart des systèmes d'alimentation électrique est en général non linéaire, il est difficile de compter sur les modèles conventionnels de régression pour prévoir exactement les futures consommations électriques.

La plupart des approches basées sur les réseaux de neurones proposées prévoient 24 heures en avance la charge maximale du jour suivant, en tenant compte des prévisions météorologiques comme la température à bulbe sec ou souvent la température ambiante. Quelques modèles de RNA ont traité les prédictions de charge seulement une heure en avance pour réduire l'erreur de prévision due aux changements non attendus de temps [14]. Dans le même article [14], Krarti fait référence à une étude de Cohen et Krarti qui est basée sur les RNA pour prédire la consommation électrique d'une entreprise située dans le Colorado. La méthode développée emploie des prévisions météorologiques et des données de charge électrique précédentes pour prédire les besoins énergétiques une heure à l'avance. Dans cette méthode, cinq différents réseaux de neurones ont été formés pour cinq différents types de jours où chacun de ces derniers est caractérisé par des critères unique de la consommation électrique. Les cinq types de jours correspondent au lundi, mardi-jeudi, vendredi, samedi et dimanche. Pour chaque type de jour, un réseau de multicouche a été développé en utilisant un modèle de rétropropagation. Les meilleurs réseaux s'avèrent ceux à 32 variables d'entrées, 22 neurones dans les couches cachées, et une variable de sortie (la cible).

Des valeurs sont fournies pour caractériser l'exécution d'essai comprenant R^2 et MAPE (erreur moyenne absolue)

$$\text{MAPE} = (\text{Valeur de prévision} - \text{valeur réelle}) / \text{valeur réelle}$$

Les résultats s'avèrent être pertinentes avec un R^2 de 0.95 à 0.99 et un MAPE de 1.4% à 1.94%. Ce qui implique que les réseaux de neurones peuvent prévoir exactement le profil d'utilisation de service pour chaque type de jour.

Après la bonne qualité de prédiction prouvée par les RNA. Un autre défaut s'est présenté devant cette technique : prédire la consommation énergétique de bâtiment pour les heures suivantes en ignorant la consommation énergétique des heures passées. Curtiss dans son étude [15] résume les résultats d'une étude basée sur six mois de données horaires enregistrées au Centre de Technologie de Zachry (ZEC) dans la station d'université, au Texas. Des études antérieures ont démontré le succès d'RNA utilisé comme prédicteurs pour la consommation horaire de l'électricité, de l'eau glacée et de l'eau chaude pour le ZEC. Les variables d'entrées du RNA ont inclus la consommation d'énergie mesurée immédiatement une ou deux heures à l'avance.

Le succès de cette étude a incité une deuxième étude, un problème plus difficile. Dans ce cas-ci, le but était de prévoir la consommation d'énergie pour les heures qui suivent sans connaissance de la consommation énergétique dans le passé immédiat. En général, les prévisions des réseaux récurrents sans connaître la consommation réelle des dernières heures ont environ deux fois l'erreur de *RMS* par rapport aux prévisions des réseaux non récurrents en connaissant la consommation des dernières heures. Par exemple, si un réseau non récurrent avait une exactitude de 4%, l'exactitude des réseaux récurrents s'est avérée à 8%.

La conclusion la plus importante de cette partie d'étude est que les réseaux récurrents offrent une méthode précise pour prévoir la consommation énergétique horaire utile pour les heures qui suivent quand les données météorologiques sont connues. Une approche des réseaux de neurones artificiels récurrents a été créée pour satisfaire ces besoins prédictifs. Il s'est avéré qu'il est possible de prévoir les charges du refroidissement et du chauffage pour

un bâtiment (un centre de technologie universitaire) avec une bonne exactitude sans se référer aux charges réelles des dernières heures. Cela sans intentionnellement augmenter l'ensemble de variables indépendantes au delà de ce qui est utilisé pour les réseaux non récurrents [15]. Les variables suivantes sont employées comme entrées du RNA pour prévoir les futures charges du chauffage et du refroidissement :

- Température sèche.
- Taux d'humidité.
- Flux du rayonnement solaire horizontal.
- Vitesse du vent.
- Heure du jour.
- Signe binaire (0/1) (jour de la semaine /fin de semaine)

Une autres études basée sur des données réelles pour la formation et l'apprentissage du RNA est résumé dans les articles [16] [17]. Le RNA dans ce cas emploi les données réelles des heures passées pour exécuter son processus de prédiction.

Pendant la période de prédiction requise pour le *SI* (Système d'identification), quand aucune de telle donnée n'est disponible, les prévisions du réseau elle-même des dernières heures sont employées au lieu des données réelles. La recherche précédente à JCEM [16] [17] avait indiqué que cette approche était réussie dans des systèmes de CVAC et les auteurs se sont attendue à ce qu'elle fonctionne pour d'autres bâtiments.

L'analyse des résultats de cette étude montre qu'on utilisant les données d'entrées d'une heure en arrière pour le RNA au cours du processus de la prédiction de réseaux on aura :

Tableau 1 Comparaison entre les résultats d'une prédiction basée sur des données réelles et une prédiction basée sur des données prédictes pour un modèle de RNA récurrent [17]

| | Type de données d'entrées | CV % |
|---------------------------|--|------|
| prévision de l'eau glacée | basé sur des entrées prévues par le réseau | 9.1 |
| | basé sur des entrées réelles | 4.7 |
| prévision de l'eau chaude | basé sur des entrées prévues par le réseau | 11.8 |
| | basé sur des entrées réelles | 7.9 |

Le tableau 1 prouve que la méthode des RNA récurrence est efficace, mais pas aussi performante qu'un réseau qui emploi des données réelles de la charge des dernières heures.

En utilisant les modèles statistiques traditionnels, comme la régression d'ARMA et la régression multilinéaire, des intervalles de confiance (CI) peuvent être calculés pour les prévisions de la consommation électrique à court terme, tout en supposant que les erreurs de prévision sont indépendantes et ont une distribution gaussiennes. Dans l'article de Alves [18], les prévisions sont obtenues par les perceptrons multicouches qualifiées par l'algorithme de rétropropagation. Trois techniques de calcul des intervalles de confiance pour les prévisions de charge à court terme basées sur les réseaux de neurones sont présentées : i) le rendement d'erreur (RE), ii) reprélèvement (RP) et iii) la régression multilinéaire adapté aux réseaux de neurones (MR). Une comparaison des trois techniques est effectuée par des simulations de prédiction en ligne.

Il y a deux approches pour estimer les intervalles de confiance en utilisant des prédicteurs du feedforward des RNA [18]. La première utilise les poids de raccordement directement ou leur distribution de probabilité afin de caractériser l'erreur de prévision des RNA (réseaux de neurones artificiels). La deuxième approche est basée sur le reprélèvement.

Le calcul du CI est accompli par l'évaluation de l'erreur de prévision (2.18):

$$(T - W)s^2 = \sum_{c=1}^T (\bar{y}_c - y_c)^2 \quad (2.18)$$

Les RNA choisis ont sept entrées, trois neurones dans la couche cachée et deux neurones dans la couche de sortie, avec des fonctions d'activation hyperboliques dans la couche cachée et linéaires dans la couche de sortie. Les entrées du RNA correspondent à la consommation électrique des heures précédentes pour 1 h, 2 h, 24 h, 168 h et 192 h, et deux entrées additionnelles, HC(k) et HS(k), codifiant l'heure du jour. Les sorties du RNA représentent la charge électrique prédictive et l'erreur de prédiction de la charge à l'heure k.

Des périodes de six semaines ont été employées pour la formation (et l'essai) avec des données regroupées selon le jour de la semaine. Pour chaque jour de la semaine, un RNA a été formé, appliquant l'algorithme de “rétropropagation” avec la contre vérification. Après la formation de sept RNA utilisant la technique de rendement d'erreur (RE), les mêmes RNA sont employés pour les techniques de reprélèvement et de régression multilinéaire. Bien que les méthodes RE et le MR exigent la prévision des valeurs de la charge seulement, l'idée est d'employer les mêmes données de formation et d'apprentissage pour comparer les prédictions des trois techniques (RE, RP et MR). Les intervalles de confiance (CI) s'étendent de 0 à 1 et indiquent le rapport entre les erreurs de prévisions et les limites de fiabilité. Si leurs valeurs sont près de 1, il signifie que les intervalles de confiance ne reflètent pas une bonne prédiction de la charge électrique.

Dans [18], on montre que les exécutions des méthodes d'évaluation d'intervalle de confiance se fondent fortement sur la similitude entre les données de passées et les données courantes (à l'instant t). Le rapport précédent reste valable aussi pour les méthodes RP et MR, dans lesquels les entrées du RNA sont influencées par les données courantes. Les CI estimés par les techniques de RE et EO sont presque indépendants de la distribution des données. La technique MR suppose que les erreurs de prévisions sont normalement distribuées et, par conséquent, les poids de raccordement seraient également gaussiens distribués. Cependant, cela n'est pas vrai pour un RNA non linéaire basé sur rétropropagation. Dans la technique

RP, le calcul de l'intervalle de confiance est l'une des sorties de la couche de rendement RNA.

D'autres structures des RNA ont été essayées et qui n'ont pas amélioré le rendement de ces derniers. En fait, le choix de l'architecture des RNA pour la technique RP assigne une difficulté supplémentaire. Des modèles non paramétriques de RNA devraient être étudiés. Des prédictions répétitives ont pu être évitées en employant des RNA avec 24 sorties, une pour chaque heure du jour.

Kawashima dans une autre étude [19] détaille les résultats d'un projet de recherche coopératif entre une université aux États-Unis et une société japonaise, qui a étudié quatre méthodes générales de prédiction pour examiner les modèles de base avec des variations et pour comparer l'exactitude de chaque modèle. Un ensemble de données saisonnières de refroidissement et de chauffage avec des conditions météorologiques connues pour le prochain jour a été employé pour évaluer l'exactitude de chaque méthode de prédiction.

Les différentes méthodes de prédictions en concurrences sont :

- *modèle ARIMA,
- * modèle exponentiel (EWMA),
- * model EWMA modifié,
- * modèle EWMA récursivement modifié,
- * modèle récursif de régression linéaire (LR),
- *modèle RNA simple,
- *modèle RNA récursivement modifié.

Après des comparaisons initiales avec un ensemble de données générées par ordinateur pour chaque méthode de prédiction, le modèle RNA a donné un taux de bruit typique dans le processus de la prédiction de deux différentes charges pour le bâtiment en question. Les prédictions de la charge de refroidissement du prochain jour employant les RNA étaient relativement semblables aux données réelles à prédire, même lorsque la météorologie du prochain jour a été aussi prédite. Ceci confirme que le modèle de RNA a une exactitude

suffisante et est la méthode correcte pour l'utilisation pratique dans la commande de système CVAC, la commande de stockage thermique et la gestion optimale de charge.

Les résultats de l'étude [19] montrent les critères d'exactitude pour les sept prévisions de la charge thermiques pendant l'été et l'hiver. Le EEP (pourcentage d'erreur de la charge maximal) sur une base horaire du modèle simple de RNA "RNA simple" étaient 6.3% de la charge maximum pour l'hiver et 5.7% pour l'été. Ceux du modèle RNA récursivement modifié étaient 5.3% et 4.7% respectivement pour l'hiver et l'été. Ces résultats prouvent que la prévision du modèle RNA est la plus efficace des sept modèles étudiés et le RNA récursif est meilleur que le RNA simple.

L'étude [19] dans sa deuxième partie est basée sur sept modèles de prévision de RNA qui ont été appliqués à deux ensembles de charges thermiques de bâtiment mesurées à Seattle, et à Phoenix. L'objectif principal de cette partie était de confirmer la gamme d'erreur de la prévision de charge par les RNA sur des charges réelles. La modélisation des RNA pour cette étude a suivi une directive énumérée dans un article précédent du même auteur. Il recommande un modèle RNA qui a une seule couche de sortie (charge thermique) et une couche cachée qui a $2n+1$ neurones (n est le nombre de variables d'entrées). Le procédé de réduction du taux d'apprentissage a été employé pendant la formation.

Les résultats de cette étude [19] comparent les sept prévisions de charge pour les deux bâtiments, Seattle et Phoenix. Pour le bâtiment S, l'exactitude de prévision des modèles à six variables d'entrées au niveau de la couche d'entrées du RNA est meilleure que celle à cinq variables d'entrées. Elle indique que plus il y a d'information à l'entrée, plus la prédiction est performante. Le pourcentage d'erreur de la charge maximal (EEP) de tous les modèles était moins de 8.5% sur une base horaire et 10.3% sur une base quotidienne. Le meilleur EEP (base horaire) était 6.8% pour "*S-6-k-n*" (prévision pour le bâtiment de Seattle avec un RNA modifié contenant six variables d'entrées et des données météorologiques prédites). L'EEP sur une base horaire avec des données météorologique prévue étaient 7.5% pour "*S-*

6-p-n" (prévision pour le bâtiment de Seattle avec un RNA non modifié contenant cinq variables d'entrées et des données météorologiques prédictes) et 8.1% pour "*P-5-p-n*" (prévision pour le bâtiment de Phoenix avec un RNA non modifié contenant cinq variables d'entrées et des données météorologiques prédictes). Ceci signifie que la prévision par les RNA a une exactitude acceptable même avec des données météorologiques prédictes. La prévision avec la modification récursive a un EEP de 7.2% sur une base horaire. C'est meilleur que le modèle non modifié (*S-6-p-n*), qui a un EEP de 7.5%. En général, l'étude confirme que le RNA a un grand potentiel pour la prévision horaire de la charge thermique. L'exactitude de la prévision de charge est suffisante pour être utilisée dans les contrôleurs des systèmes de CVCA.

2.4 Les résultats des deux concours de la prédition d'énergie (Shootout I et II)

Le premier concours (Shootout I) a été basé sur l'utilisation de deux séries de données *A* et *B* d'un bâtiment d'un centre de technologie universitaire EC [20] :

A : contient 3000 données, incluant l'eau froide et chaude, consommation électrique totale, les données météorologiques,...

B : contient 2400 données présentant les mesures de la radiation solaire.

La procédure de la compétition est basée sur la prédition horaire des besoins énergétique du bâtiment EC (Chw, Hw et le Wbe) pour une période de quatre mois pour la préparation des modèles de réseau et deux mois pour le test. La performance de chaque étude est basée sur des mesures statistiques standard du CV et MBE. Le tableau 2 résume respectivement les méthodes des deux contestants gagnants.

Tableau 2 Les méthodes des deux contestants gagnants du concours Shootout I

| Gagnant | Nom | Méthode |
|---------|-----------------|---|
| 1 | David Mackay | Méthode bayésienne non linéaire |
| 2 | Mattias Ohlsson | Méthode de commande prédictive de la perception des multicouches. |

La différence entre les résultats du premier participant (CV glob.=10,46%), est nettement inférieure aux autres participants qui ont un CV variant de 14,5% à 16,5%.

Un deuxième concours de prédiction a été développé et conduit pour évaluer les modèles empiriques les plus efficaces pour modeler la consommation horaire d'énergie des bâtiments due aux modifications [21]. Ce deuxième concours a utilisé deux ensembles d'ajustement horaire mesuré pré-modifications et post-modifications. L'exactitude des modèles des contestants a été évaluée en déterminant leur capacité de prévoir les données qui ont été enlevées de la période de formation. L'article [21] récapitule la performance des quatre contestants principaux. Le tableau 1, donne les statistiques pour les modèles produits par les contestants pendant la période de formation pour le centre d'ingénierie (EC) et le bâtiment d'affaires (BUS). Le classement est fait à partir du coefficient de variation CV et l'erreur systématique moyenne MBE qui est employée comme paramètre secondaire. La colonne E5 du tableau 3 représente la moyenne des résultats pour les 4 contestants. Le tableau 4 décrit les méthodes employées par les 4 contestants.

Les résultats du deuxième concours confirment un certain nombre de résultats du premier concours (Shootout I) et ont également fourni quelques nouvelles perspectives excitantes au sujet de l'utilisation de tels modèles de base pour calculer l'économie d'énergie due aux modifications. Ainsi les résultats montrent que les réseaux neurologiques fournissent toujours le modèle le plus précis pour la prévision de l'énergie d'un bâtiment. Cependant, l'exactitude des entrées de réseau neurologique a changé selon les prétentions que les contestants ont faites au sujet des données de formation et la façon par laquelle ils ont assemblé leurs réseaux. Un des résultats étonnantes du deuxième concours est le fait que les modèles statistiques habilement assemblés semblent être aussi précis ou, dans certains cas, plus précis que certaines des entrées de réseau neurologique. Les différences dans les prévisions du bâtiment d'affaires semblent également indiquer l'importance d'évaluer le bruit dans les modèles et prêter une attention particulière aux prétentions au sujet des programmes, etc.

Tableau 3 Résultats des différentes expériences du concours Shootout II [21]

| | CV % | | | | |
|------------|-------|-------|-------|-------|---------|
| | E1 | E2 | E3 | E4 | Moyenne |
| EC | 7.85 | 17.96 | 11.92 | 6.87 | 8.96 |
| BUS | 31.58 | 42.45 | 25.1 | 26.95 | 28.21 |

Tableau 4 Méthodes utilisées par les gagnants du concours Shootout II [21]

| Position | participant | Méthode |
|-----------|------------------|---|
| Gagnant 1 | Dodier, Henze | 10 réseaux neurones, 2 couches cachées avec 25 neurones dans chacune, une seule couche de rendement avec une activation linéaire, essai de Wald utilisé pour le choix des variables d'entrée. |
| Gagnant 2 | S. Katipamula | Un programme de jour-type statistique pour les chaînes des données météorologiques indépendantes, modèle de régression multiple statistique horaire de weekday/weekend pour chaque heure du jour. |
| Gagnant 3 | Y. Chonan et al. | Régression non linéaire bayésienne avec des hyper paramètres multiples. Déplacement manuel des annexes. |
| Gagnant 4 | K. Jang et al. | Commande prédictive, réseaux neurologiques auto associatif. Fonction de transfert hyperbolique tangente. |

2.5 Conclusion

Un certain nombre de modèles de prévision d'énergie de bâtiment ont été examinés dans ce chapitre. Une courte description de chacune des méthodes de prévision examinées a été

fournie pour illustrer comment ces modèles de prévision sont employés dans la pratique et le type d'exécution de prévision réalisé par chaque modèle.

Le choix d'un modèle de prévision d'énergie de bâtiment n'est pas une tâche facile. Toutes les méthodes de prévision décrites dans la littérature ci-dessus ont des dispositifs distinctifs. Certains d'entre elles s'exécutent mieux que d'autres, mais aucune d'elles n'a eu une bonne performance. La régression et les modèles de série chronologique sont basés sur la théorie mathématique classique. Ainsi, le comportement de ces modèles, est bien compris. L'évaluation des paramètres modèles est habituellement directe. Cependant, ces modèles tendent à fonctionner correctement seulement pour les systèmes d'énergie qui se comporte bien. Ils ne sont pas habituellement favorables aux changements brutaux de l'utilisation d'énergie due aux événements inattendus.

Le modèle artificiel de réseau neurologique fonctionne généralement mieux pour les bâtiments qui montrent un comportement non linéaire en consommation d'énergie. Cependant, le succès d'employer les RNA dépend d'un certain nombre de questions de conception telles que le choix des entrées, le rendement, le nombre de couches cachées, le nombre de neurones utilisés dans chaque couche et les algorithmes de formation utilisés.

Plusieurs accents ont été mis sur le modèle de réseau neurologique parce qu'il a l'avantage unique qu'aucun rapport clair entre la variable d'entrée et le rendement ne doit être défini avant que le modèle soit employé dans le processus de prévision. Une fois que l'entrée et le rendement sont choisis et introduits dans un RNA, le rapport entre l'entrée et le rendement est identifié par un processus d'auto apprentissage. L'exactitude de la prévision peut être améliorée en ajustant l'architecture du RNA. En raison de ce dispositif unique, le temps et l'effort qui sont normalement exigés pour établir un modèle mathématique approprié dans une méthodologie conventionnelle de prévision peut être réduit et limité.

CHAPITRE 3

LES RÉSEAUX DE NEURONES ARTIFICIELS POUR LA PRÉDICTION DE LA CONSOMMATION ÉNERGÉTIQUE DU BÂTIMENT

Les réseaux de neurones artificiels (RNA) sont des méthodes analytiques qui répliquent le fonctionnement du cerveau humain. C'est une approche qui provient de la science de l'intelligence artificielle et il y a eu nombreuses applications industrielles des RNA depuis quelques années. Les RNA consistent en un ensemble d'outils et de méthodes de calcul, pouvant être appliqués à des domaines aussi divers que la statistique, le traitement de signal, la reconnaissance des formes ou la prédiction.

L'application de la technique des RNA a démontré son potentiel dans le domaine de la prédiction des besoins énergétiques du bâtiment comme ce fut démontré dans le chapitre précédent. Cependant, une telle technique comme les RNA reste relativement approximative au niveau de ces résultats puisqu'elle est liée et limitée à des variables et des données d'entrées suffisantes pour une bonne prédiction mais incomplètes pour représenter d'une façon exacte et absolue un milieu particulier et spécifique comme la prédiction des consommations des bâtiments.

Le but de ce chapitre est de donner une vue générale sur les réseaux de neurones artificiels, ainsi que leur fonctionnement, afin de justifier le recours à ces méthodes dans la prédiction énergétique. Le chapitre décrit brièvement les types d'architecture des RNA, leurs caractéristiques, les concepts de base, le fonctionnement des neurones artificiels, l'apprentissage du réseau neurone et l'aspect dynamique des RNA.

3.1 Caractéristiques générales

Les RNA contiennent des neurones interconnectés qui permettent de mémoriser la structure d'un problème réel existant avec ces solutions et de l'appliquer à la résolution des nouvelles situations similaires.

Les neurones sont organisés en réseau, et le choix de la topologie particulière du réseau dépend en grande partie du type de problème à résoudre. Un RNA est normalement organisé en plusieurs couches. L'information dans un réseau de neurones se propage de couche en couche, parfois à l'intérieur même d'une couche, par l'intermédiaire de connexions pondérées. Le type de propagation le plus usuel est celui par anticipation, appelé aussi connectivité directe, ou encore unidirectionnelle [22]. Dans ce type de réseau, le signal se propage de l'entrée vers la sortie, et il n'existe pas de connexions à l'intérieur d'une même couche. Un exemple typique de ce type de réseau est le perceptron multicouche.

Un réseau de neurones opère en deux phases qui sont habituellement consécutives : une phase de conception et une phase d'utilisation. C'est durant la phase de conception que l'architecture du réseau est choisie et les paramètres fixés. C'est à cette étape que seront choisis, par exemple, le nombre de couches cachées et le nombre de neurones dans chacune des couches cachées. C'est également durant cette phase que le réseau est formé [22]. L'entraînement ou l'apprentissage est une procédure par laquelle la structure du RNA est ajustées afin d'extraire les tendances des données historiques mises pour des fins.(voir la section 3.4)

Une fois l'entraînement du réseau complété, ce dernier peut alors être utilisé pour réaliser le travail pour lequel il a été conçu. Quelques modèles récemment proposés poursuivent l'apprentissage durant cette phase. Ils sont connus sous le nom de modèles dynamiques et on s'y intéresse dans ce mémoire pour leurs potentiels d'adaptation. Cependant, dans la majorité des modèles, une fois que l'apprentissage est terminé, les poids des diverses connexions sont gelés à la valeur obtenue suite à l'entraînement du réseau.

Comme déjà mentionnée, la conception du modèle est une phase très importante dans l'utilisation des RNA. Cependant, le choix des variables d'entrées du RNA reste une étape critique dans la formation et l'apprentissage du réseau.

3.2 Les entrées pertinentes

Le problème de la détermination des entrées pertinentes se pose de manières très différentes selon les applications envisagées. En effet, si le processus que l'on veut modéliser est un processus industriel conçu par des ingénieurs, en général, on connaît les grandeurs qui interviennent et les relations causales entre celles-ci. Dans la prédition des besoins énergétiques du bâtiment, les sorties des RNA prennent souvent l'estimation de la charge électrique, thermique, ou bien la consommation des combustibles. Cependant, on trouve une grande diversité au niveau des entrées à cause de la variété des grandeurs physiques agissant dans ce domaine. Parmi les entrées les plus citées dans la littérature on trouve la température sèche et humide, l'ensoleillement, l'humidité, les indices du temps, les consommations, l'occupation, etc....

L'expérience a montré que les RNA cessent de bien performer si on surpassé un certain nombre d'entrées ou si l'on introduit des données non pertinentes. Dans ce cas, les entrées créent une perturbation au niveau de l'apprentissage des RNA ce qui va influencer les résultats de la prédition.

Dans ce contexte, et comme déjà mentionné dans le chapitre précédent, plusieurs articles dans la littérature ont traité le problème d'identifier les entrées pertinentes dans la prédition des consommations énergétiques. Dodier, dans sa revue [13], résume les méthodes les plus fréquentes pour traiter ce type de problème dans le domaine de l'énergie du bâtiment. Mackay utilise une technique qui comporte la détermination automatique de la pertinence – ARD- (*Automatic Relevance Determination*). Une méthode qui permet de détecter automatiquement les variables d'entrée appropriées, et qui est basée sur l'évaluation bayésienne [23]. On trouve aussi une méthode qui se base sur le mode statistique pour la corrélation non linéaire, nommé « *delta essai* » pour choisir les variables d'entrées qui sont appropriées pour la performance de la prédition [23]. Dodier, dans son étude, s'est basé sur la statistique de Wald [23] pour identifier les entrées non pertinentes. Si W (facteur de Wald) est assez grand pour être statistiquement significatif, l'entrée est considérée appropriée et elle est préservée. Si W n'est pas significatif, la variable d'entrée est enlevée de l'ensemble des entrées.

Dans le domaine des statistiques, on trouve aussi une méthode très efficace, connue sous le nom de l'analyse en composantes principales (ACP). Cette méthode qui a été adoptée ici pour la sélection des variables d'entrées pour le RNA, est une méthode classique utilisée pour la réduction des dimensions. Elle permet d'extraire à partir des données d'un nuage de points multidimensionnels les directions importantes via différents processus comme le calcul de la matrice de passage et la matrice de covariance ou les valeurs propres [24].

Aussi un autre problème qui demeurent dans ce type de recherche et auquel on va être confronté dans cette étude est celui des données des entrées manquantes et qui reste parfois un vrai handicap pour la performance de l'approche (section 5.1).

3.3 Fonctionnement du neurone artificiel

Un neurone est simplement une fonction non linéaire, paramétrée de ses variables d'entrée. L'intérêt des neurones réside dans les propriétés qui résultent de leur association en réseau, c'est à dire de la composition des fonctions non linéaires réalisées par chacun des neurones [25]. On distingue deux types de réseaux de neurones, les réseaux bouclés et les réseaux non bouclés [25].

- la sortie d'un réseau de neurone non bouclé est statique, et représente une fonction non linéaire de ses entrées et de ses paramètres. Les réseaux de neurones non bouclés à couches, dont les neurones cachés ont une fonction d'activation sigmoïde, sont souvent appelés perceptrons multicouche (ou MLP pour *Multi-Layer Perceptron*).
- les réseaux de neurones bouclés (ou récurrents) sont dynamiques et réalisent une (ou plusieurs) équations aux différences non linéaires, par composition des fonctions réalisées par chacun des neurones et des retards associés à chacune des connexions.

Aussi, tout réseau de neurones bouclé peut être mis sous forme canonique, comprenant un réseau de neurones non bouclé dont les sorties d'état sont ramenées avec un retard d'unité [25]. Les réseaux de neurones artificiels non bouclés sont formés de plusieurs couches : une

couche d'entrée, une ou plusieurs couches cachées et une couche de sortie. Les neurones peuvent être partiellement ou entièrement interconnectés comme celui de la figure 3.

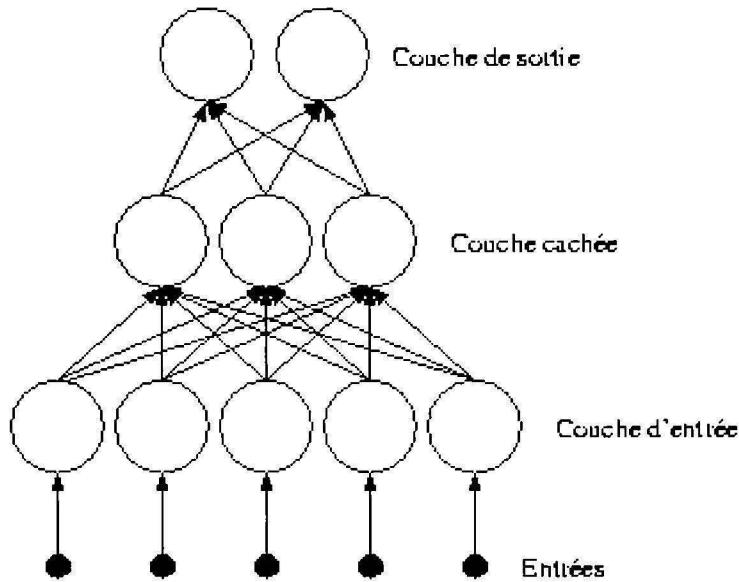


Figure 3 *Architecture de base pour un réseau de neurones artificiels non bouclés.*

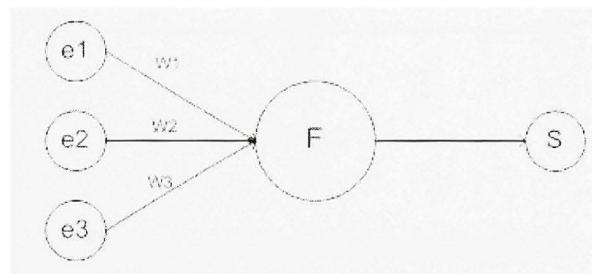


Figure 4 *Architecture du fonctionnement d'un neurone artificiel.*

Sur la figure 4 ci-dessus, le neurone est relié à trois entrées d'où il reçoit de l'information de chacune, qui sont présentées par e_1 , e_2 et e_3 . Les connexions des neurones n'ont pas la même importance, ils sont liés au poids synaptiques W_n affectés à chaque connexion. Les entrées et les poids sont combinés sous la forme d'une seule entrée E comme suit :

$$E = w_1 * e_1 + w_2 * e_2 + w_3 * e_3 = \sum w_i * e_i \quad (3.1)$$

Une fois la valeur de E connue, le neurone y applique une fonction F . Cette fonction est connue sous le nom de fonction de transfert ou fonction d'activation. Cette fonction, linéaire ou non, génère un signal de sortie qui est envoyé à la couche suivante [26]. Le choix de cette fonction est un élément important dans les RNA. Les fonctions d'activation se regroupent sous quatre types : fonctions linéaires, radiale, de seuillage et sigmoïde. Cette dernière qui est une fonction de régression non linéaire, est généralement la plus utilisé par les RNA pour modéliser des paramètres non linéaires. La forme générale de la fonction d'activation unipolaire continue –sigmoïde- (Figure 5) est définie comme suit [28]:

$$F(E) = \frac{1}{1 + e^{-\lambda \cdot E}}, \text{ avec } \lambda \geq 0 \quad (3.2)$$

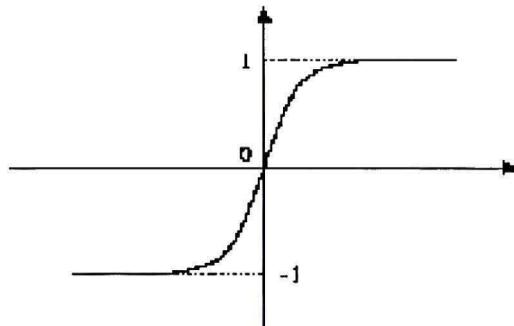


Figure 5 Fonction d'activation sigmoïde.

(Tiré de Sabourin, 2000)

(La référence complète du document est présentée dans la bibliographie)

Le produit S de $F(E)$ calculé par le neurone représente la sortie de ce dernier. La valeur S devient une nouvelle entrée pour les autres neurones qui sont connectés au neurone de référence, ou une sortie finale si le neurone appartient à la couche de sortie.

Chaque couche de réseau applique aux entrées leur propre fonction d'activation, il en résulte un certain nombre de sortie, qui sont à leur tour introduites sous forme de nouvelles entrées E_n pour la couche des neurones suivante et qui à son tour calcule avec leur propre fonction

d'activation les résultats qui seront transmis à la série de neurones suivantes, et ainsi de suite...

3.4 L'apprentissage du réseau de neurones

On peut définir l'apprentissage des RNA comme une procédure qui mène à estimer les paramètres des neurones du réseau, afin que celui-ci remplisse au mieux la tâche qui lui est assignée [25]. La phase d'apprentissage consiste à modifier selon l'algorithme d'apprentissage choisi tous les poids des connexions du réseau et toutes les valeurs de polarisation ou de seuil de chacun des neurones des couches cachées et des couches de sortie [22]. Dans le cadre de ces définitions, on peut distinguer deux types d'apprentissage que l'on emploie avec différents types d'architectures : l'apprentissage supervisé et l'apprentissage non supervisé [26].

- L'apprentissage supervisé :

Un ensemble de données divisé en entrées et sorties est présenté au réseau de neurones sous forme d'une base de données. Un algorithme d'apprentissage prend en charge le calcul de l'écart entre les sorties réelles et les sorties prédictives par le réseau de neurones. Cet algorithme fait en sorte que la valeur de l'écart devient minimale, tout en ajustant les poids des connexions au fur et à mesure.

- L'apprentissage non supervisé :

Dans ce type d'apprentissage, on laisse le réseau évoluer librement jusqu'à ce qu'il se stabilise, sans lui fournir les données de sortie, le réseau ajuste les poids des connexions seulement avec les données d'entrées. Par l'apprentissage non supervisé, le réseau cherche à détecter les similarités et les différences entre les variables présentées dans la base de données et à refléter ces propriétés dans les valeurs de sortie, d'où son utilisation pour le traitement du signal et l'analyse factorielle.

Après l'apprentissage, le RNA est testé en lui introduisant uniquement des valeurs d'entrées puis en vérifiant si les sorties produites sont acceptables.

L'architecture du RNA joue aussi un rôle important dans le processus d'apprentissage. Si le nombre de neurones dans la couche cachée est insuffisant, le RNA peut manquer

d'opportunités pour bien capturer les relations intrinsèques entre les variables de la base de données. Par contre, s'il y a trop de neurones dans la couche cachée, il peut en résulter un trop grand nombre d'itérations et nuire à la capacité de prévision ou de classification du RNA : au lieu d'apprendre à généraliser à partir des paires de données historiques soumises et ainsi capturer les caractéristiques des points individuels [26]. On dit alors que le réseau apprend par cœur ou mémorise la fonction qu'il tente de modéliser. L'approche la plus efficace pour déceler le sur-apprentissage par le réseau est la validation croisée (cross validation) : une partie des données, qu'on désigne par un ensemble de test, sert à stopper l'apprentissage si l'erreur d'apprentissage diminue ou stagne alors que l'erreur de vérification augmente, signifiant que le réseau commence à apprendre par cœur [26].

L'erreur de validation obtenue par la validation croisée, constitue un bon indice de la performance d'un réseau. Mais comme l'ensemble de test utilisé lors de la validation croisée fait partie du processus d'apprentissage, cet indice de performance s'avère biaisé à moins qu'il ne soit prévu de réserver un autre ensemble pour valider de façon indépendante le modèle suite à l'apprentissage en évaluant la justesse des prévisions effectuées par le modèle développé [26]. L'erreur de cet ensemble de données, désigné par l'ensemble de production ou de validation, peut être utilisée comme critère d'arrêt afin de déterminer le meilleur moment pour cesser l'apprentissage, tout en permettant de comparer l'habileté de généralisation de différents modèles [26].

3.5 Ajustement des poids synaptiques

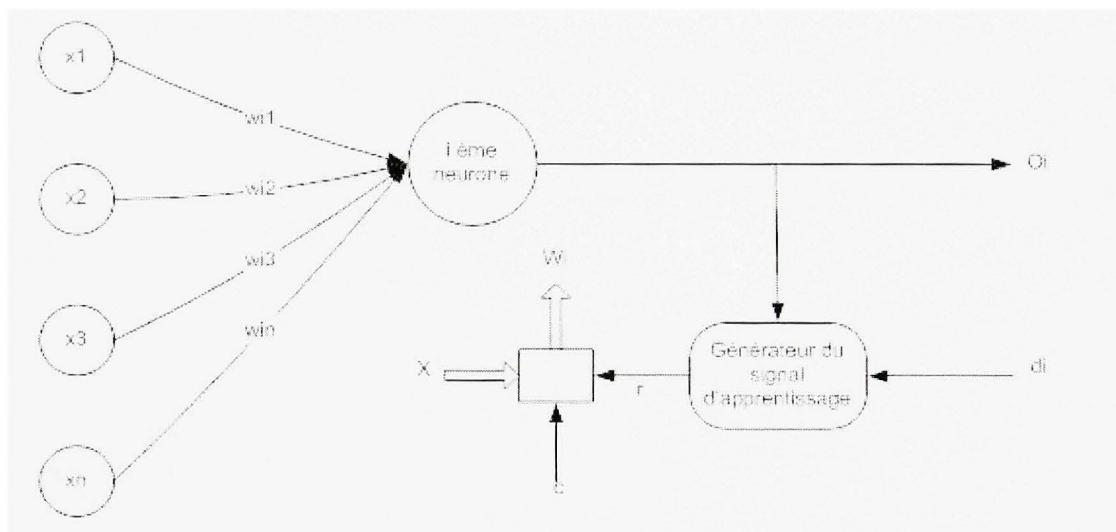
Peu importe le type d'apprentissage, les poids de connexions de neurone sont modifiés par un algorithme d'apprentissage dont l'objectif est de trouver le minimum de la fonction d'erreur dans un espace multidimensionnel [26]. Une des fonctions la plus utilisée par différents algorithmes d'apprentissage est celle des moindres carrés.

La rétropropagation est le nom d'un algorithme le plus utilisé en prévision. Le rendement d'un neurone particulier est défini par une fonction non linéaire appelé fonction de seuil.

Pendant un apprentissage supervisé, la rétropropagation utilise la méthode du gradient croissant pour minimiser les erreurs. Plus de détail sur le procédé de la rétropropagation peuvent être trouvés dans l'article de Kawashima [9]. Ce type d'algorithme est le mieux adapté, pour l'étude ici et il sert à entraîner le réseau Feedforward (réseau à propagation directe). Ce réseau est non bouclé et ne présente aucune rétroaction entre les neurones des différentes couches, car les activations sont projetées vers l'avant.

3.6 Règles d'apprentissage des réseaux de neurones

La figure ci-dessous (Figure 6), illustre l'apprentissage des poids associés aux connexions d'un neurone artificiel. La sortie désirée d_i est utilisée dans le mode d'apprentissage supervisé seulement [27].



Avec $X = (x_1, x_2, \dots, x_n)$ et $W = (w_{i1}, w_{i2}, \dots, w_{in})$

Figure 6 Schéma général pour l'apprentissage des poids synaptiques.

(Tiré de Zurada, 1992)

(La référence complète du document est présentée dans la bibliographie)

Le seuil correspond au poids W_{in} ; conséquemment la valeur de l'entrée x_n est fixée à -1. La règle d'apprentissage généralisée, proposée par Amari en 1990 est couramment utilisée dans

les travaux portant sur les réseaux de neurones [28]. Le vecteur de poids $Wi = [W_{i1} \ W_{i2} \ \dots \ W_{in}]^t$ augmente proportionnellement au produit de l'entrée x et du signal d'apprentissage r . Le signal d'apprentissage r est en général une fonction de Wi , x et quelquefois du signal fourni par le programmeur, soit d_i .

Ainsi, on obtient pour le réseau de la figure précédente (Figure 6) :

$$r = r(W_i, x, d_i) \quad (3.3)$$

L'ajustement du vecteur Wi produit lors de l'étape d'apprentissage au temps t , en accord avec la règle d'apprentissage généralisée est égale à :

$$\Delta W_i(t) = cr[W_i(t), x(t), d_i(t)]x(t) \quad (3.4)$$

Où c est un nombre positif appelé constante d'apprentissage qui détermine le taux d'apprentissage effectué à chaque itération.

Le vecteur de poids du $i^{ème}$ neurone adapté au temps t deviendra, à la prochaine étape $t+1$, égale à :

$$\Delta W_i(t+1) = W_i(t) + cr[W_i(t), x(t), d_i(t)]x(t) \quad (3.5)$$

Par convention, la $k^{ème}$ étape d'apprentissage sera noté

$$W_i^{k+1} = W_i^k + cr[W_i^k, x^k, d_i^k]x^k \quad (3.6)$$

Parmi les principales règles d'apprentissage on trouve celle de Hebb, du perceptron, du Delta, de Widrow-Hoff, de type corrélation, du ‘Gagnant-prend-tout’ et celle de Outstar [27].

3.7 Le mode incrémental des réseaux de neurones

L'avantage d'utiliser un modèle de prévision RNA plutôt qu'un autre modèle comme les séries chronologiques est que les RNA essayent à l'avance d'établir le modèle et d'estimer ces paramètres en se basant sur des données historiques. Cet avantage on peut le constater dans le chapitre de la littérature avec l'exemple des deux concours de SHOUTOUT I et II où les RNA ont montré une grande aptitude dans la prédiction des besoins énergétique par rapport aux modèles mathématiques.

Le modèle RNA le plus couramment utilisé dans la littérature est le modèle statique. Ce type de modèle, une fois établi, est rarement changé, le RNA garde les mêmes poids synoptiques, ce qui implique que la présence de nouvelles mesures plus récentes dans le temps sortant de l'ordinaire pour les mêmes variables d'entrées du système comme la température ou l'humidité peut rendre le modèle non valide. Ceci peut influencer directement un système de prédiction énergétique d'un bâtiment qui subit une modification. Autrement dit, un tel modèle statique n'est donc pas bien qualifié à prédire à court terme la consommation d'énergie, dans le but d'établir des plans opérationnels pour le bâtiment. En effet, le modèle de prédiction doit pouvoir s'adapter à des changements inattendus comme les variations climatiques ou la consommation énergétique.

Bien qu'un modèle de RNA statique puisse être capable d'accomplir une bonne prédiction des besoins énergétique du bâtiment pendant toutes les saisons, un modèle global à grande échelle de prévision de RNA doit être formé avec une quantité suffisamment grande de données historiques pour couvrir la plage de prédiction. La formation d'un RNA employant un si grand nombre de données est souvent une tâche ardue pour le processus de formation et d'apprentissage des RNA, par ailleurs le modèle s'avère être douteux face à des changements inattendus comme les conditions climatiques.

Pour ces raisons, une nouvelle approche est adoptée ici qui consiste en un modèle dynamique de RNA pouvant s'adapter instantanément en se mettant à jour chaque fois que des nouvelles données climatiques ou opérationnelles deviennent disponibles. Yang [29] propose deux approches adaptatives de RNA, le mode cumulatif et le mode avec fenêtre glissante. Un RNA peut être adapté périodiquement par l'augmentation de sa base

d'adaptation par des nouvelles mesures rassemblées. Le modèle cumulatif a l'avantage évident de pouvoir identifier les tendances saisonnières locales et globales de la variation d'énergie puisqu'il garde toutes les données enregistrées depuis sa formation. Son inconvénient principal se résume dans le fait que la quantité de données devient très grande à travers le temps, ce qui complique l'adaptation du RNA à chaque fois.

Alternativement, la taille de la base d'apprentissage peut être maintenue constante et des nouvelles données peuvent être rajoutées tandis que les plus anciennes vont être supprimées de l'ensemble de la base d'adaptation. Cette méthode d'adaptation du RNA est connue sous le nom de l'adaptation avec fenêtre glissante. La taille standard des données de recyclage de la fenêtre glissante permet une adaptation rapide pour le système de prédiction, mais présente aussi l'inconvénient que les données de l'adaptation peuvent seulement contenir l'information récente ce qui ne reflète pas le changement annuel ou saisonnier du modèle d'utilisation d'énergie.

CHAPITRE 4

PRÉDICTION DE LA CHARGE ÉLECTRIQUE DU REFROIDISSEUR DE L'ÉTS BASÉE SUR DES DONNÉES SIMULÉES

Le présent chapitre résume un ensemble de tâches réalisées pour prédire les besoins énergétiques du Pavillon A de l'École de technologie supérieure de Montréal basée sur des données simulées par le logiciel DOE-2. L'analyse en composantes principales (ACP) est utilisée pour identifier les variables pertinentes pour la formation et l'apprentissage des RNA. Aussi, un modèle de régression multivariables est utilisé pour extraire la combinaison la plus compacte des entrées RNA à l'échelle du temps.

Le chapitre met en avantage la prédiction via les RNA en comparant les résultats d'une étude basée sur un modèle purement mathématique (la régression multi linéaire) et une autre basée sur la prédiction statique en utilisant le RNA. L'approche dynamique des RNA est aussi détaillée dans ce chapitre avec ces deux modes – accumulative et à fenêtre glissante- et avec deux versions pour le choix des données de l'adaptation du RNA.

4.1 Sélection des données d'entrée avec l'ACP

Lorsqu'on conçoit un modèle à partir des mesures, il est indispensable que l'ensemble des variables d'entrée soit aussi réduit que possible [13]. En effet, à chaque entrée du modèle correspond un nombre de paramètres proportionnel au nombre de neurones cachés [9]. Il est donc nécessaire que :

- la représentation des entrées soit aussi compacte que possible,
- l'ensemble des entrées doit contenir tous les facteurs pertinents par rapport à la valeur à modéliser; tout en minimisant l'influence des perturbations ou du bruit entraîné par des paramètres superflus qui peuvent introduire des variations non significatives sur les variables d'entrée, ce qui peut constituer autant de sources d'erreur pour le modèle.

Préalablement à la conception du modèle proprement dit, il convient par conséquent de procéder à une sélection des entrées. Cette sélection revêt deux aspects [13] :

- la réduction de la dimension de l'espace de représentation des variables du modèle, et
- l'élimination des entrées qui n'ont qu'une faible influence sur la sortie.

Lorsque plusieurs mesures continues sont observées ou mesurées sur un ensemble d'individus ou d'objets, il est rare que toutes les mesures prises soient indépendantes, c'est-à-dire qu'elles apportent une information complètement différente l'une de l'autre. L'analyse en composantes principales (ACP) constitue un outil pour évaluer et représenter la redondance entre plusieurs mesures ou variables. Elle est souvent utilisée pour représenter graphiquement et de manière synthétique les faits saillants d'un ensemble de données. Grâce à cette méthode descriptive, les fichiers de données comprenant un grand nombre de variables (mesures) peuvent être analysés et résumés graphiquement avec la structure sous-jacente des données.

L'analyse en composantes principales (ACP) sur la base des données récupérées et complétée a comme objectif de définir les variables les plus pertinentes afin de bien décrire les observations et d'avoir une idée plus judicieuse sur les variables qu'on doit choisir pour l'apprentissage du RNA.

Les variables de la base de données prédéfinie sont :

| | |
|--|----|
| - jour de l'année | X1 |
| - l'heure du jour | X2 |
| - le type de jour | X3 |
| - la température humide | X4 |
| - la température sèche | X5 |
| - la radiation solaire | X6 |
| - la charge thermique de refroidissement | X7 |
| - la consommation électrique totale du refroidisseur | X8 |

Cette base représente une année typique extraite de l'historique de l'école sur plusieurs années et contient 8760 prises de données pour les 8 variables déjà indiqués.

Le Toolbox de Matlab contient une variété de fonctions qui permet de faire une analyse en composantes principales complète. L'ACP permet de définir la matrice de corrélation entre les différentes variables de la base des données qui est donnée dans le tableau 5 ci-dessous.

Cette matrice donne une première idée des associations existantes entre les différentes variables.

Tableau 5 Table de corrélation entre les différentes variables de la base de données

| | X1 | X2 | X3 | X4 | X5 | X6 | X7 | X8 |
|----|--------|--------|--------|-------|-------|--------|-------|-------|
| X1 | 1 | 0 | 0 | 0,278 | 0,261 | -0,059 | 0,1 | 0,12 |
| X2 | 0 | 1 | 0 | 0,049 | 0,072 | -0,007 | 0,192 | 0,242 |
| X3 | 0 | 0 | 1 | 0,051 | 0,048 | -0,018 | 0,03 | 0,037 |
| X4 | 0,278 | 0,049 | 0,051 | 1 | 0,991 | 0,257 | 0,665 | 0,738 |
| X5 | 0,261 | 0,072 | 0,048 | 0,991 | 1 | 0,334 | 0,693 | 0,767 |
| X6 | -0,059 | -0,007 | -0,018 | 0,257 | 0,334 | 1 | 0,41 | 0,424 |
| X7 | 0,1 | 0,192 | 0,03 | 0,665 | 0,693 | 0,41 | 1 | 0,969 |
| X8 | 0,12 | 0,242 | 0,037 | 0,738 | 0,767 | 0,424 | 0,969 | 1 |

À partir de la colonne X8, on peut définir le degré de la corrélation entre la consommation électrique totale du refroidisseur et les autres variables d'entrée. Le calcul des corrélations est fait à l'instant t pour toutes les variables, car le but de cette partie est juste le calcul de la corrélation et non la prédition pour les prochaines heures. Ces résultats sont illustrés dans la figure 7.

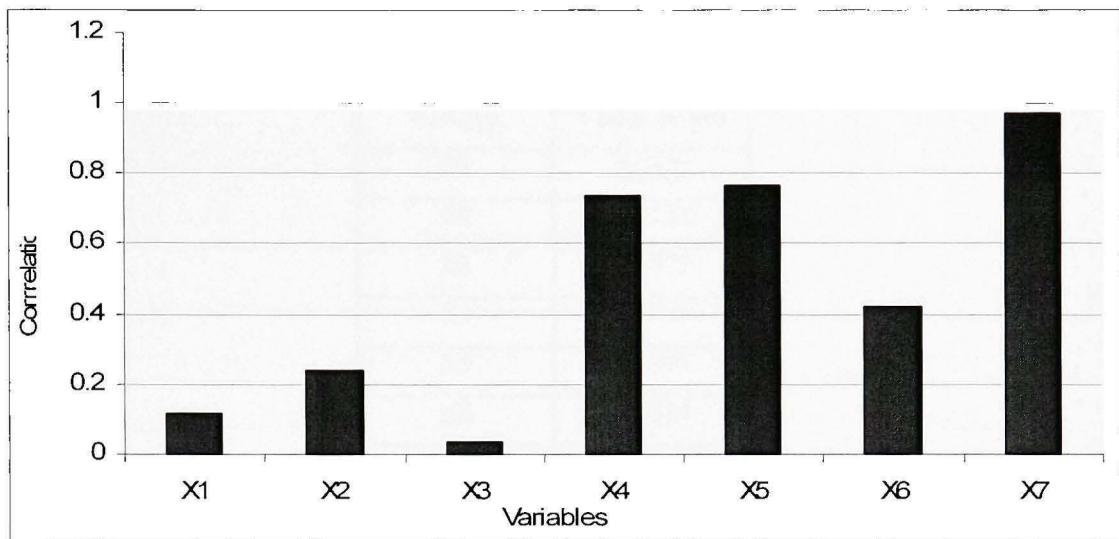


Figure 7 La corrélation entre la consommation électrique du refroidisseur et les variables d'entrée.

En analysant le graphique de la figure 7, on peut classer facilement les variables suivant leurs pertinences et leurs corrélations avec la consommation électrique totale du refroidisseur à l'instant t . On remarque que les températures à bulbe sec et humide sont les grandeurs physiques les plus influentes sur la consommation du refroidisseur avec des coefficients de corrélation d'ordre 0,76 et 0,73 respectivement, suivi par le flux de la radiation solaire (0,42). L'heure du jour et le jour de l'année ont aussi une influence notable sur le fonctionnement du refroidisseur (0,24 et 0,12). La composante la moins influente dans ce cas est le type de jour avec un coefficient de corrélation ne dépassant pas 0,04. La grandeur X7 représente la charge de refroidissement, qui est presque liée à la consommation électrique X8.

Les ACP permettent aussi de définir les vecteurs propres d'un nouveau repère sur lequel l'analyse sera basée en projetant les vecteurs des axes de l'ancien repère sur le plan constitué par les deux nouveaux principaux axes (Tableau 7). Dans ce cas, on a choisi les axes Y1 et Y2 qui sont associés aux valeurs maximales des valeurs propres 1,13 et 3,68 calculées suivant des lois statistiques des ACP réalisé par des fonctions incluses dans le Toolbox de Matlab (Tableau 6).

Tableau 6 Table des valeurs propres

| Variable | Valeur propre |
|----------|---------------|
| X1 | 0.0053 |
| X2 | 0.0223 |
| X3 | 0.4377 |
| X4 | 0.6896 |
| X5 | 0.9995 |
| X6 | 1.0234 |
| X7 | 1.1394 |
| X8 | 3.6820 |

Tableau 7 Table des vecteurs propres

| | y1 | y2 |
|----|--------|-------|
| x1 | -0,741 | 0,129 |
| x2 | 0,315 | 0,098 |
| x3 | -0,127 | 0,028 |
| x4 | -0,239 | 0,468 |
| x5 | -0,184 | 0,481 |
| x6 | 0,433 | 0,251 |
| x7 | 0,179 | 0,468 |
| x8 | 0,157 | 0,49 |

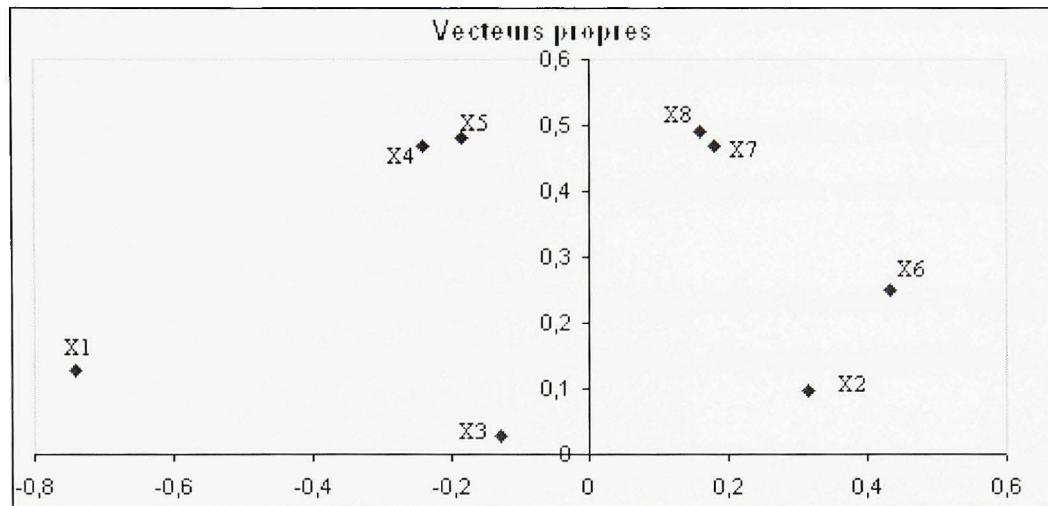


Figure 8 La projection de l'ancien repère sur les nouveaux axes.

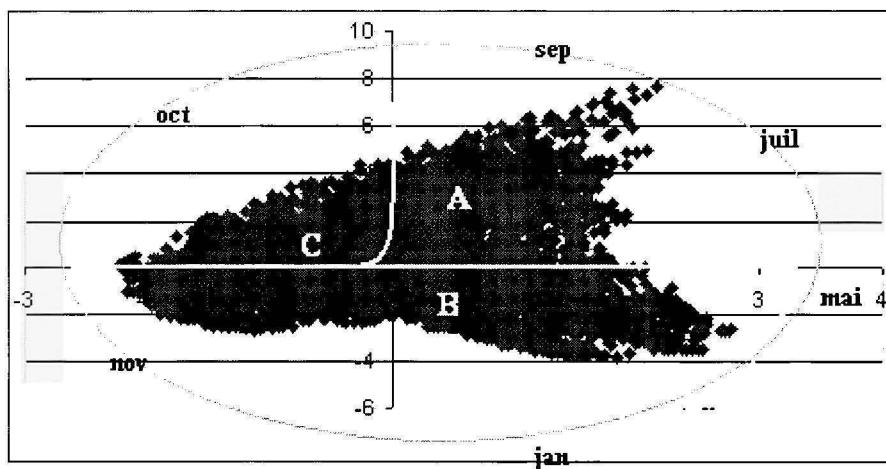


Figure 9 Schéma de distribution de la population.

En analysant quelques points de ce dernier schéma (Figure 9), trois zones de distribution de population (A, B et C) sont détectées selon la variable « jour de l'année » qui est fortement corrélée avec l'axe Y1 (axe des abscisses), et la consommation électrique du refroidisseur qui est corrélée avec l'axe Y2 (en ordonnées). Ces zones représentent les périodes de l'année selon lesquelles la consommation est un peu élevée :

- La zone A correspond à la période allant du mois de juillet au début septembre. C'est la période d'été où la consommation du refroidisseur est importante. Des valeurs maximales ont été enregistrées

- La zone B représente la période allant du mois de novembre à mai, c'est la saison hiver-printemps. Des valeurs de consommation minimales ont été enregistrées, ce qui est normal pour une telle période de l'année. L'orientation de la distribution des points de la gauche vers la droite montre bien la diminution de la consommation du refroidisseur au cours de cette période.
- La zone C : Correspond à la période des mois septembre et octobre. C'est le passage de l'été à l'hiver, ce qui justifie une consommation moyenne du refroidisseur.

Globalement, à partir de la distribution de la population au cours de l'année, on peut déduire que la consommation électrique suit un cercle qui représente bien les besoins du refroidisseur du bâtiment. Ces résultats prouvent l'utilité des ACP dans l'analyse de telles données.

4.2 Étude préliminaire avec un modèle de régressions multivariables

Le but de cette étude avec un modèle de régression multivariables est d'expliquer et de trouver la tendance de la variation de la charge électrique E_t à l'instant t par rapport à l'action de plusieurs variables explicatives qui ont été identifiées avec l'ACP précédente, comme l'heure du jour, les températures humides et sèches et la charge électrique à des instants antérieurs (jusqu'à $t-12$).

La régression multiple peut être utilisée à plusieurs fins, dont :

- trouver la meilleure équation ou modèle de prévision et en évaluer la précision et la signification.
- estimer la contribution relative de plusieurs variables explicatives sur la variation de la charge électrique.

Dans la bibliothèque Toolbox de Matlab, on trouve un modèle prédéfini pour le calcul des coefficients de la régression multiple. L'équation de la régression multiple est celle d'un hyperplan à p dimensions et dont la forme est la suivante :

$$E_t = r_0 + \sum_{i=1}^{12} a_i \cdot Th_{t-i} + \sum_{j=1}^{12} b_j \cdot Ts_{t-j} + \sum_{k=1}^6 c_k \cdot E_{t-k} + d_0 \cdot Hdj \quad (4.1)$$

Où :

E_t : la charge électrique à l'instant t (kW).

Th_i : la température humide à $t-i$ (avec $i=1$ à 12).

Ts_j : la température sèche à $t-j$ (avec $j=1$ à 12).

E_k : la charge électrique à l'instant $t-k$ (kW) (avec $k=1$ à 6).

Hdj : l'heure du jour à l'instant t .

a_i, b_j, c_k, d_0, r_0 : coefficients de régression.

Avec : $p=i+j+k+2$

L'étude est donc basée sur 31 variables présentant :

12 variables de température humide, de $t-1$ à $t-12$.

12 variables de température sèche, de $t-1$ à $t-12$.

6 variables de charge électrique, de $t-1$ à $t-6$.

1 variable qui présente l'heure du jour à l'instant t pour laquelle on doit prédire E_t .

Plusieurs régressions ont été réalisées avec des sous groupes de ces différentes variables pour trouver le regroupement le plus performant.

1) Dans un premier temps, onze régressions multiples ont été réalisées avec les températures humides, sèches et l'heure du jour sans la charge électrique des instants précédents. Les résultats sont présentés dans le tableau 8 ci-dessous. Chaque rangé correspond à une étude. Les -* - indiquent quelles variables étaient présentes dans l'étude. La performance de la régression est évaluée avec l'erreur moyenne (*Err-Moy*). *Err-Max* représente l'erreur maximale que la régression peut donner avec les entrées prédefinies.

Dans cette étude préliminaire, on a utilisé l'ensemble des données simulées (un an) pour établir les coefficients de la régression. Cependant, la performance est le rapport entre les consommations réelles et les consommations prédictes.

Tableau 8 Résultats des simulations de la régression multiple sans inclure la charge électrique des instants précédents

| cas | T humide | | | | | | | T sèche | | | | | | | Err-Moy % | Err_Max (kW) |
|-----|----------|-----|-----|-----|-----|-----|------|---------|-----|-----|-----|-----|-----|------|-----------|--------------|
| | t-1 | t-2 | t-3 | t-4 | t-5 | t-6 | t-12 | t-1 | t-2 | t-3 | t-4 | t-5 | t-6 | t-12 | | |
| 1 | * | | | | | | | * | | | | | | | 40.91 | 93.3 |
| 2 | * | * | | | | | | * | * | | | | | | 40.7 | 95.9 |
| 3 | * | * | * | | | | | * | * | * | | | | | 40.6 | 91.9 |
| 4 | * | * | * | * | | | | * | * | * | * | | | | 40.5 | 91 |
| 5 | * | * | * | * | * | | | * | * | * | * | * | | | 40.3 | 90.2 |
| 6 | * | * | * | * | * | * | | * | * | * | * | * | * | | 40.1 | 89.1 |
| 7 | * | * | * | * | * | * | | * | | | | | | | 40.8 | 92.6 |
| 8 | * | * | * | * | * | | | * | * | | | | | | 40.7 | 92.5 |
| 9 | * | * | * | * | | | | * | * | * | | | | | 40.6 | 92.3 |
| 10 | * | | | | | | | * | * | * | * | * | * | | 40.58 | 90.3 |
| 11 | * | * | * | * | * | * | * | * | * | * | * | * | * | | 39.29 | 85.3 |

2) Dans un second temps, douze régressions multiples ont été réalisées avec les températures humides, sèches, l'heure du jour et la charge électrique des instants précédents. Les résultats sont présentés dans le tableau 9.

Tableau 9 Résultats des simulations de la régression multiple incluant la charge électrique des instants précédents

| cas | T humide | | | | | | T sèche | | | | | | Consommation électrique | | | | | | Err-Moy % | Err_Max |
|-----|----------|-----|-----|-----|-----|-----|---------|-----|-----|-----|-----|-----|-------------------------|-----|-----|-----|-----|-----|-----------|---------|
| | t-1 | t-2 | t-3 | t-4 | t-5 | t-6 | t-1 | t-2 | t-3 | t-4 | t-5 | t-6 | t-1 | t-2 | t-3 | t-4 | t-5 | t-6 | | |
| 1 | * | * | * | * | * | * | * | * | * | * | * | * | * | * | * | * | * | * | 9.42 | 53.8 |
| 2 | * | * | * | * | | | * | * | * | * | | | * | * | * | * | * | | 9.48 | 52.7 |
| 3 | | | | | | | | | | | | | * | * | * | * | * | * | 9.6 | 53.2 |
| 4 | * | * | * | | | | | | | | | | * | * | * | * | * | * | 9.47 | 54 |
| 5 | * | * | | | | | | | | | | | * | * | * | * | * | * | 9.47 | 53.9 |
| 6 | * | | | | | | | | | | | | * | * | * | * | * | * | 9.45 | 54.3 |
| 7 | | | | | | | * | * | * | | | | * | * | * | * | * | * | 9.53 | 53 |
| 8 | | | | | | | * | * | | | | | * | * | * | * | * | * | 9.53 | 52.8 |
| 9 | | | | | | | * | | | | | | * | * | * | * | * | * | 9.5 | 52.8 |
| 10 | * | | | | | | | | | | | | * | * | * | * | * | | 9.46 | 54.3 |
| 11 | * | | | | | | | | | | | | * | * | * | * | | | 9.51 | 54.1 |
| 12 | * | * | | | | | | | | | | | * | * | * | * | | | 9.53 | 53.8 |

En analysant les données des deux tableaux, on peut remarquer que la prédiction de la charge électrique à l'instant t sans inclure les données des consommations précédentes aboutit à des résultats insatisfaisants (plus de 40% d'erreurs) (Tableau 8). Le deuxième tableau rassemble plusieurs combinaisons qui donnent une idée générale sur les variables les plus influentes et le pas du temps qu'il faut prendre en compte. On remarque qu'en incluant les consommations précédentes l'erreur moyenne passe notamment de 40% à moins de 10% (Tableau 9). Si on compare les résultats des deux tableaux, on peut présumer que les consommations ultérieures sont plus influentes que les données de températures sèche ou humide. Néanmoins, la meilleure combinaison reste celle du 6^{ème} cas du tableau 9, avec les six consommations électriques des heures passées et une mesure de la température humide d'une heure en avant et l'heure du jour. Une combinaison qui donne une erreur moyenne de 9,45%.

Le premier cas du tableau 9 reste plus précis que le 6^{ème} cas, mais ce dernier est plus avantageux grâce au nombre limité de ces variables d'entrées, chose qui peut faciliter les simulations après.

4.3 Types de données choisies pour la prédiction

La matrice de corrélation formé précédemment lors de l'ACP des données disponibles de la simulation de la charge de réfrigération donne la corrélation entre la consommation électrique du refroidisseur et les variables d'entrées. Les températures sèche et humide sont les variables les plus influentes vis-à-vis la charge du refroidisseur. On ajoute pour ces deux températures l'heure du jour avec son facteur de corrélation de 0,24 qui, joue un rôle très important dans la gestion de l'énergie du bâtiment puisqu'il représente la variable du temps. Cette dernière demeure importante dans la prédiction des besoins énergétique pour les prochaines heures.

Cependant, le modèle de régression multivariable a permis de mieux optimiser le choix au niveau du pas dans le temps. Donc, les variables sélectionnées pour former l'architecture du RNA de prédiction est comme suit :

- heure du jour
- température humide à l'instant $t-1$
- six charges électriques de $t-1$ à $t-6$

4.4 La répartition de la base de données simulée

La base de données d'origine, constituée de 8760 prises de mesures, inclut des données pour toutes les heures entre le premier janvier et le 31 décembre de l'année 2004. La variable de la charge du refroidisseur représente la demande électrique du refroidisseur du pavillon A de l'ÉTS, simulée avec le logiciel DOE-2 en considérant les données de plusieurs grandeurs physiques comme la température, l'ensoleillement et l'humidité qui influencent cette variable. Cette base de données synthétique puisqu'elle est simulée, est divisée en deux parties : une pour l'apprentissage des réseaux de neurones et l'autre pour tester et valider le modèle.

La base d'apprentissage représente 67% de la base d'origine, le reste est préservé pour le test et la validation. La base est répartie d'une façon structurée de manière à avoir deux jours successifs pour l'apprentissage tandis que le troisième est pour la validation et ainsi de suite.

4.5 Prédiction première par la régression multilinéaire (MLR)

La régression multiple est une méthode mathématique qui permet d'étudier la relation entre une variable Y et d'autres variables X_i . Exécuter une régression multiple consiste à se baser sur l'analyse d'un ensemble de données afin d'établir une approximation de la relation mathématique existante entre la variable Y et les variables X_i .

Les résultats d'une régression multiple sont d'une part le produit de l'équation de régression qui détermine la relation entre la variable Y et les variables X_i , ainsi que différents coefficients et graphiques qui vont permettre d'affiner l'analyse afin :

- d'examiner la fiabilité de la prédiction.
- de vérifier si la relation entre Y et X_i est réelle ou uniquement apparente.

La régression multiple peut faire l'objet de différents usages. Elle peut être utilisée afin de décrire des relations entre les variables X_i et d'analyser leur action sur la variable Y , afin de faire des estimations ou des prédictions ou alors on peut utiliser l'équation de régression comme un outil de contrôle (si on souhaite par exemple savoir de quelle manière modifier la valeur d'une variable X_i afin d'obtenir une valeur fixée de Y).

Matlab propose une fonction nommée ONES utile pour résoudre l'équation de la régression multiple. Si on prend dans notre cas la variable de sortie E , qui est la charge électrique du refroidisseur, et X_i les variables d'entrées, l'équation de régression sera sous la forme :

$$E = a_0 + \sum_{i=1}^n a_i X_i \quad (4.2)$$

Avec n est le nombre des variables.

D'après l'étude précédente sur le choix des entrées pertinentes, on a huit variables d'entrée :

Hdj : heure du jour

Th_1 : température humide à l'instant $t-1$

E_i : la consommation électrique à l'instant $t-i$ avec $i=1\dots 6$

La résolution sera donc sous la forme :

$$\begin{aligned} X &= [\text{ones}(\text{size}(e)) \text{ } hdj \text{ } th_1 \text{ } e_1 \text{ } e_2 \text{ } e_3 \text{ } e_4 \text{ } e_5 \text{ } e_6]; \\ a &= X \setminus e; \end{aligned}$$

Où a est le vecteur des coefficients de la régression multivariées.

Les charges estimées sont calculées par une équation sous la forme :

$$E_{\text{estim}} = X^* a;$$

La résolution mathématique par Matlab en utilisant la partie apprentissage de la base des données simulés par le logiciel DOE-2 pour le pavillon *A* de l'ÉTS donne un vecteur de coefficient a sous la forme (Tableau 10) :

Tableau 10 Vecteur des coefficients pour la régression multivariable

| Coefficient de a_i | valeur |
|----------------------|-----------|
| a_0 | -13,073 |
| Hdj | -0,12632 |
| Th_{t-1} | 0,43892 |
| E_{t-1} | 1,0746 |
| E_{t-2} | -0,062976 |
| E_{t-3} | 0,0061513 |
| E_{t-4} | -0,12374 |
| E_{t-5} | -0,011869 |
| E_{t-6} | -0,058624 |

Les résultats de la régression multilinéaire obtenus par l'utilisation de la fonction ONES du Toolbox-Matlab sur la partie validation de la base des données simulées, permettent de calculer le CV=13,74%, le RMSE=8,12 kW et de tracer la courbe de comparaison entre les charges prédites par la régression MLR et les données de validations réelles (Figure 10).

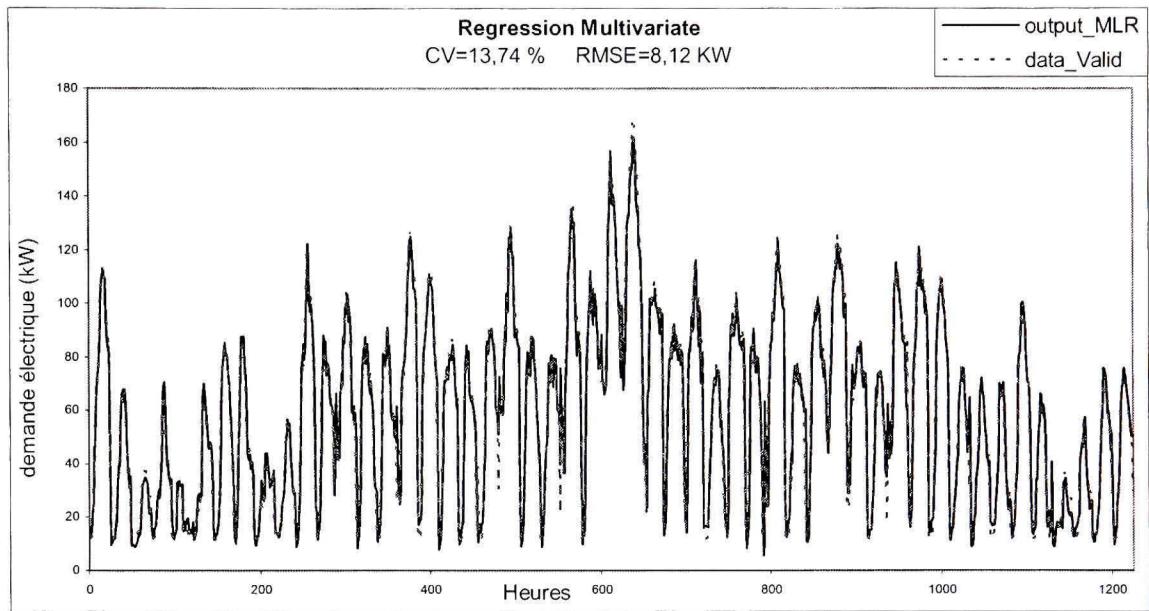


Figure 10 Comparaison entre les charges réelles et les charges prédictes par la régression multilinéaire.

On fait un agrandissement sur la période entre les heures 800 et 900 heures pour bien montrer la qualité de la prédiction des MLR dans la figure 11.

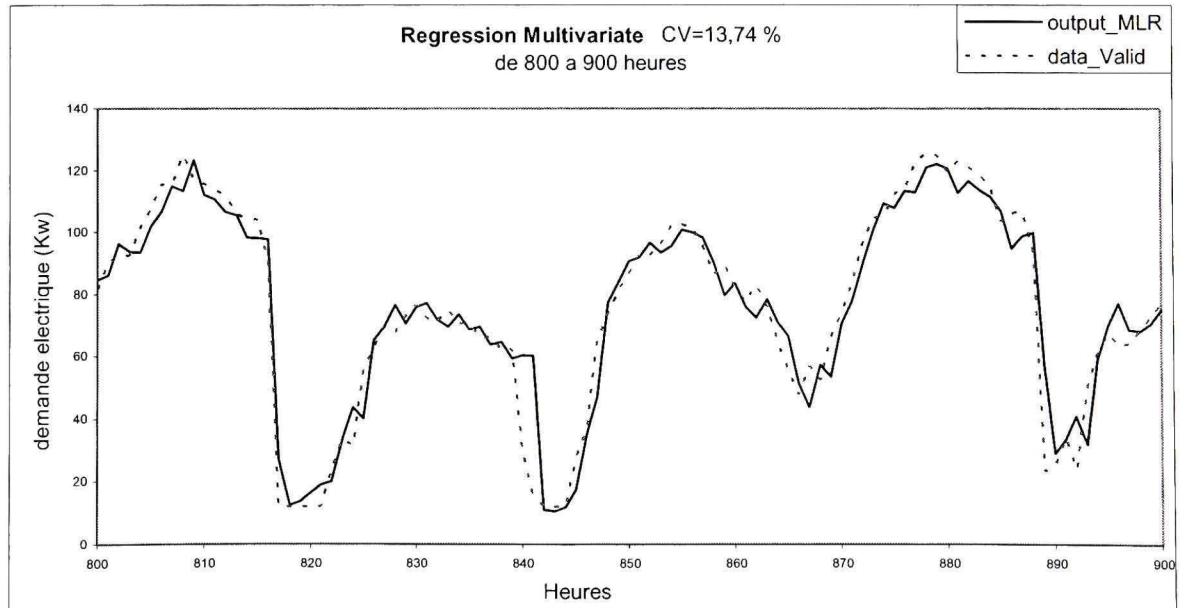


Figure 11 Agrandissement de la figure 10 sur une période de 800 à 900 heures.

4.6 Prédiction statique via les réseaux neurones artificiels

4.6.1 Choix du modèle

Le choix du modèle de RNA qu'on va utiliser dans les simulations est basé sur l'analyse de la littérature dans la documentation bibliographique ainsi que des tests de comparaison qui ont été effectués. L'architecture de réseau est formée de trois couches de neurones, une couche d'entrée, une couche cachée et la couche de sortie. La première couche contient $n=8$ neurones, ce qui représente le nombre de variables d'entrées pour le réseau (Figure 12). La couche cachée est formée de $2n+1=17$ neurones [19]. Enfin la couche de sortie contient un seul neurone et présente la valeur de sortie, c'est-à-dire la charge prédictive du refroidisseur à l'instant $t+1$.

Le choix des données pertinentes basé sur les deux études (ACP et régression multivariables) peut être présenté sous la forme suivante (Figure 12)

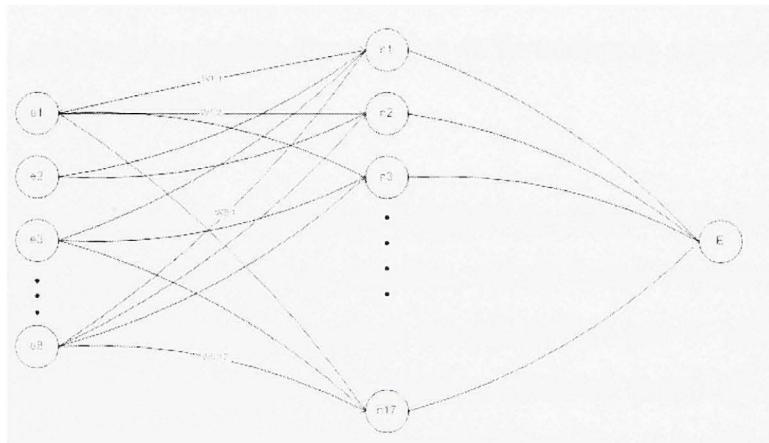


Figure 12 L'architecture utilisée pour la formation du RNA.

Avec :

e_1 : heure du jour

e_2 : température humide à l'instant $t-1$

e_3, \dots, e_8 : charge électrique de $t-1$ à $t-6$

E : la charge électrique prédictive pour l'instant $t+1$

$W_{i,j}$: les poids synaptiques du RNA

n_i : les neurones de la couche cachée

Le Toolbox de MATLAB offre aussi plusieurs algorithmes avec la rétropropagation de l'erreur pour former le réseau. Après plusieurs tests, le mieux adapté s'avère celui du –Feed Forward Backpropagation- en raison de sa performance. D'autres architectures ont aussi été essayées telles que utilisé plus d'une couche cachée ou plus de $2n+1$ de nombre de neurones au niveau de la couche cachée, mais il fut constaté que cela augmente uniquement la complexité de l'architecture du réseau et le temps d'apprentissage, ce qui, généralement, diminue la performance du modèle RNA utilisé.

Pour la fonction de l'apprentissage, on a choisi celle de Levenberg-Marquardt (LM), puisque la taille moyenne de la base de données de l'apprentissage du réseau. Le LM reste l'algorithme le plus adapté surtout pour le gain de temps au niveau de l'apprentissage. L'inconvénient principal de l'algorithme LM est qu'il exige le stockage de quelques matrices qui peuvent être très grandes pour certains problèmes. La taille de la matrice de Jacobian est $Q \times n$, où Q est le nombre d'ensembles de formation et n est le nombre de poids et de polarisations dans le réseau [30].

Pour l'activation des neurones, on a choisi la TANSIG (la fonction d'activation unipolaire continue –sigmoïde-) comme fonction de transfert, vu ses caractéristiques mathématiques (voir section 3.3). La fonction de performance est déterminée par la MSE (Mean-Square Error) et on essaye de lui attribuer une valeur minimale (Matlab prend 10^{-5} par défaut) pour le nombre d'époques (le processus d'apprentissage de l'entrée à la sortie du RNA pendant une seule itération). La solution semble converger après 300 itérations. Les poids initiaux du réseau sont choisis arbitrairement.

4.6.2 La normalisation des données

Dans la plupart des cas, la magnitude et l'étendu des valeurs des variables d'entrées et de sorties du réseau sont différents. Par exemple, dans cette étude la grandeur numérique de la température varie entre 55 et 100 °F et celle de la charge électrique varie entre 15 et 130 kW. Il est préférable de normaliser ces données de sorte qu'elles aillent le même ordre de grandeur, pour faciliter et améliorer l'apprentissage du réseau de neurones. Dans les expériences suivantes, toutes les variables d'entrée et de sortie sont normalisées pour avoir des valeurs entre -1 et 1.

Matlab propose une fonction (*premnmx*) réservée pour réaliser ce type de normalisation :

$$[P_n, \min_p, \max_p, T_n, \min_t, \max_t] = \text{premnmx} (P, T);$$

Où P et T représentent les matrices qui contiennent les données d'entrées et de sorties originales. P_n et T_n , sont les nouvelles matrices normalisées qu'on va introduire dans le réseau. Les vecteurs \min_p , \max_p , \min_t et \max_t sont la coordination entre les matrices réelles et les matrices normalisées et contiennent les bornes minimum et maximum pour chaque variable des matrices P et T . Elles sont exigées pour calculer de nouveau la sortie des RNA à ses unités originales après que le processus de la formation soit complété. Ce dernier traitement est accompli suite à une fonction (*postmnmx*) dans Matlab qui est :

$$[T_nv] = \text{postmnmx} (\text{outval}, \min_t, \max_t);$$

Où outval est la sortie normalisée prédite par le RNA et T_nv représente la sortie prédite, mais à l'échelle réelle.

4.6.3 La formation et le test du modèle statique

Comme indiqué dans la section 4.4, deux tiers des données sont réservés pour l'apprentissage du réseau. Le reste sert au test et à la validation. L'apprentissage et la

validation ne couvre que la période de l'été qui dure du 1^{er} mai au 30 septembre de l'année 2004, c'est la période où le refroidisseur est mis en marche. En tenant compte de l'étude à la section 4.2, le choix des variables d'entrée pour le modèle de prédiction est limité aux suivantes :

- les six consommations électriques des heures précédentes (de $t-1$ à $t-6$)
- une mesure de la température humide à l'instant $t-1$
- l'heure du jour (l'heure de prédiction t).

Les outils de Matlab permettent de visualiser les différentes étapes de l'apprentissage des réseaux de neurones. La performance par rapport au nombre d'époques est définie par l'erreur des moyennes carrées (MSE) entre les données prédites par le RNA et les données introduites comme sortie présumée du RNA (Figure 13).

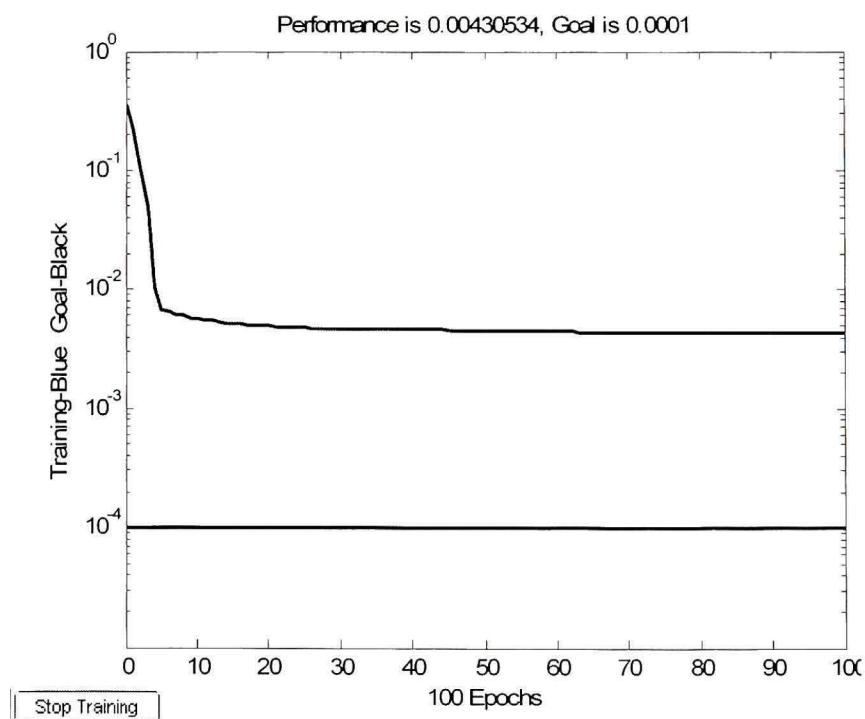


Figure 13 La performance par rapport au nombre d'époques.

La taille moyenne des données d'entrées pour le RNA permet l'utilisation de Levenberg-Marquardt comme fonction de formation pour l'apprentissage du réseau, élément qui a dû accélérer le processus d'apprentissage et de convergence. Sur le graphe ci-dessus on remarque bien que le MSE a atteint son minimum (0,0043) avant la 20^{ème} époque.

La figure 14 illustre la qualité de l'apprentissage du réseau avec les deux tiers des données disponible réservé pour l'apprentissage du RNA, il compare le rendement du RNA au niveau de la formation (*output-net*) et les données présentées comme cible pour le réseau (*Target*). On remarque que les courbes des deux variables sont presque identiques.

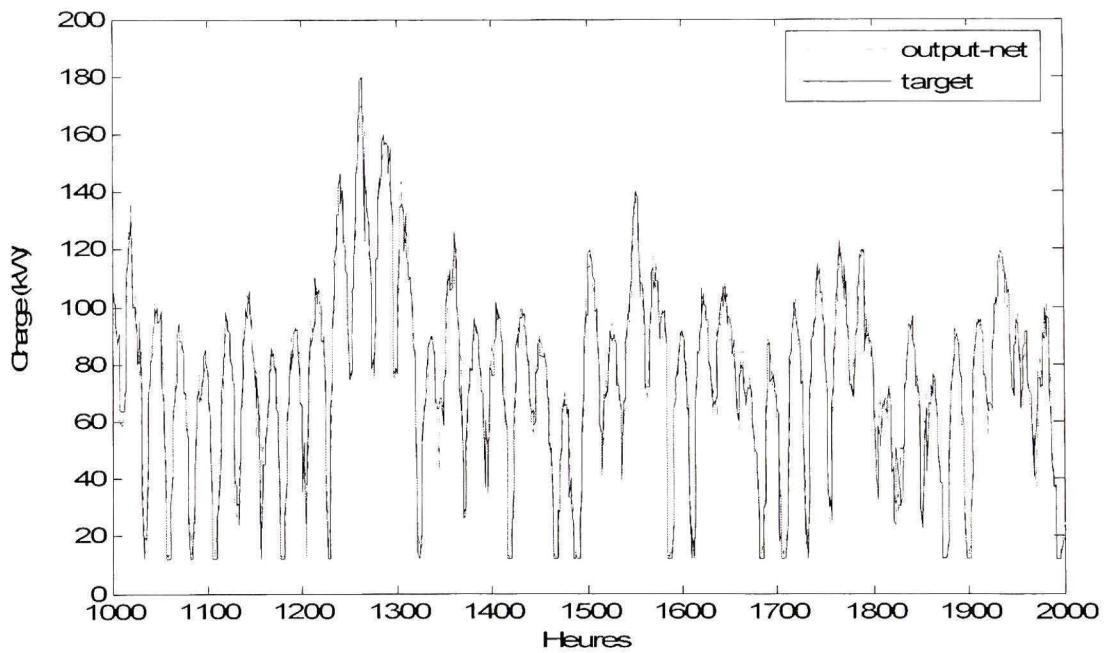


Figure 14 Comparaison entre la cible et le rendement du RNA durant l'apprentissage.

La figure 15 ci-dessous montre le niveau d'erreur entre les deux précédentes grandeurs, la cible du RNA et son rendement au court de l'apprentissage. Elle est définie sous la forme : Erreur(t)= $E(t) - Ep(t)$, avec $Ep(t)$ la variable prédictive par le réseau et $E(t)$ la cible de réseau. L'erreur est concentrée entre -20 et 20 kW, avec quelque dérapage au niveau de l'apprentissage qui peut atteindre une différence de -45 kW.

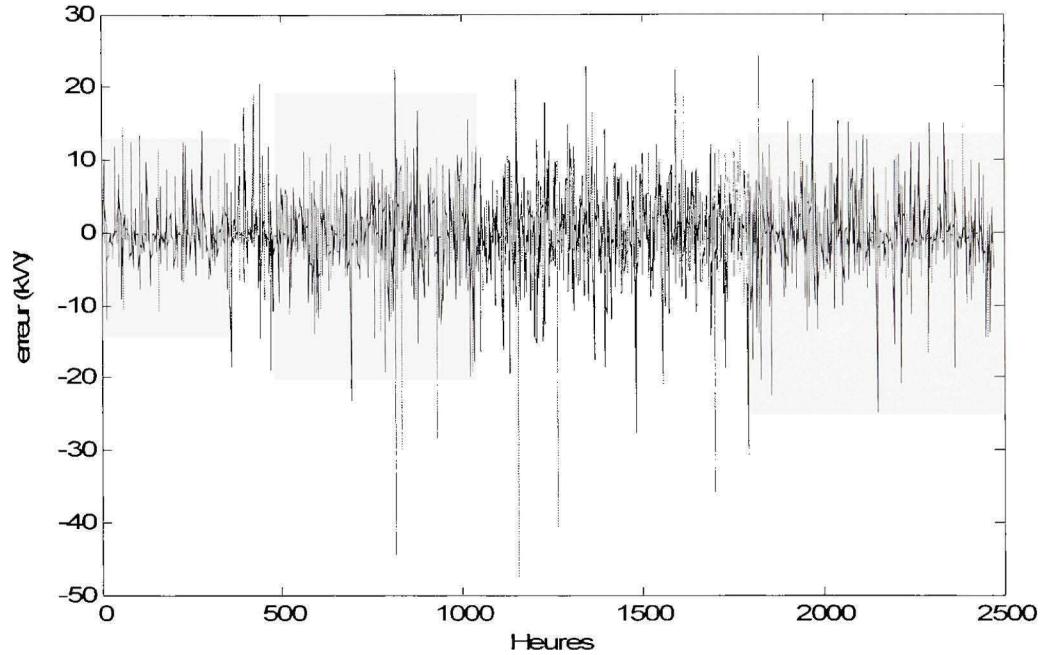


Figure 15 La différence entre la cible et le rendement du RNA durant l'apprentissage.

On trouve aussi dans Matlab une fonction *postreg* capable de tracer la finesse entre les données réelles et les données prédictes par le réseau de neurones.

$$[m, b, r] = \text{postreg}(\text{Pred}, \text{Reel});$$

m: pente de la régression linéaire

b: facteur d'interception

r: l'erreur relative (*r*=1 signifie la corrélation parfaite)

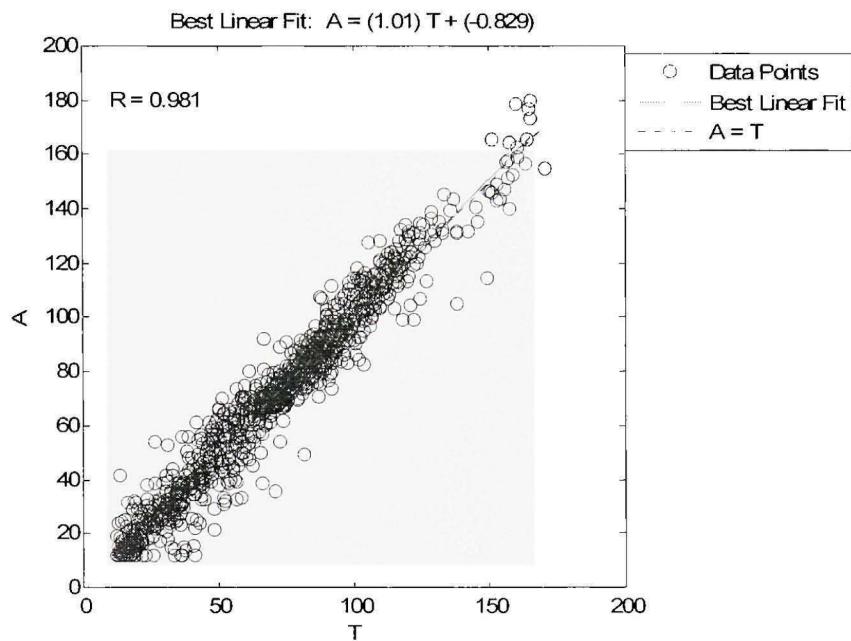


Figure 16 La finesse de la prédiction statique avec les données de validation pour les RNA.

Comme on le remarque sur le graphe ci-dessus (Figure 16), cette fonction permet d'évaluer visuellement la qualité de la prédiction suivant la distribution de nuage des points et aussi via le coefficient de l'erreur relative ($R=0.98$). L'utilisation du réseau de neurones ainsi formé pour la prédiction statique de la charge électrique simulée du refroidisseur de l'ETS a donné un $CV=10,8\%$ et un RMSE de l'ordre de 6,4 kW. La figure 17, montre le niveau de performance du réseau de neurones dans la prédiction de la charge électrique en comparant les charges prédites avec celles de la base de validation.

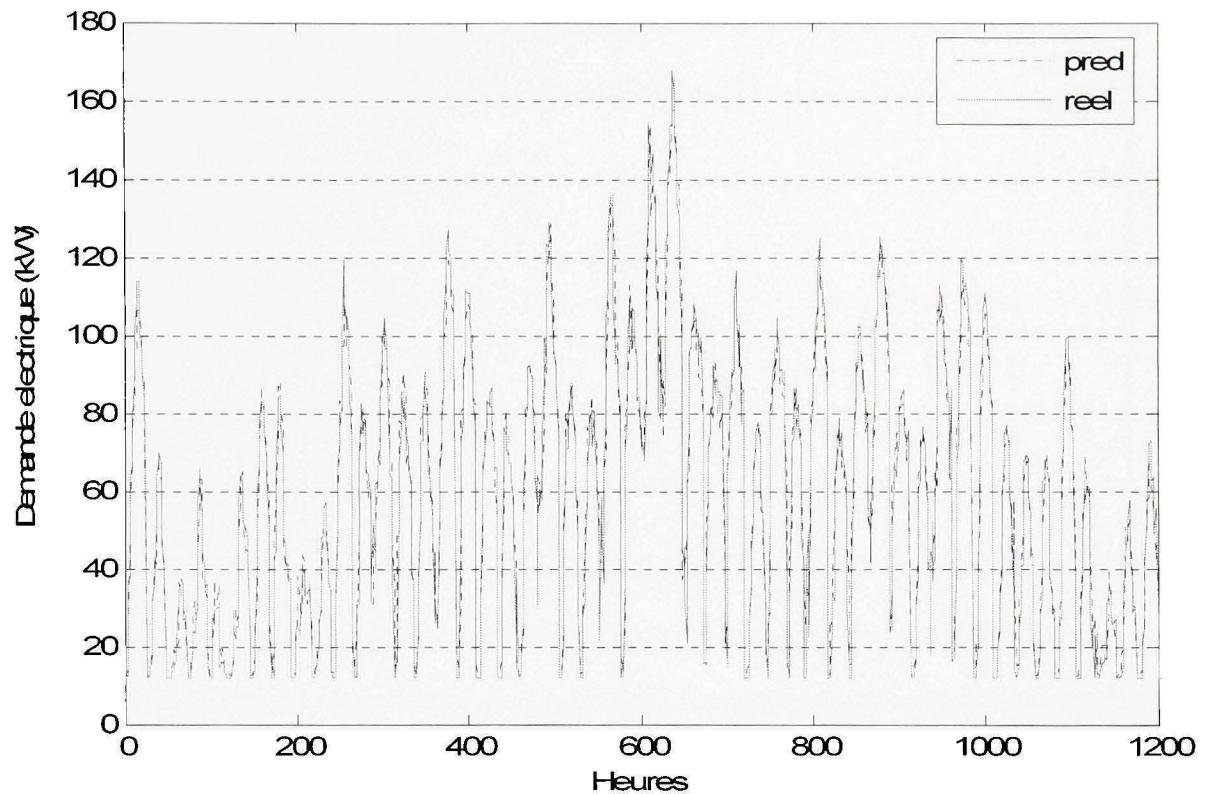


Figure 17 Comparaison entre les charges réelles et les charges prédictes par un RNA statique avec les données de validation.

On fait un zoom sur la période allant de l'heure 800 à l'heure 900 pour bien montrer la qualité de la prédiction des RNA à la figure 18.

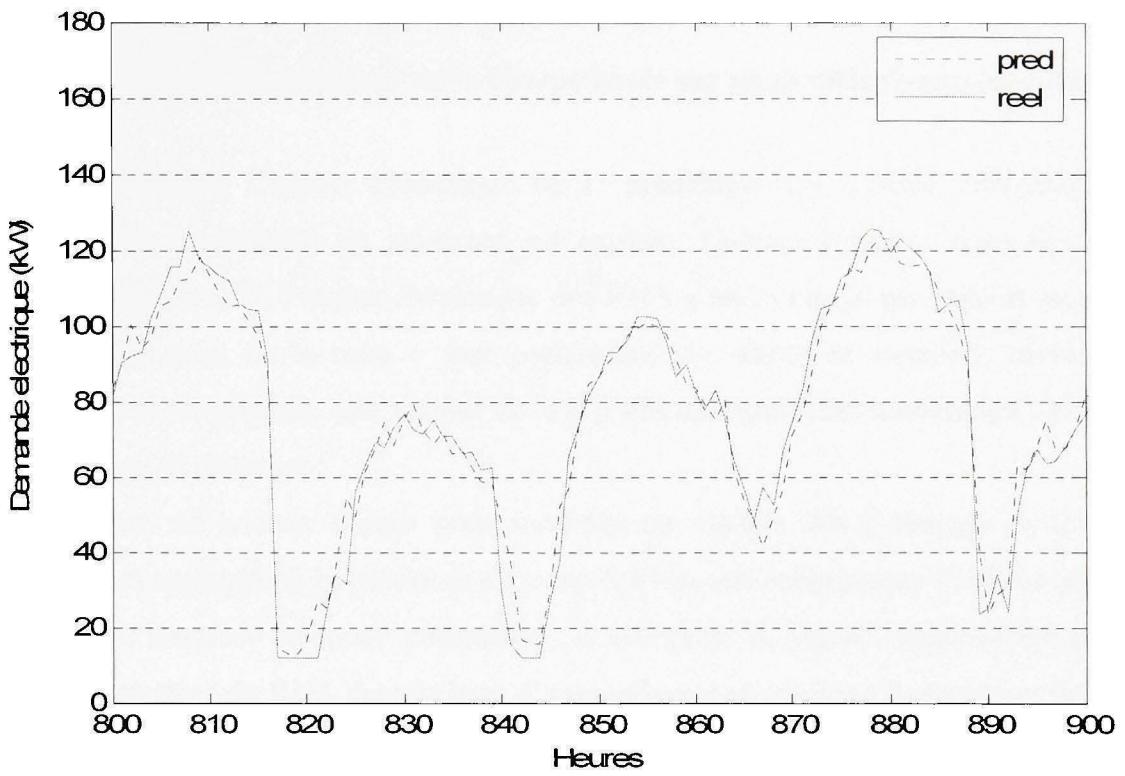


Figure 18 Agrandissement de la figure 17 entre les heures 800 et 900.

4.6.4 Résultats et comparaison

Tableau 11 Résultats des simulations –régression multilinéaire et RNA

| Moyen de prédiction | CV % | RMSE (KW) |
|-------------------------------|-------|-----------|
| Régression multilinéaire | 13,74 | 8,12 |
| Réseaux de neurones statiques | 10,8 | 6,4 |

Avec une différence de 3% (13,74-10,8) au niveau du CV et presque 2 kW (8,12-6,4) pour le RMSE, les deux expériences démontrent un léger avantage de la prédiction via la méthode de réseau de neurones par rapport à la régression multilinéaire. Par conséquent, en fonction de résultats obtenus, cette recherche adapte l'architecture du réseau neurones utilisé afin de l'améliorer. Le mode dynamique des RNA est donc testé dans la prochaine section.

4.7 La prédition en ligne de la charge basée sur un modèle dynamique des RNA

Dans cette section, l'aspect dynamique de la prédition des besoins énergétiques du bâtiment avec les réseaux de neurones est exploré. Comme expliqué dans le chapitre précédent (section 3.7), l'aspect dynamique des RNA a un avantage par rapport au modèle statique, c'est celui de la mise à jour permanente du réseau de neurones servant à la prédition. Par conséquent, cela permet de tirer profit des nouvelles données qui deviennent disponibles au fil du temps.

Généralement, on a deux façons pour modifier un modèle RNA statique et le rendre dynamique et approprié à la prévision en ligne des besoins énergétiques [29]. La première approche est nommée le mode cumulative, il accumule toutes les données enregistrées depuis la formation du RNA dans la base d'apprentissage et applique l'adaptation du réseau en employant l'ensemble entier de ces données. La deuxième approche est connue sous le nom de mode avec fenêtre glissante. Cette approche est plus intéressante que la précédente puisque, dans sa forme intégrale, le réseau prend en compte toutes les données enregistrées depuis sa formation, mais la structure de la base d'adaptation du réseau maintient une quantité fixe de données pour l'adaptation qui avance dans le temps. Le schéma ci-dessous (Figure 19) présente le principe du fonctionnement de la fenêtre glissante.

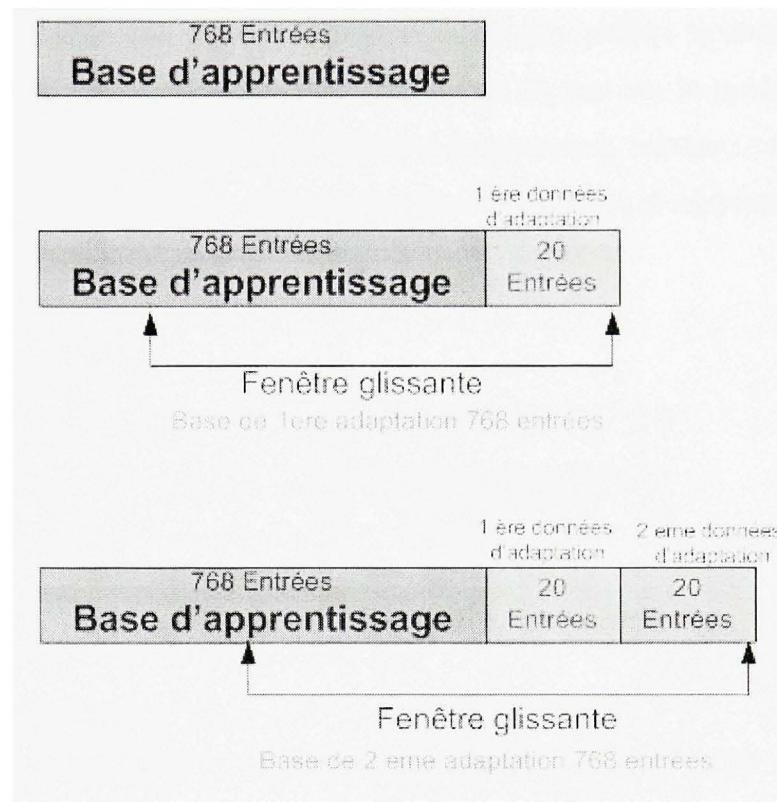


Figure 19 *Principe du fonctionnement de la fenêtre glissante.*

La répartition de la base de données est différente de celle de la prédiction statique. L'expérience prendra en compte toujours les données simulées de la même période d'été. Les mesures du mois de mai (températures et consommations électriques) sont conservées pour la formation et l'apprentissage du réseau. Le modèle statique précédent est utilisé comme modèle de base, c'est-à-dire on adopte la même structure (nombre de couches cachées, nombre de neurones,...) pour l'apprentissage de base. Cependant, deux versions seront préservées pour l'adaptation et qui sera prise en compte après l'accumulation d'un certain nombre fixé de nouvelles mesures enregistrées. Le test de la qualité de prédiction et la validation de l'adaptation du réseau sont effectués à la période du 1^{er} juin au 30 septembre 2004.

L'adaptation du réseau est déclenchée automatiquement chaque fois qu'un nombre prédefini d'entrée qui sort de l'ordinaire (température ou charge électrique –voir les deux versions qui suivent) est accumulé. Pour cela, on a développé un algorithme qui s'exécute à chaque

heure (le temps d'avoir une nouvelle entrée et aussi pour prédire la charge horaire) et qui peut trancher entre les nouvelles données influentes ou non sur la prédition des charges électriques. Le schéma à la figure 20 présente le processus incrémental – apprentissage, prédition et adaptation- tout en incluant les deux techniques d'adaptation du RNA (base cumulative ou à fenêtre glissante).

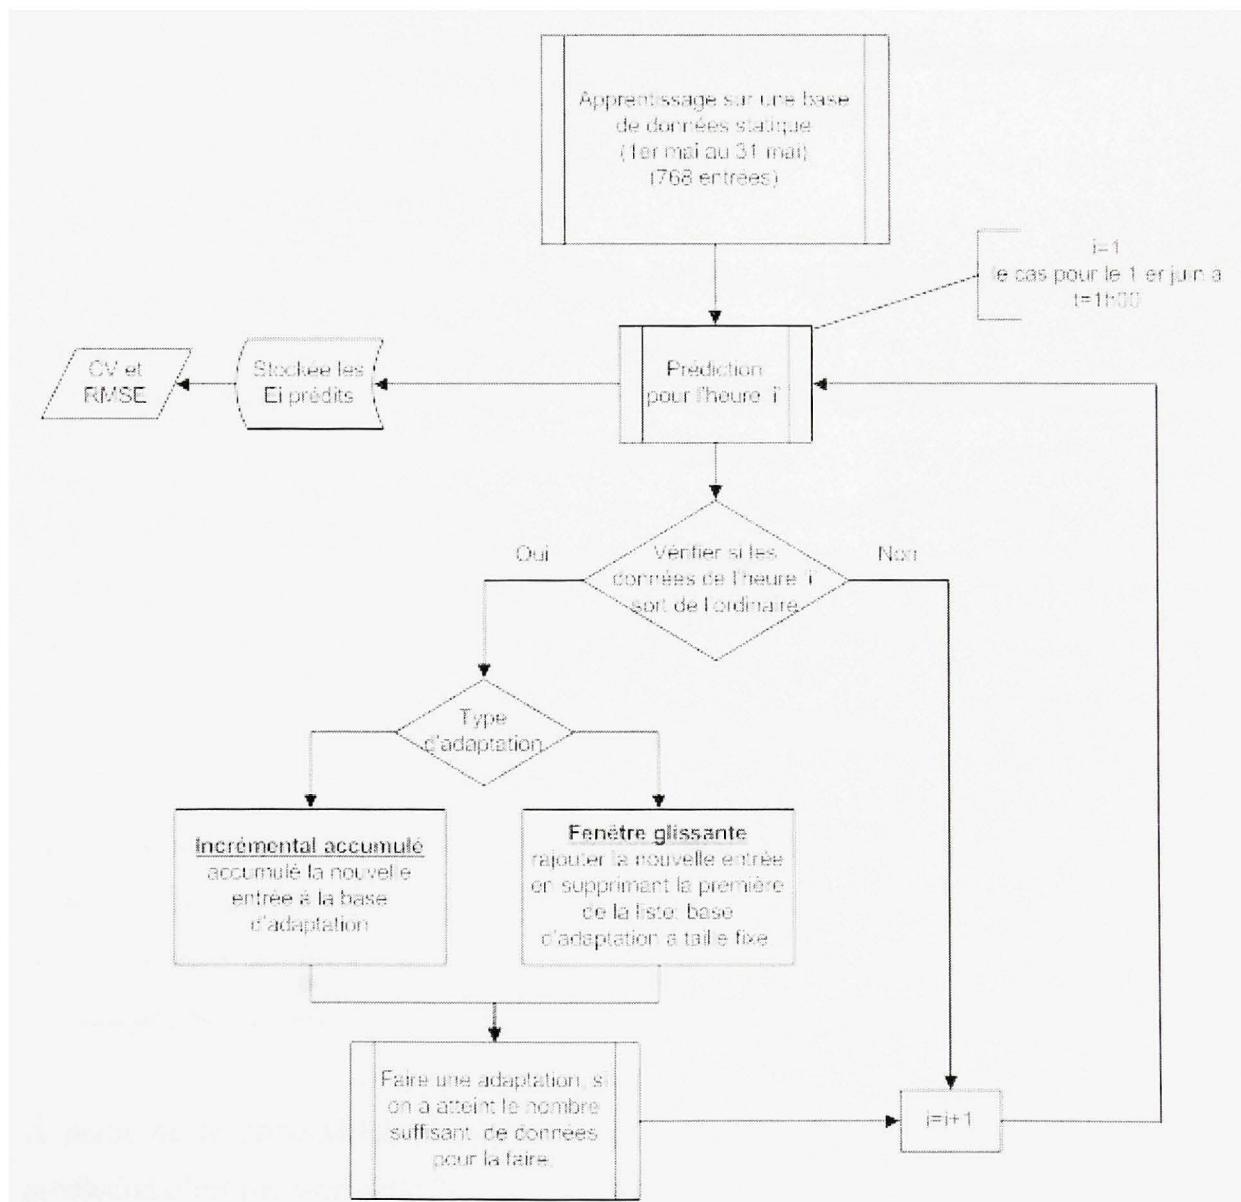


Figure 20 Processus du fonctionnement du mode dynamique de la prédition avec les RNA.

L'adaptation du RNA est limitée par les critères d'une journée qui sort de l'ordinaire. Pour cela on a adopté deux algorithmes qui présentent deux expériences distinctes sur la façon de sélection des données non prises en compte par le réseau de neurones.

Version N 1 :

Dans cette version, les critères d'une journée non ordinaire sont définis en se référant aux températures et charges électriques minimales et maximales de la base d'apprentissage du réseau. L'adaptation se fait aussi à chaque fois que le système détecte une nouvelle donnée non comprise entre le Min et le Max de la base d'apprentissage.

L'algorithme de sélection est de la forme suivante :

- 1- lire la base d'apprentissage et définir le Min et le Max des températures et des charges électriques (T_{\min} , T_{\max} , Ec_{\min} et Ec_{\max}).
- 2- lire à chaque heure les nouvelles données enregistrées pour l'adaptation (T_i' et Ec_i').
- 3- déclencher l'algorithme de sélection des données :

Si $T_i' > T_{\max}$ ou $T_i' < T_{\min}$ ou $Ec_i' > Ec_{\max}$ ou $Ec_i' < Ec_{\min}$

Insérer les nouvelles données dans la base d'apprentissage, en augmentant la taille de cette dernière (incrémental cumulatif) ou en gardant une taille fixe (fenêtre glissante).
- 4- faire une adaptation ou pas, suivant l'étape 3 de l'algorithme.

Sur une base de prédiction et d'adaptation contenant 2928 entrées, on a pu constater avec cette méthode de sélection que 16 entrées qui sortent de l'ordinaire, ce qui implique le même nombre d'adaptations qui permettent au RNA de s'adapter à des conditions climatiques ou aux besoins énergétiques non inclus à la formation du réseau auparavant.

À partir de la présentation de la finesse (Figure 21), on constate que le niveau de la prédiction n'est pas assez satisfaisant. Une majorité du nuage de points est assez distante de la ligne de la meilleure finesse.

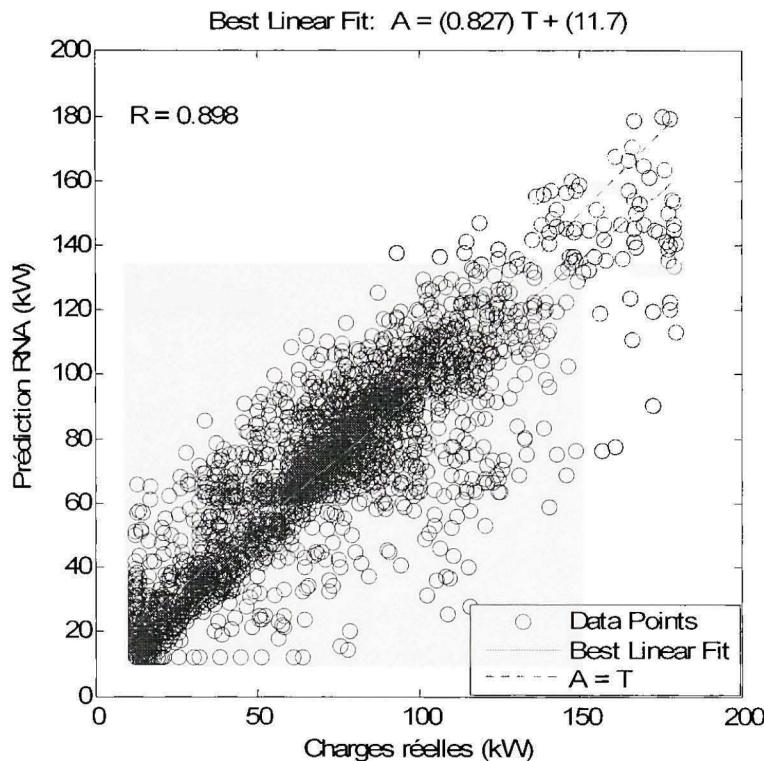


Figure 21 *Finesse de la prédiction en tenant compte de l'adaptation – version N1 (à fenêtre glissante).*

Tableau 12 Comparaison entre les RNA statiques et dynamiques -version 1-

| | Sans adaptation du réseau | Avec adaptation : base accumulative | Avec adaptation : fenêtre glissante |
|------------------|---------------------------|-------------------------------------|-------------------------------------|
| CV % | 27,46 | 25,03 | 25,01 |
| RMSE (KW) | 17,75 | 16,18 | 16,17 |

On remarque une variation de CV de 2,4% (27,46-25,01) entre un réseau adapté et non adapté et une très légère variation entre un réseau adapté avec base cumulative et un autre avec fenêtre glissante.

Les résultats présentés dans le tableau ci-dessus (Tableau 12) montrent le rôle de l'adaptation du RNA qui est prouvé par la baisse du CV, mais aussi une certaine faiblesse au niveau de la qualité de l'adaptation. Le fait d'avoir juste 16 données qui sortent de

l'ordinaire durant une période de quatre mois, remet en question la pertinence de cet algorithme de sélection des données à ajouter pour l'adaptation du réseau. De plus un CV de l'ordre de 25% reste moyennement élevé. Il faut donc améliorer l'algorithme de la sélection des données à ajouter.

Les graphes ci-dessous (Figure 22) montrent la qualité de la prédiction en utilisant la version N1 pour différentes périodes.

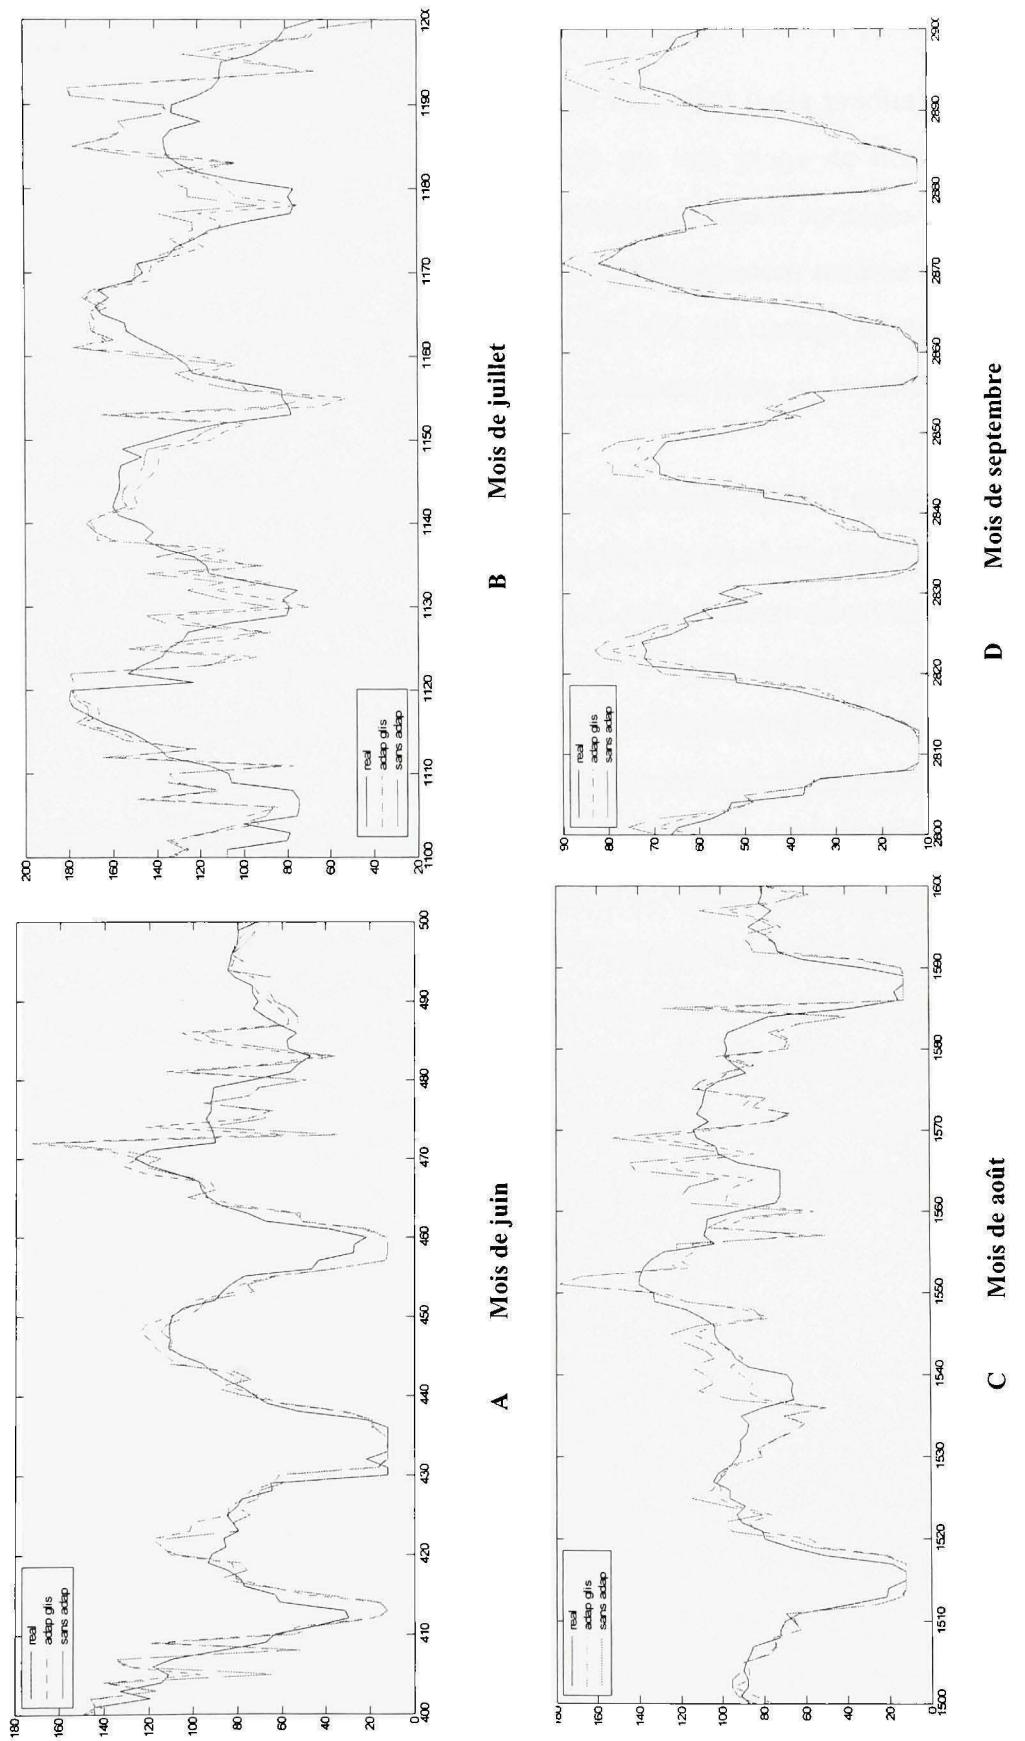


Figure 22 Qualité de la prédiction dynamique avec version N1 et données simulées (Demande électrique vs Heures).

Version N 2 :

Une deuxième version est testée pour améliorer la qualité de la prédiction dynamique des RNA. L'apprentissage du réseau, se fait aussi sur une plage de données présentée du premier au 31 mai (768 entrées), et prend en considération neuf variables à l'entrée (ajout de la température humide à l'instant $t-2$) qui servira ultérieurement comme indice de référence pour la sélection des nouvelles données à ajouter. Ce qui change la structure de base du réseau de neurones au niveau du nombre de neurones dans sa couche cachée ($2n+1=19$ neurones).

L'adaptation du réseau est déclenchée automatiquement après l'accumulation des vingt nouvelles entrées qui sortent de l'ordinaire (température ou charge électrique). Pour cela, on a adopté un nouvel algorithme qui peut trancher entre les nouvelles données influentes ou pas sur la prédiction des charges électriques. Pour la partie qui tranche entre les données à ajouter ou pas, on a utilisé la technique des listes chaînées (voir annexe 1) pour accélérer l'exécution du programme qui prend en considération les températures aux instants $t-1$, $t-2$ et la charge à $t-1$ pour la comparaison des entrées. On a pu mettre en vigueur, dans l'algorithme, un tableau dynamique (nommé *File 2*, annexe 1) dans lequel on vérifie si la nouvelle entrée existe déjà et on l'ajoute si ce n'est pas le cas. Ce tableau, après l'ajout de chaque 20 nouvelles entrées, joue le rôle d'une base d'adaptation pour le réseau neurone.

Sur une base de prédiction et d'adaptation contenant 2928 entrées on a pu enregistrer 102 adaptations (c'est à dire 2040 nouvelles entrées) qui permettent au réseau de neurone de s'adapter à des conditions climatiques ou aux besoins énergétiques non inclus précédemment à la formation du réseau.

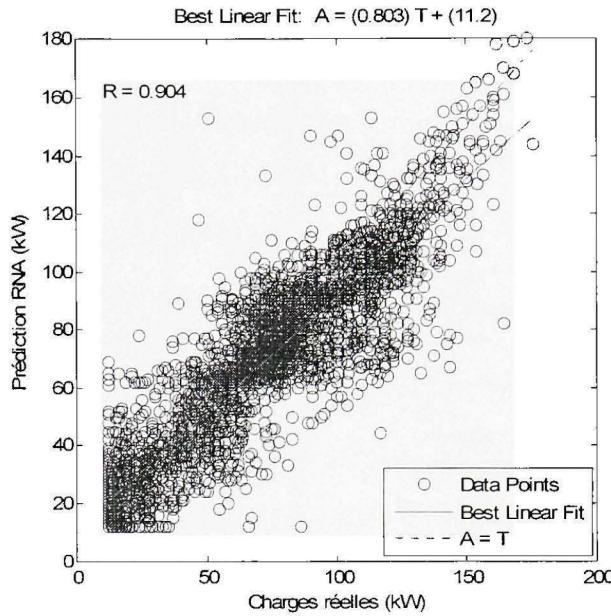


Figure 23 Finesse de la prédiction en tenant compte de l'adaptation –Version N2-.

Tableau 13 Comparaison entre les RNA statiques et dynamiques -Version 2-

| | Sans adaptation du réseau | Avec adaptation : base cumulative | Avec adaptation : fenêtre glissante |
|------------------|------------------------------|--------------------------------------|--|
| CV% | 27,5 | 21 | 23,9 |
| RMSE (KW) | 17,7 | 13,6 | 15,4 |

On remarque avec la nouvelle méthode (Version N2) plus les données de températures supplémentaires (ajout de la température humide à $t-2$), qu'en incluant plus de données qui sortent de l'ordinaire de la base d'apprentissage, on a pu gagner plus de 6% (27,5-21) au niveau de CV (Tableau 13), mais ceci uniquement pour le mode à base cumulative. Avec le mode fenêtre glissante on a eu une amélioration de 3,5% (27,5-23,9) du CV par rapport à un RNA sans adaptation et 1% par rapport à la version 1, ce qui n'est pas vraiment suffisant, surtout que ce mode est le plus réputé et demandé à cause de sa base d'adaptation dynamique et de dimension constante. Les graphes ci-dessous (Figure 24) donnent une idée plus générale sur la qualité de la prédiction en utilisant la deuxième version.

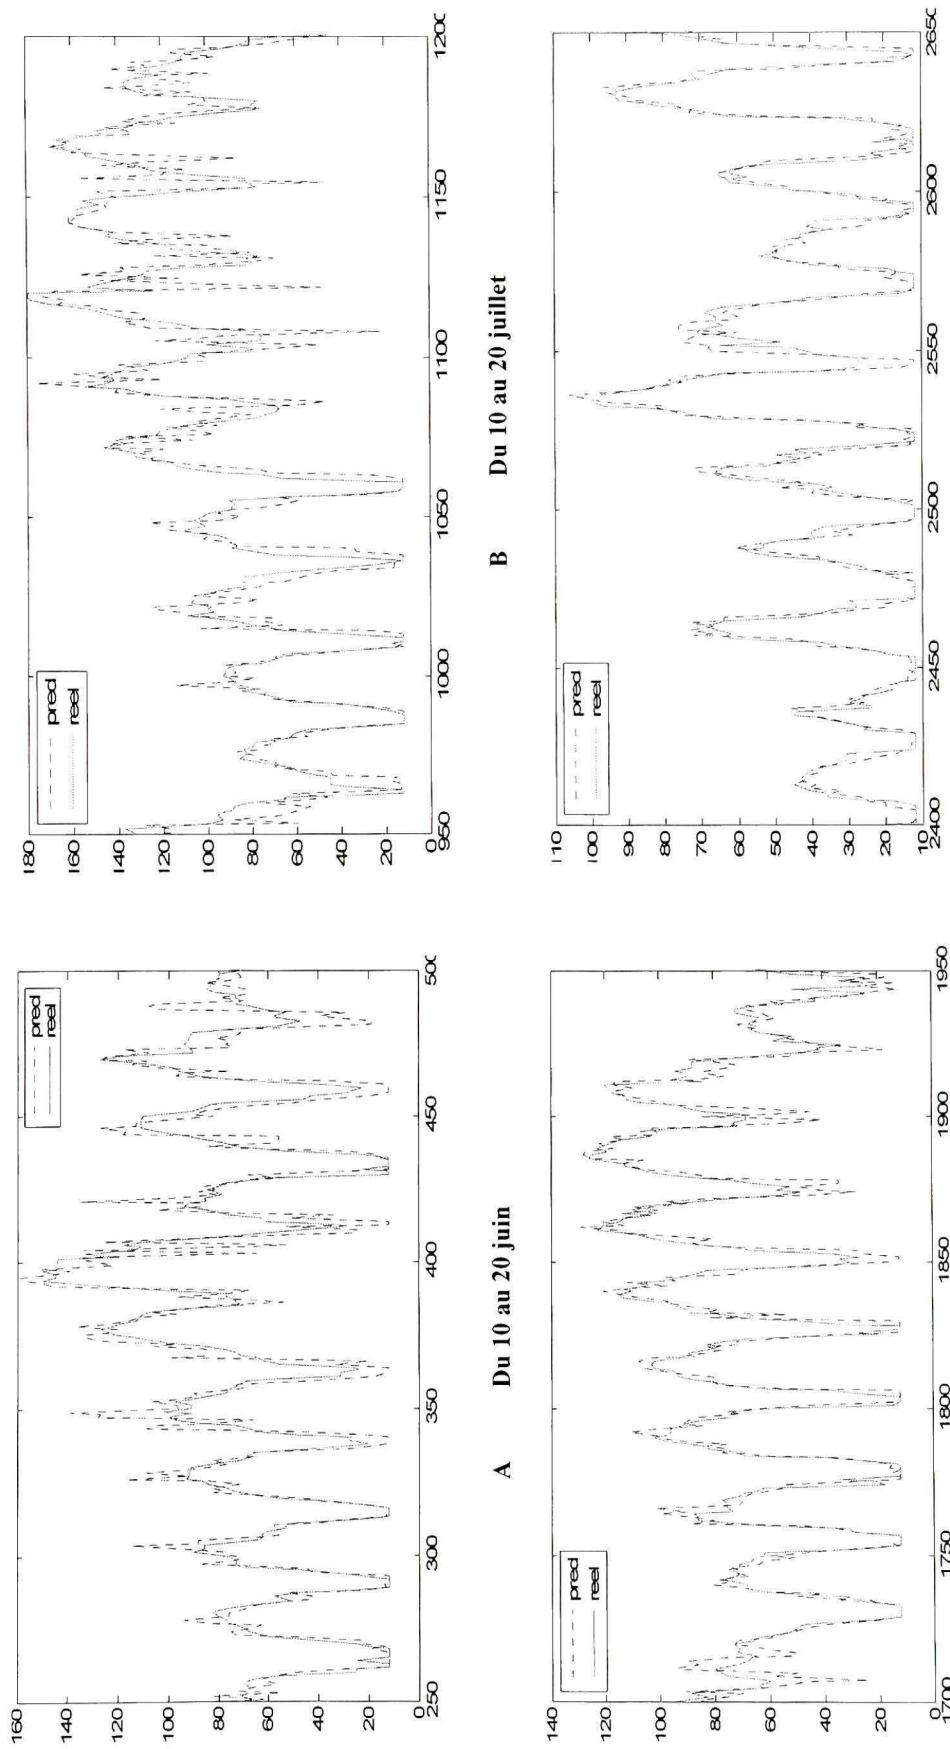


Figure 24 Qualité de la prédiction dynamique avec version N2 et données simulées (Demande électrique vs Heures).

4.8 Sommaire

Le présent chapitre détaille la première partie des simulations de ce mémoire concernant la prédiction des besoins énergétiques du pavillon *A* du bâtiment de l'ÉTS en utilisant les réseaux des neurones artificiels. L'étude est basée sur des données simulées obtenues avec le logiciel DOE-2.

Le chapitre démontre l'importance de l'analyse par composantes principales (ACP) pour définir les variables pertinentes que l'on doit choisir pour la formation et l'apprentissage des RNA. La régression multivariable a permis de trouver une combinaison compacte de variables d'entrées pour le RNA en termes de l'échelle du temps. Le chapitre met en valeur la prédiction des besoins énergétiques du pavillon *A* de l'ÉTS avec les RNA en mode statique par rapport à un modèle purement mathématique (la régression multilinéaire). Aussi, il élabore le traitement et la normalisation des données, le choix du modèle à utiliser. Cependant, la partie importante est réservée pour la prédiction en ligne des besoins énergétiques en utilisant un modèle dynamique des RNA avec ces deux approches, cumulative et à fenêtre glissante, cela permet de tirer profit des nouvelles données qui deviennent disponibles au fil du temps. Ces derniers sont limités par les critères d'une journée qui sort de l'ordinaire et sont sélectionnés par deux algorithmes proposés dans le chapitre.

Les tableaux 14 et 15 résument l'ensemble des résultats trouvés au cours de ce chapitre. Ces deux groupes d'expériences ont été élaborés (apprentissage et validation) sur la même plage de données simulées avec une différence dans sa répartition.

Tableau 14 Comparaison entre la prédiction avec la régression multilinéaire et les RNA statique

| Mode de prédiction | CV % | RMSE (KW) |
|-------------------------------|--------------|-------------|
| Régression multilinéaire | 13,74 | 8,12 |
| Réseaux de neurones statiques | 10,8 | 6,4 |

Tableau 15 Comparaison entre différents types de RNA basé sur des données simulées

| Mode de prédiction | | CV (%) | RMSE (kW) |
|--|-----------|--------------|--------------|
| RNA Statique | | 27.5 | 17.7 |
| RNA Dynamique avec base cumulative | Version 1 | 25.03 | 16.18 |
| | Version 2 | 21 | 13.6 |
| RNA dynamique avec base à fenêtre glissante | Version 1 | 25.01 | 16.17 |
| | Version 2 | 23.9 | 15.4 |

Les résultats trouvés au cours de ce chapitre basés sur des données simulées par le logiciel DOE-2 ont permis de mieux comprendre les différents facteurs qui influencent la prédiction de la consommation énergétique des bâtiments. Dans le chapitre suivant, le même type de prédiction (RNA statique et dynamique) sera cette fois étudié avec des données réelles du bâtiment de l’ÉTS récupéré du système de contrôle de l’École.

CHAPITRE 5

PRÉDICTION DE LA CHARGE ÉLECTRIQUE TOTALE ET DE LA CHARGE DE LA RÉFRIGÉRATION BASÉE SUR DES DONNÉES RÉELLES

L'accès à des données réelles mesurés sur le bâtiment de l'ÉTS permet de valider l'approche de la prédition des besoins énergétiques en utilisant les réseaux de neurones. Cette étude est basée sur des données réelles obtenues pendant deux années consécutives (2004 et 2005) pour les pavillons A et B de l'ÉTS. La base de données contient une quantité suffisante d'information pour la formation et la validation du réseau de neurones conçu pour la prédition des charges.

Dans une première étape, des expériences pour prédire et valider l'appel de puissance électrique de l'École de technologie supérieure sont présentées dans ce chapitre. Puis l'étude se concentre plus spécifiquement sur la prédition de la charge électrique du refroidisseur de l'École, pour laquelle on tentera d'analyser et résoudre les différentes difficultés qui peuvent être appréhendées durant cette étude de prédition. En se basant sur les méthodes antérieures utilisées pour la prédition fondée sur les données simulées (type de réseaux RNA, méthodes d'adaptation de réseau, sélection des entrées aptes pour une meilleure adaptation), plusieurs modèles seront développés et testés avec des critères mieux adaptés en fonction du nombre et le type des variables sauvegardées.

5.1 Traitement des données réelles

La base de données récupérée du système de contrôle de l'ÉTS rassemble des données pour l'ensemble des années 2004 et 2005 qui présentent l'appel de puissance de l'École et la charge électrique du refroidissement avec la date et le type de jour (3665 entrées pour chaque année, chacune contient les données de l'heure du jour, le type de jour, la température humide et la demande de puissance électrique).

Dans cette étude, on s'est limité à l'été avec une plage de données couvrant la période du 1^{er} mai au 30 septembre pour chaque année car elle contient la consommation électrique incluant les besoins de refroidissement. Les données étaient enregistrées pour chaque 15 minutes. Il a donc fallu calculer leur moyenne sur une heure pour avoir une prédition horaire.

D'après l'étude précédente sur les variables pertinentes pour la prédition, le choix de variables s'est limité à :

- Hdj : heure du jour.
- Ts : température humide.
- Ec : la charge électrique.

Il faut noter qu'on a dû supprimer une partie de données erronées (pour l'appel de puissance totale et la charge électrique du refroidisseur) au niveau de la mesure des températures ou de la charge électrique du mois de mai 2005 et aussi remplir 25 jours de données manquantes des températures pour le mois de mai 2004 avec des données provenant d'Environnement Canada.

5.2 Apprentissage et adaptation du réseau

Comme la prédition de l'appel de puissance totale de l'ETS avec des données réelles est basée sur le même principe que celle des données simulées, en tenant compte du nombre et du type des variables d'entrées, on a adopté la même architecture du RNA que celui du chapitre précédent:

- Type de réseau neurone : Feed-forward backpropagation.
- Fonction de formation : Levenberg-Marquardt.
- Fonction de transfert : TANSIG (Sigmoïde).
- Fonction de performance : MSE (Mean Square Error- Erreur de la moyenne des carrées)
- Nombre de couches cachées : 1
- Nombre de variables d'entrées : n=9

- Nombre de neurones pour la couche cachée : $2n + 1 = 19$
- Nombre d'époques pour la convergence : 200 (initial).
- Variables d'entrée : heure du jour, température sèche à $t-1$ et $t-2$, la charge électrique de $t-6$ à $t-1$.
- Variable de sortie : la charge à l'instant t (l'heure de prédiction).

Le réseau dans chaque cas de prédiction (charge totale ou refroidissement) a été entraîné sur la plage de données s'étalant du 1^{er} mai au 30 septembre 2004. Sa validation et son adaptation sont faites sur la partie des données de la même période de 2005. La partie adaptation du réseau - mode incrémental - est contrôlée par la méthode utilisée précédemment en se basant sur la structure des listes chaînées tout en respectant la norme des journées qui sortent de l'ordinaire confié à l'algorithme de tri.

5.3 Prédiction en ligne de la charge totale de l'école

La formation du réseau et son apprentissage sont faits sur une base de données qui contient 3665 entrées présentant la période de l'été 2004. Sur le graphe ci-dessous (Figure 25), on remarque le rôle de la fonction Levenberg-Marquardt au niveau de la vitesse de la convergence sur le processus d'apprentissage du réseau, ainsi son MSE atteint un minimum après 80 itérations.

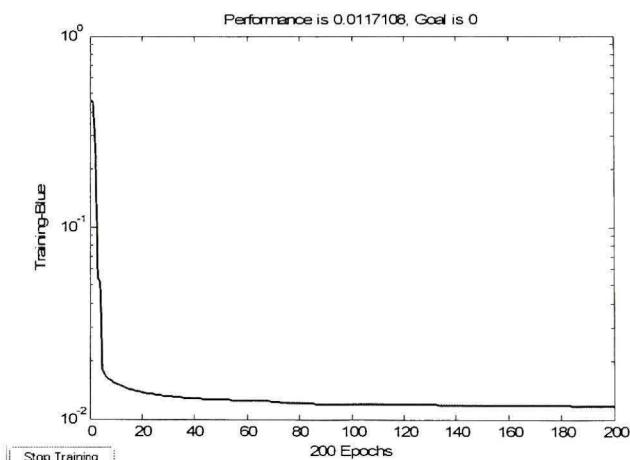


Figure 25 Itération de l'apprentissage du réseau de neurones avec les données réelles.

La comparaison entre le rendement du RNA durant l'apprentissage (output-net) et les données présentées comme cible pour l'apprentissage du réseau (réseau) (Figure 26) détaille la qualité de l'apprentissage. Cette qualité est remarquable sur toute la plage de données réservées à l'apprentissage, sauf pour quelques charges (heures de crêtes) ou le réseau ne suit pas les données réelles (Figure 27) et cela dû à la qualité de ces mesures (données réelles récupérées) qui ne représentent pas les charges réelles à ces heures-ci.

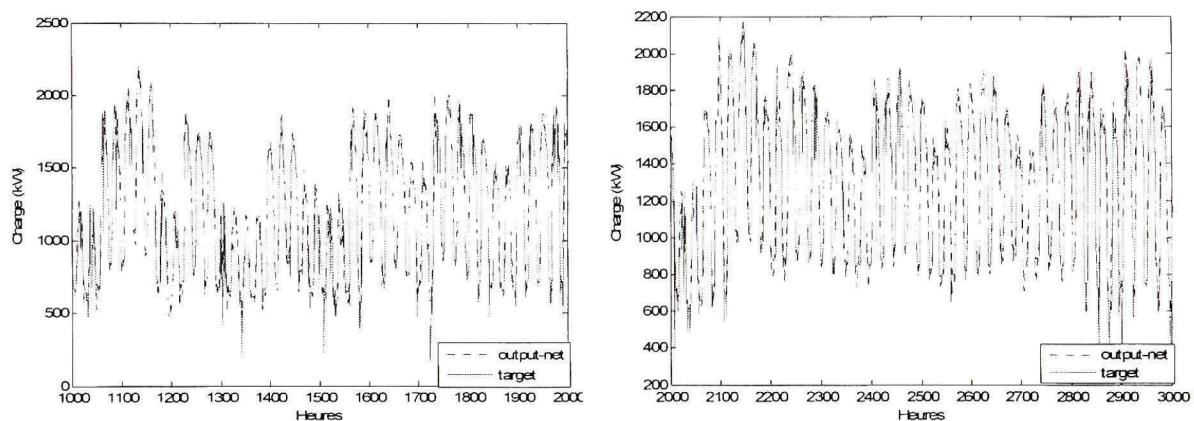


Figure 26 Comparaison entre la cible et le rendement du RNA durant l'apprentissage sur la période 2004.

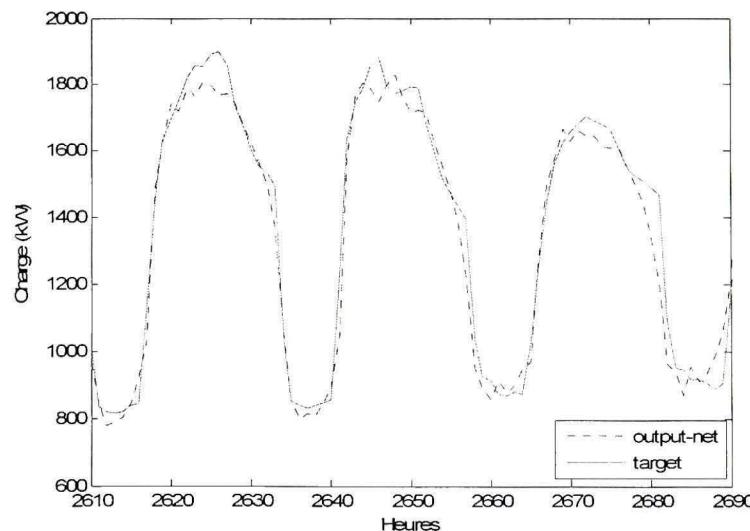


Figure 27 Agrandissement de la figure 26 sur un intervalle de trois jours.

L'erreur entre la cible et le rendement du RNA durant l'apprentissage qu'on a déjà défini au chapitre précédent sous la forme $\text{Erreur}(t) = E(t) - E_p(t)$ est présenté dans la figure 28. Cette erreur est concentrée entre -400 et 200 kW.

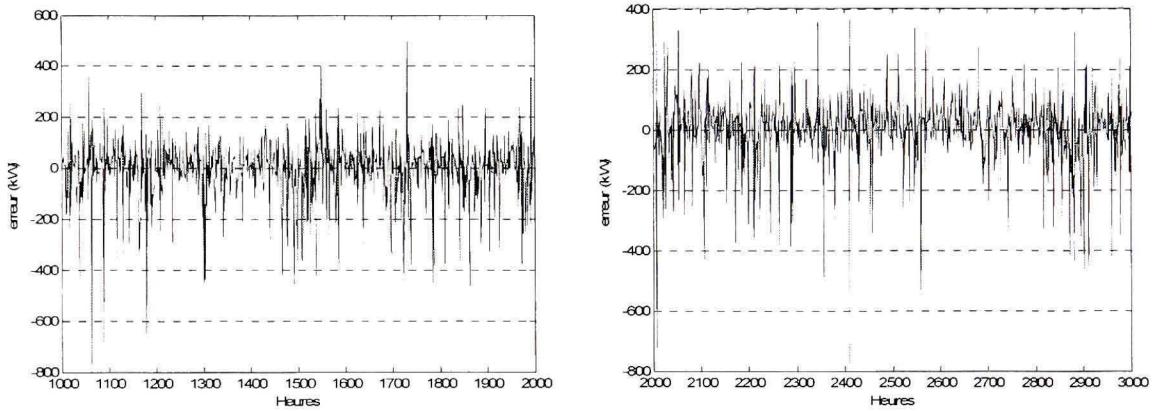


Figure 28 L'erreur entre la cible désirée et le rendement du RNA durant l'apprentissage (2004).

Sur une base de prédiction et d'adaptation contenant 3101 entrées (été 2005) on a pu enregistrer 146 adaptations (c-à-d 2920 nouvelles entrées, sur le fait d'avoir une adaptation à chaque accumulation de 20 nouvelles entrées) qui permettent au réseau neurone de s'adapter à des nouvelles conditions climatiques ou aux besoins énergétiques non inclus lors de l'apprentissage du réseau auparavant.

La finesse de la prédiction présentée dans les figures 29 (prédiction statique) et 30 (prédiction dynamique) permet d'estimer visuellement la qualité de la prédiction en évaluant la distribution du nuage des points (charges) par rapport à l'axe A=T. Aussi, les graphes montrent un léger avantage pour le mode dynamique de la prédiction vue la concentration de la distribution des charges autour de l'axe A=T.

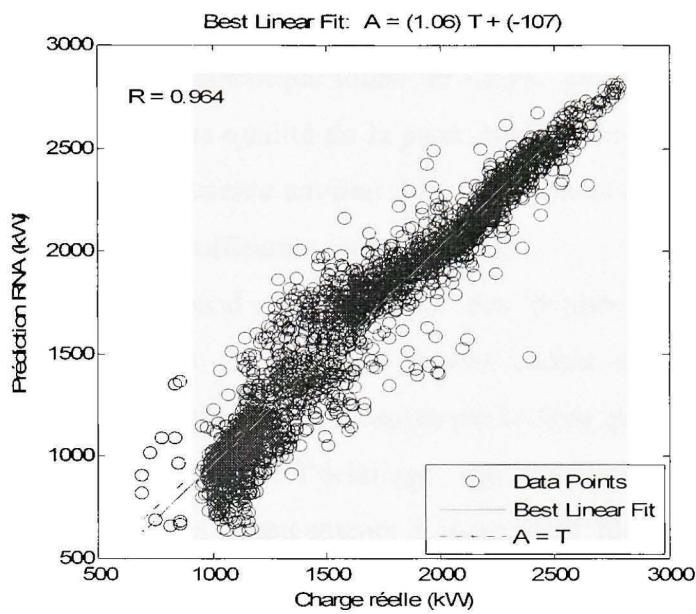


Figure 29 La finesse de la prédiction statique basée sur les données de validation 2005.

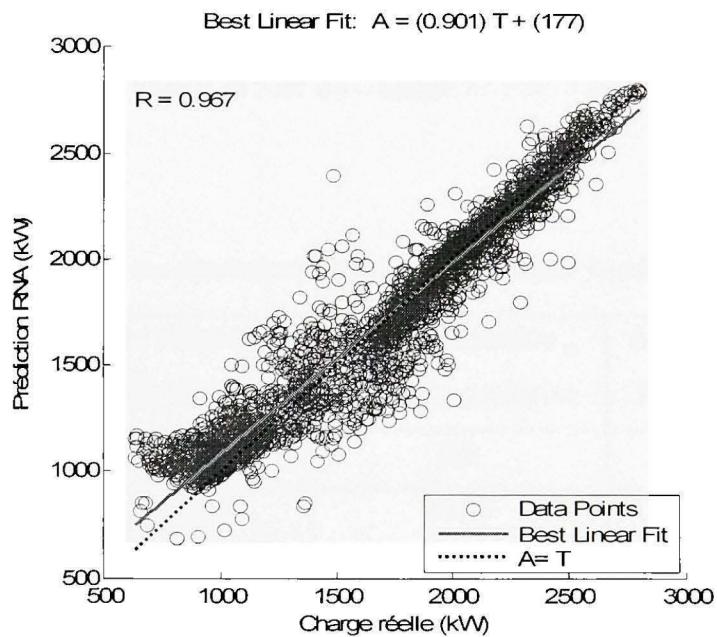


Figure 30 La finesse de la prédiction dynamique basée sur les données de validation 2005.

Le tableau ci-dessous (Tableau 16) résume les différents résultats trouvés au cours des simulations sur la consommation électrique totale de l'ÉTS. Les valeurs de CV calculées montrent le niveau satisfaisant et la qualité de la prédiction via les RNA. Aussi, le RMSE qui est de l'ordre de 134 kW, représente environ 5 % de la consommation totale de l'École qui peut atteindre 2800 kW, reste suffisamment acceptable.

La qualité de la prédiction dépend de la qualité des données réelles utilisées pour l'apprentissage et le test du réseau. Ces données peuvent cacher aussi plusieurs défauts de mesures de la consommation électrique totale, causés par le fait que cette dernière englobe les consommations du refroidisseur, de l'éclairage, des auxiliaires électriques, etc. Ces consommations peuvent subir des changements brutaux non interceptés à cause de la grandeur de la charge électrique totale de l'École (2800 kW), choses qu'on peut remarquer facilement dans la section (5.5) sur la prédiction de la charge simulée du refroidisseur.

Au niveau de l'adaptation du réseau, le CV subit une légère variation qui ne dépasse pas 0,6 %. Cela est dû à la bonne qualité de l'apprentissage de base qui est fait sur une base de données assez complète pour avoir un réseau bien formé (du 1er mai à la fin septembre 2004), ce qui ne met pas en valeur le rôle de l'adaptation du RNA soit en mode accumulatif ou à fenêtre glissante.

Tableau 16 Résultats des simulations pour la consommation électrique totale de l'ÉTS

| | Sans adaptation du réseau | Avec adaptation : base accumulative | Avec adaptation : fenêtre glissante |
|-----------|------------------------------|--|--|
| CV % | 8,7 | 8,3 | 8,1 |
| RMSE (KW) | 144,3 | 136,9 | 133,6 |

La figure 31 compare les données réelles et les valeurs prédictes par le RNA dynamique à fenêtre glissante avec les données de validation de l'année 2005. En général, la différence entre les deux courbes est à peine apparente. Aussi on peut remarquer que la puissance du réseau a détecté même les jours de fin de semaine et prédit leurs charges correctement.

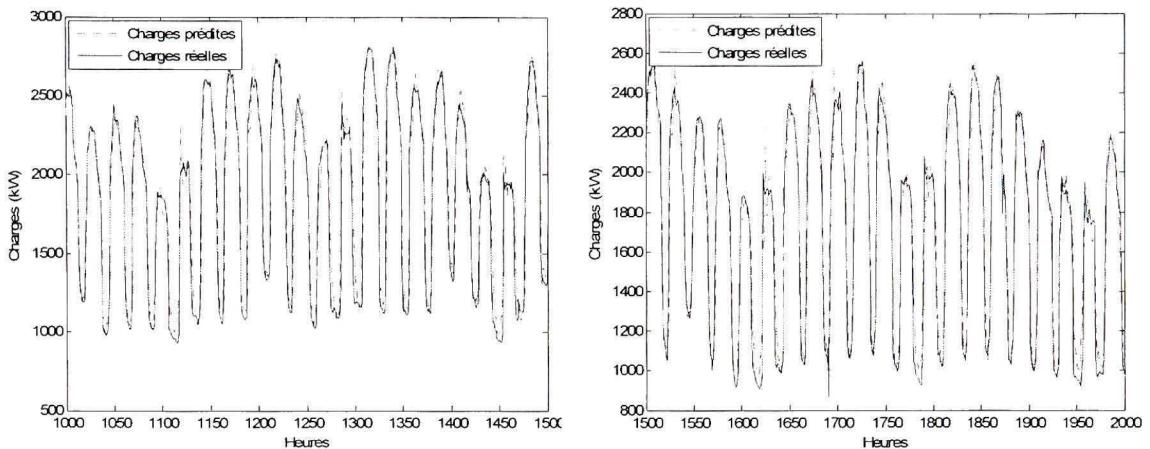


Figure 31 Comparaison entre les données réelles et les valeurs prédites par le RNA avec adaptation à fenêtre glissante (données de validation 2005).

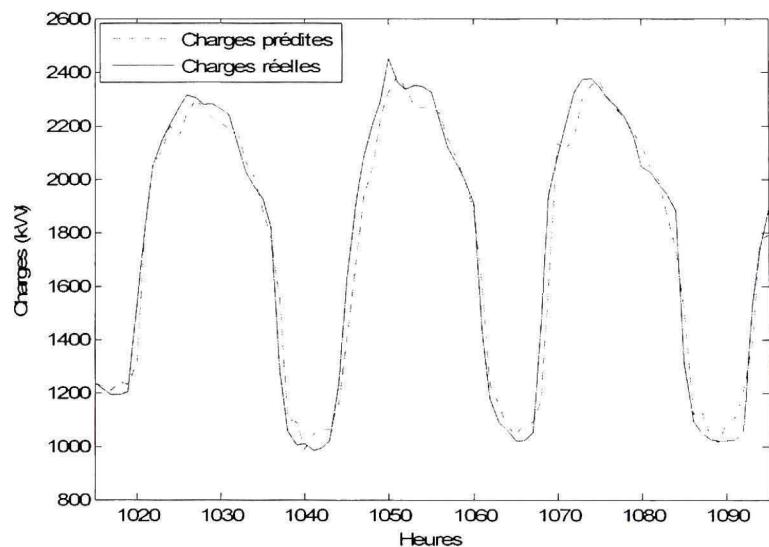


Figure 32 Vue agrandie pour la figure 31 entre les heures 1015 et 1095.

5.4 Prédiction en ligne de la charge totale avec l'ajout du type de jour

Dans la section précédente, on a prédit et validé l'appel de puissance totale de l'École de technologie supérieure. En se basant sur neuf variables d'entrées pour le réseau de neurone, on a pu trouver un CV qui varie entre 8,1 et 8,7 suivant le modèle de la prédiction. L'analyse des résultats trouvés et la comparaison entre les courbes de la figure 31 et 32 ont bien montré que le RNA a automatiquement distingué entre les jours de fin de semaine et les jours du reste de la semaine.

Pour mieux analyser ce point, on garde les mêmes critères de l'étude précédente (5.2) en ajoutant une nouvelle variable d'entrée qui est le type de jour, qui reste un élément essentiel dans la distribution de la consommation de l'énergie puisqu'il distingue entre les jours de la semaine, les fins de semaines et les jours fériés. La nouvelle variable a des valeurs de 1 à 7, où chaque chiffre présente une journée de la semaine (dimanche : 1, lundi : 2, mardi : 3, mercredi : 4, jeudi : 5, vendredi : 6, samedi : 7). La nouvelle structure du réseau sera donc sous la forme :

- Nombre de variables d'entrées : n=10
- Nombre de neurones pour la couche cachée : $2n + 1 = 21$
- Variables d'entrées : heure du jour, température sèche à $t-1$ et $t-2$, la charge électrique de $t-6$ à $t-1$ et le type de jour.
- Variable de sortie : la charge à l'instant t .

Le tableau 17 regroupe les résultats trouvés avec la nouvelle architecture RNA qui contient le type de jour.

Tableau 17 Résultats de la prédiction en tenant compte du type de jour

| | Mode statique | Fenêtre glissante | Mode cumulatif |
|-----------|---------------|-------------------|----------------|
| RMSE (kW) | 144,2 | 152,9 | 156,1 |
| CV (%) | 8,7 | 9,2 | 9,4 |

En comparant les résultats de ce tableau avec ceux trouvés précédemment (sans type de jour, Tableau 16), on remarque que l'introduction du type de jour influence de manière légèrement négative la qualité de la prédition de 1% (le CV passe de 8% à 9%).

On peut conclure que généralement le type de jour reste un indicateur réel pour la distribution de la consommation électrique (Figure 33), mais il peut être ignoré pour la prédition via les RNA.

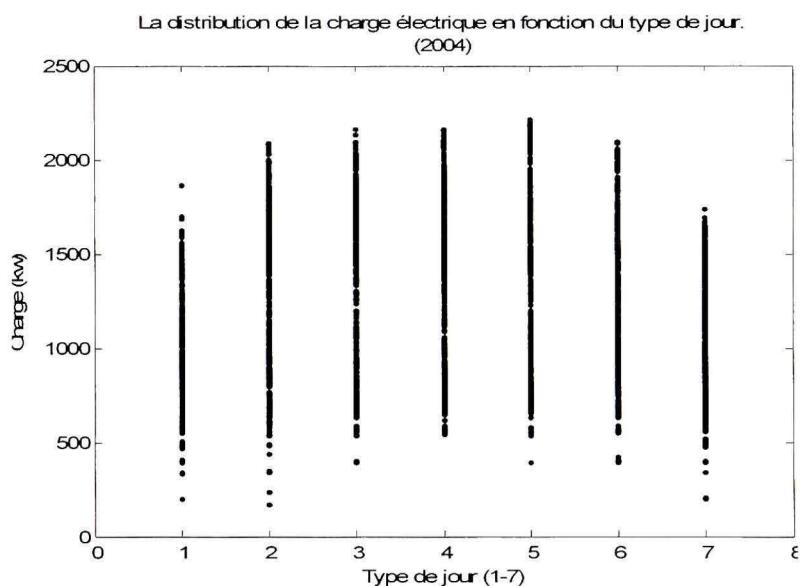


Figure 33 Distribution de l'appel de puissance électrique totale par rapport au type de jour.

5.5 La prédition en ligne de la charge électrique du refroidisseur

L'utilisation des données de l'appel de puissance électrique totale de l'ÉTS nous a permis de valider l'approche de la prédition des besoins énergétiques du bâtiment en utilisant les réseaux neurones (CV qui ne dépasse pas 9%). La prochaine étude se concentre sur une plage de données juste pour la charge électrique du refroidisseur.

Cette étude est basée sur la même méthode que l'étude de la section précédente (5.2) avec la même architecture de réseau, les mêmes variables et les mêmes fonctions. Le seul changement est de se limiter aux mesures de la charge du refroidisseur pour l'apprentissage,

l'adaptation et le test. La formation et l'apprentissage du réseau sont faits sur les données de l'été 2004. La figure 34 de l'apprentissage montre que le réseau converge avant la 60 ème itération, ce qui prouve que le RNA a pris compte de toutes les mesures présentées comme entrées pour le réseau.

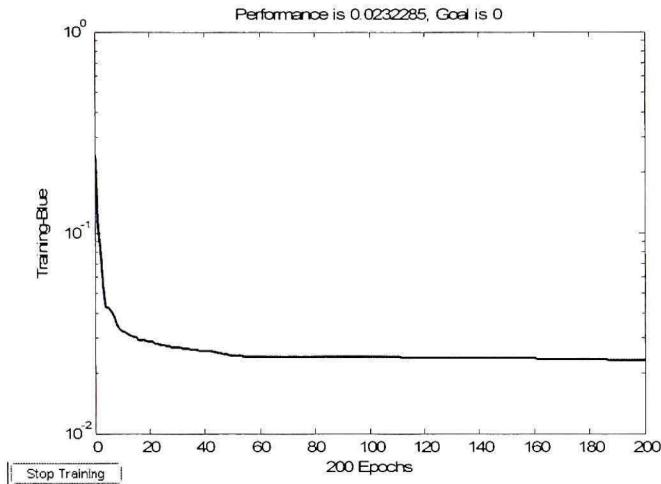


Figure 34 Evolution de l'apprentissage du réseau neurone.

En utilisant la technique précédente des listes chaînées et sur une base de prédiction et d'adaptation contenant 3081 entrées de l'été 2005, on a pu enregistrer 81 adaptations (c à d. 1620 nouvelles entrées sur le fait d'avoir une adaptation chaque accumulation de 20 nouvelles entrées) qui permettent au réseau de neurones de s'adapter à des conditions climatiques ou aux besoins énergétiques non inclus lors de la formation initial du réseau (été 2004).

La finesse de la prédiction avec ces deux modes, statique ou incrémental illustrée dans la Figure 35 montre cette fois-ci une certaine faiblesse du RNA à prédire correctement les charges du refroidisseur. On remarque qu'il y a une majorité de points -charges- qui sont bien distantes de la droite $y=x$ qui présente la meilleure finesse, ce qui indique une prédiction non performante. Aussi on peut remarquer sur l'axe des abscisses le problème des charges prédictes nulles et qui peuvent atteindre 300 kW du côté réel.

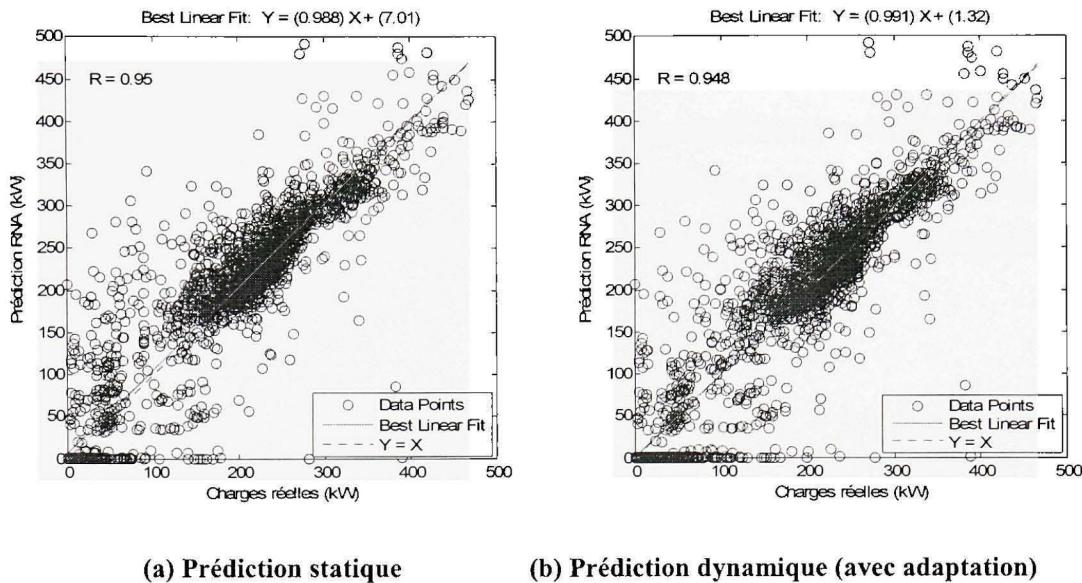


Figure 35 La finesse de la prédiction basée sur les données de validation 2005 du refroidisseur.

Toutes les anomalies de la prédiction remarquées dans les graphes de la finesse sont confirmées par le calcul du CV et de la RMSE qu'on trouve dans le tableau 18 :

Tableau 18 Les résultats de la prédiction en ligne de la charge du refroidisseur

| | Mode statique | Avec adaptation : base accumulative | Avec adaptation : fenêtre glissante |
|-----------|---------------|--|--|
| CV % | 32,8 | 27,4 | 27,5 |
| RMSE (KW) | 47,07 | 39,33 | 39,53 |

En comparaison, ces derniers résultats sont bien moins performantes que ceux du chapitre précédent (4.6) basés sur des données simulées, dans lequel on a pu trouver un CV de l'ordre de 21 %, alors qu'on ne disposait que des données d'une seule année 2004 et que l'apprentissage du RNA est fait sur un seul mois, celui de mai 2004. Les résultats soulèvent

une question pour expliquer ces anomalies dans la prédition qu'on va essayer de résoudre par la suite.

La figure 36 ci-dessous donne une vue globale sur la comparaison entre les données réelles de la charge électrique du refroidisseur et les charges prédites par le RNA en question (Figure 37). La figure suivante donne une image agrandie sur un intervalle horaire entre les heures 1385 et 1475 heures pour essayer de localiser les points d'erreurs et les anomalies du RNA (Figure 37).

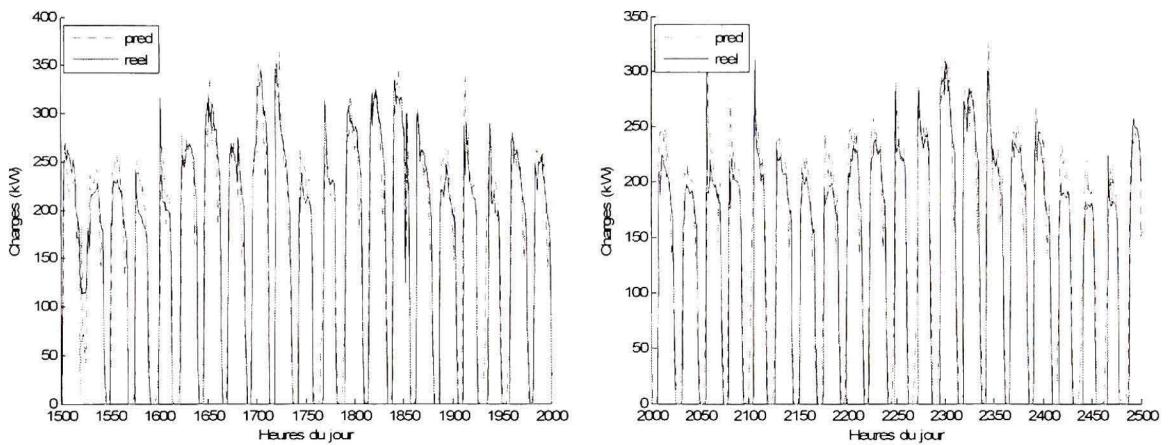


Figure 36 Comparaison des charges réelles et des charges prédites pour le refroidisseur avec un RNA dynamique à fenêtre glissante.

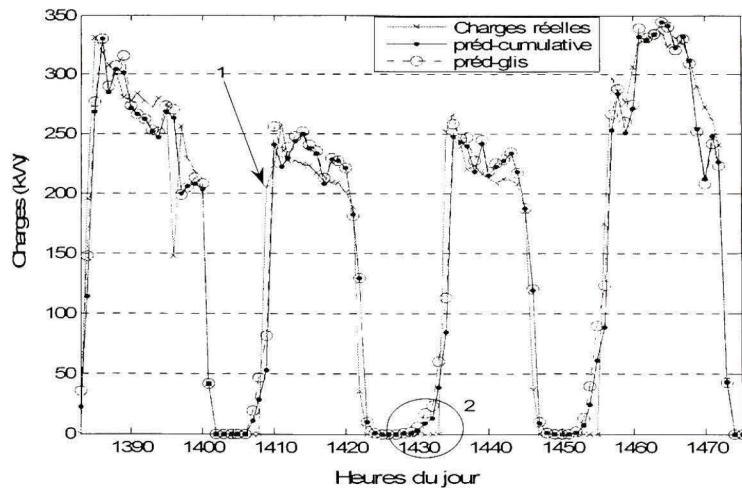


Figure 37 Agrandissement de la comparaison sur un intervalle de 4 jours.

On remarque un certain déphasage au niveau de la prédition entre les données réelles avec celles prédictes. Ce déphasage est particulièrement remarquable à chaque départ du refroidisseur (point 1). Le réseau de neurone n'arrive pas à prédire le départ du refroidisseur quand la charge électrique passe de 0 KW (mode OFF) à 150 KW et plus (mode démarrage du refroidisseur). La prédition avec le RNA n'a pas une courbe pointue qui peut permettre à avoir une prédition plus précise à chaque démarrage du refroidisseur (point 2). Des solutions potentielles sont explorées et présentées dans les prochaines sections.

5.6 Prédiction des charges juste pour les heures de démarrage du refroidisseur

D'après la section précédente (5.5), la cause principale du mauvais fonctionnement du système de prédition est due surtout à la période de démarrage du refroidisseur. Pour cela, cette section se concentre sur la prédition des charges du refroidisseur juste aux heures du démarrage dans le mode statique de la prédition pour l'appliquer ensuite au mode incrémental.

L'apprentissage du réseau est réalisé en utilisant seulement les données correspondantes aux charges de 6h et 7h de l'été 2004, tout en gardant la structure du RNA précédent. Le test est fait sur les données de 6h et 7h de l'été 2005. Ces heures correspondent au démarrage du refroidisseur à condition que la température à ces horaires soit égale ou supérieure à 14 °C, qui représente la température de mise en marche du système de refroidissement à l'ETS. Les résultats trouvés pour cette prédition sont présentés dans les deux figures ci-dessous (Figures 38 et 39).

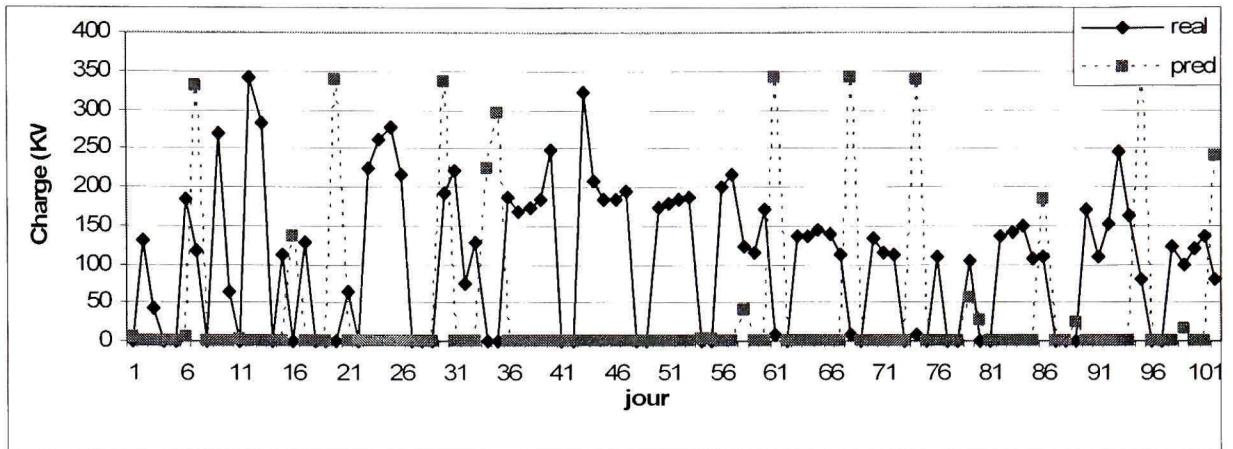


Figure 38 Les prédictions de la charge du refroidisseur à 6h du matin pour une $T > 14^{\circ}\text{C}$.

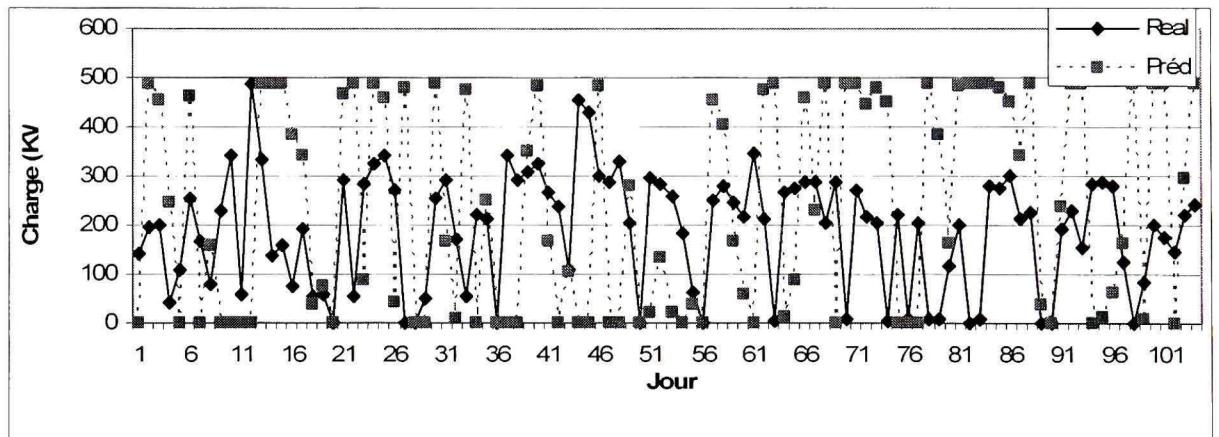


Figure 39 Les prédictions de la charge du refroidisseur à 7h du matin pour une $T > 14^{\circ}\text{C}$.

En comparant avec les résultats de l'étude précédente (5.5), on remarque visuellement que le fait de prendre en compte la condition de 14°C et éliminer toutes les données, qui peuvent être la source de bruit ou de mauvaises entrées pour l'apprentissage du réseau de neurone, n'a pas amélioré les résultats des prédictions. Le profil de la charge électrique du refroidisseur en fonction de la température pour le cas de 7h du matin est donc analysé dans la figure 40.

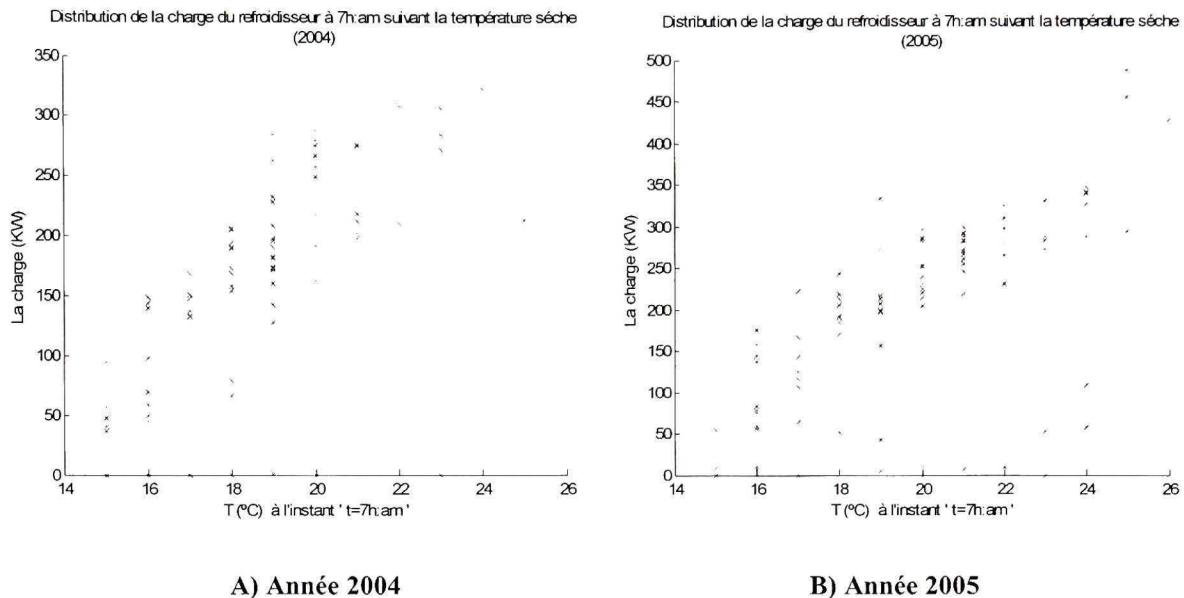


Figure 40 *Le profil de la charge du refroidisseur en fonction de la température sèche pour les années 2004 et 2005.*

La distribution des charges en fonction des températures, illustrée dans les graphes ci-dessus à la figure 40 peut expliquer la mauvaise prédition trouvée. On remarque que pour la même température -qui est considérée comme la plus importante variable d'entrée pour les RNA- des différences importantes pour les charges de démarrage du refroidisseur ont été enregistrées. Par exemple, pour la température 19 degrés (année 2004) la charge du refroidisseur s'étale de 130 jusqu'à 280 kW. Ce qui implique une difficulté d'apprentissage pour les RNA. Aussi on peut conclure de la figure 40 que la charge électrique du refroidisseur n'est pas liée seulement à la température extérieure. Plus concrètement la charge électrique de ce dernier est plutôt liée à la température intérieur de l'École et non à celle de l'extérieure.

Un autre modèle a été testé avec deux réseaux distincts, un pour prédire la charge à 6h00 et l'autre pour celle de 7h00. L'utilisation d'un tel système de prédition n'a pas amélioré la qualité de prédition. Pour ces raisons, une autre méthode qui consiste à corriger les charges électriques des heures de démarrage est testée dans la section suivante.

5.7 Méthode de prédition simplifiée des charges électriques pour les heures du démarrage (de 6h à 10h)

Vu le problème que cause le démarrage du refroidisseur, une autre méthode a été recherchée pour améliorer la qualité de la prédition et optimiser le CV. Il s'agit d'adopter une méthode de simple consultation du tableau 19 (*Table look-up*) qui sert à corriger les charges du refroidisseur au cours des heures du démarrage pour différentes températures.

Les charges corrigées sont calculées et ajustées par le calcul des moyennes des charges réelles en fonction de chaque heure de démarrage et de chaque température. Les heures de démarrage prises en compte sont de 6h à 10h.

Le tableau 19 contient toutes les données adoptées pour prédire d'une manière programmée lors de l'apprentissage et le test. Aussi, deux exemples de courbes correspondantes à un démarrage à 7h ou 9h sont présentées à la figure 41.

Tableau 19 Table de prédition simplifiée de la consommation (E) selon la température et les heures du démarrage en kW

| T (°C) | E (kW) | | | | |
|--------|--------|-----|-----|-----|-----|
| | 6h | 7h | 8h | 9h | 10h |
| 14 | 16 | 20 | 50 | 74 | 106 |
| 15 | 28 | 57 | 84 | 114 | 125 |
| 16 | 36 | 94 | 117 | 133 | 135 |
| 17 | 49 | 132 | 150 | 152 | 154 |
| 18 | 75 | 162 | 175 | 176 | 172 |
| 19 | 97 | 197 | 203 | 193 | 184 |
| 20 | 123 | 233 | 229 | 208 | 198 |
| 21 | 134 | 254 | 248 | 228 | 202 |
| 22 | 146 | 272 | 266 | 253 | 217 |
| 23 | 150 | 296 | 284 | 273 | 242 |
| 24 | 155 | 322 | 309 | 296 | 273 |
| 25 | 160 | 344 | 332 | 318 | 300 |

| | | | | | |
|----|-----|-----|-----|-----|-----|
| 26 | 165 | 361 | 352 | 335 | 314 |
| 27 | 170 | 384 | 373 | 353 | 331 |
| 28 | 176 | 413 | 400 | 375 | 342 |

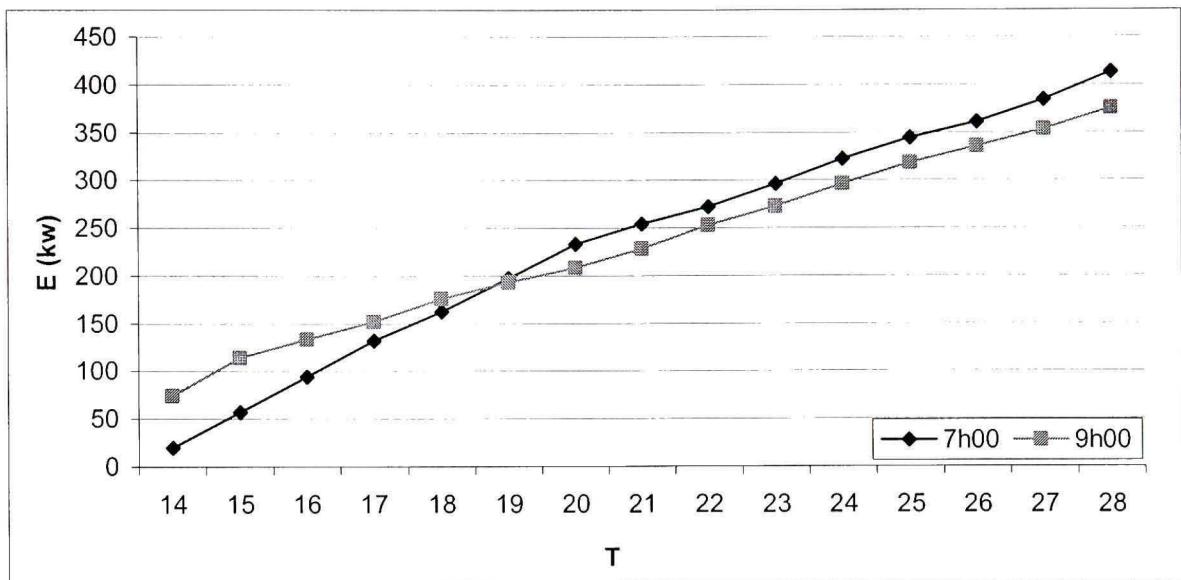


Figure 41 Corrélation entre la température et la charge électrique corrigée pour un démarrage à 7h ou 9h.

On a essayé deux types de prédiction avec cet algorithme pour le démarrage, le premier avec une seule prédiction simplifiée et le deuxième avec multi prédiction simplifiée.

5.7.1 L'apprentissage avec une seule prédiction simplifiée

La prédiction simplifiée dans cette section consiste à analyser et attribuer une charge E (kW) prédéfinie au tableau 19 à l'heure du démarrage pour améliorer la qualité de la prédiction pour toute la journée, au lieu d'une prédiction avec les RNA pour l'heure du démarrage. Ce type d'apprentissage prend en compte la prédiction simplifiée juste pour l'heure du démarrage, les charges des heures qui viennent après le démarrage sont prédites

par le RNA. Les heures de la période du démarrage prises en compte sont toujours de 6h à 10h et leur identification est liée à la séquence de contrôle.

La figure 42 ci-dessous, attribuée pour 8h00 (comme exemple), démontre qu'un apprentissage avec le modèle « une seule prédition simplifiée » ne sera pas pertinent. Cette dernière n'est pas suffisante pour réduire la différence entre les charges électrique pour la même heure et la même température (Figure 42).

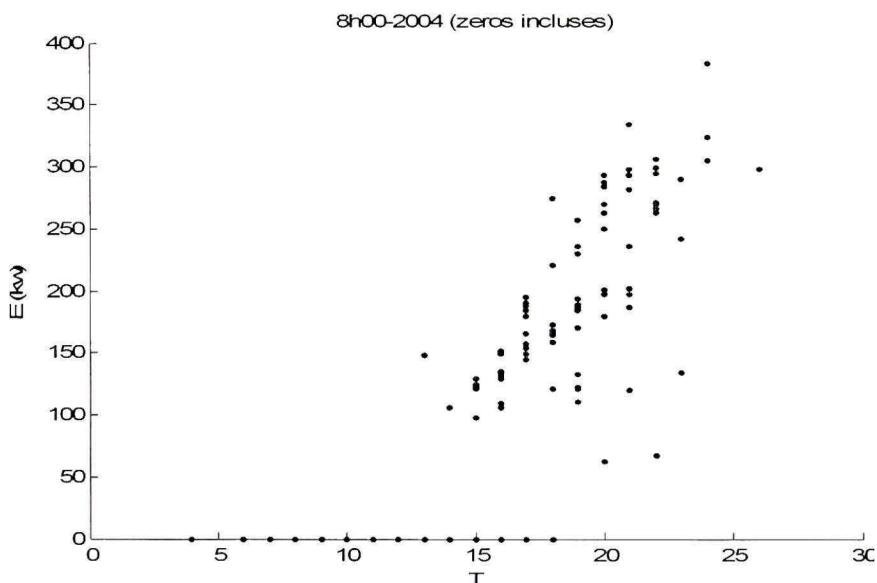


Figure 42 La distribution des charges du refroidisseur avec une seule correction à 8h00.

5.7.2 L'apprentissage avec multi prédition simplifiée

Le système dans ce cas réalise trois prédictions simplifiées consécutives -ajustées du tableau 19- par rapport aux données initiales (Figure 40-année 2004-), il affecte la charge de l'heure du démarrage ainsi que les deux heures qui le suivent (Figure 43).

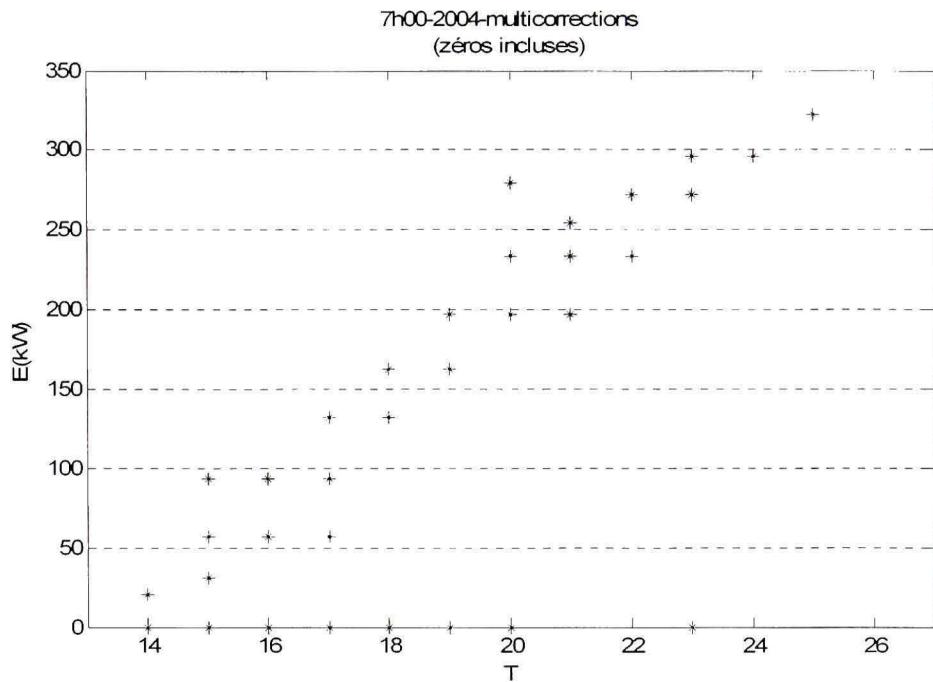


Figure 43 *Distribution des charges du refroidisseur avec multiples prédictions simplifiées à 7h00.*

On remarque toujours sur la figure 43 que pour la même température on peut avoir deux à trois différentes charges. Cela est dû au fait qu'on peut avoir des charges du refroidisseur non nulles avant 6h, c à d. on n'aura pas de correction dans ce cas là, puisque notre plage de correction des charges de démarrage du refroidisseur est limité entre 6h et 10h. Ce qui implique que les charges de la période de démarrage gardent leurs valeurs initiales non corrigés.

La figure 44 montre les étapes suivies au cours de la prédiction avec correction des charges de démarrage du refroidisseur.

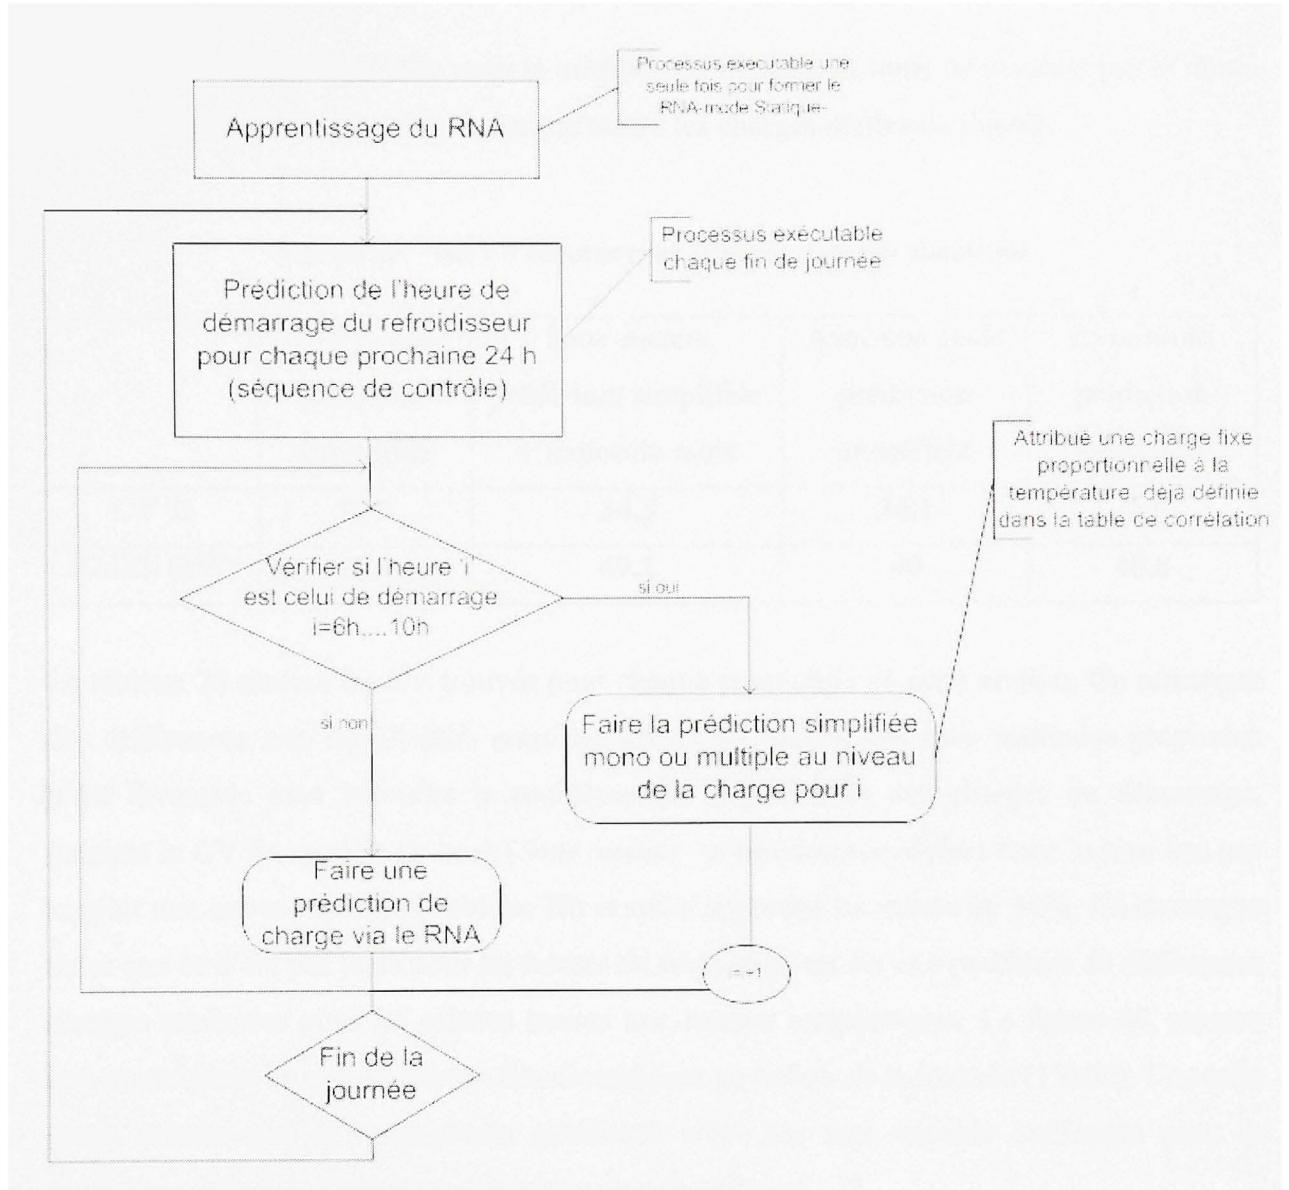


Figure 44 Les étapes de la prédiction dans le cas de la correction des charges de démarrage.

5.7.3 Résultats obtenus avec la correction des charges et l'indice de mois

On a aussi introduit une nouvelle variable au niveau des entrées du RNA, une variable qui présente l'indice du mois, pour pouvoir distinguer entre les charges électriques du refroidisseur de chaque mois et qui peuvent ne pas être liés seulement à la température

extérieure. La simulation faite avec la méthode de l'indice du mois ne contient pas le mode de correction des charges, elle comprend toutes les charges réelles de l'école.

Tableau 20 Les CV obtenus pour différents types de simulation

| | Sans aucune prédition simplifiée | Sans aucune prédition simplifiée + indice du mois | Avec une seule prédition simplifiée | Avec multi prédition simplifiée |
|-----------|----------------------------------|---|-------------------------------------|---------------------------------|
| CV % | 33.9 | 34.3 | 34.1 | 34 |
| RMSE (kW) | 48.7 | 49.2 | 49 | 48.8 |

Le tableau 20 résume les CV trouvés pour chaque simulation de cette section. On remarque des différences non significatifs entre les CV et qu'aucune des trois méthodes proposées n'est favorable pour résoudre le problème de la prédition des charges du démarrage, puisque le CV du modèle de base (*Sans aucune prédition simplifiée*) reste le plus bas par rapport aux autres modèles (Tableau 20) et qui s'approche lui-même de 34%. On remarque aussi que ce n'est pas juste pour les heures de démarrage qu'on a ce problème de différentes charges attribuées pour les mêmes heures aux mêmes températures. La figure 45, montre que le problème se répète pour un fonctionnement au milieu de la journée (15h00). Une telle étude montre que la température extérieure n'est pas une variable suffisante pour la prédition de la consommation électrique du refroidisseur.

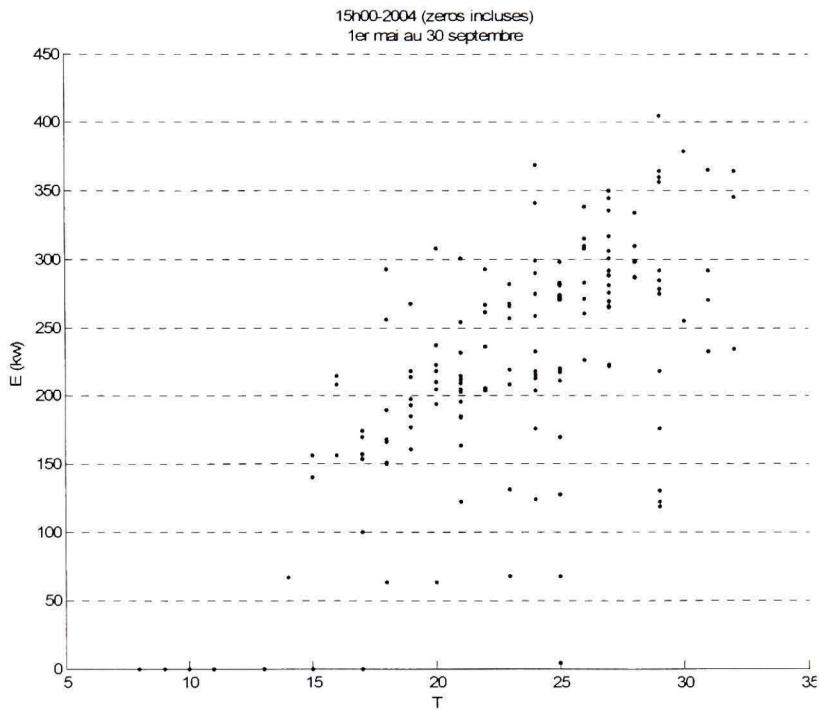


Figure 45 Distribution des charges en fonction des températures ($^{\circ}\text{C}$) pour 15h00.

5.8 Analyse du CV de la prédition suivant l'heure du jour

Pour mieux comprendre l'effet du démarrage et de l'heure du jour sur la qualité de prédition, on calcul le CV avec un modèle de prédition statique pour chaque tranche horaire du jour pour la période du 1^{er} mai au 30 septembre 2005 (Tableau 21). Cela va nous permettre d'identifier l'influence de chaque tranche horaire sur la valeur du CV totale. Dans le calcul des CV partiels (pour chaque ensemble d'heures), on a ignoré la période de 0h à 5h parce que le système est normalement en arrêt. Cela n'empêche pas de dire que dans les feuilles de calcul on a constaté des erreurs de prédition dans cette plage horaire, ce qui explique la différence entre le CV calculé précédemment sur l'ensemble général des données et le CV_moy calculé dans la table ci-dessous (Tableau 21). Le calcul effectué rassemble deux types de CV, le premier (CV_ss_cor) prend comme variables d'entrées : l'heure du jour, deux températures (à t et $t-1$) et six charges électriques antérieures (de $t-1$ à $t-6$) sans aucune correction au niveau des charges électriques de la période de démarrage du

refroidisseur. Le deuxième (CV_cor), prend les mêmes variables d'entrées, mais en prenant en considération la correction multiple (sur plusieurs heures 5.7.2).

Tableau 21 Tableau des coefficients de variances pour chaque heure du jour

| Hdj | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 |
|--------------------|-------|------|------|------|------|------|------|------|------|------|
| CV_ss_cor % | 124 | 40,8 | 35,6 | 24,4 | 22 | 18,2 | 12,8 | 10,4 | 16,5 | 15,9 |
| CV_cor % | 103,7 | 55,3 | 35 | 25,4 | 20,8 | 17,3 | 13,8 | 13,7 | 16,7 | 18,2 |

| Hdj | 16 | 17 | 18 | 19 | 20 | 21 | 22 | 23 | CV_moy |
|------------------|------|------|------|------|------|------|------|------|---------------|
| CV_ss_cor | 15,5 | 17,8 | 16 | 18,4 | 50,5 | 43,2 | 29,9 | 66,1 | 32,1 |
| CV_cor | 12,7 | 13,5 | 21,3 | 19,4 | 43,4 | 38,3 | 28,9 | 57,1 | 30,8 |

On peut aussi remarquer que le CV pour les deux types de prédictions, avec ou sans prédition simplifiée, ne dépasse pas 25% si on prend en compte la plage du temps de 9h à 19h et 17% comme moyenne, c-à-d en excluant les heures de démarrage et les heures de refroidissement tardif de la journée (Figures 46 et 47).

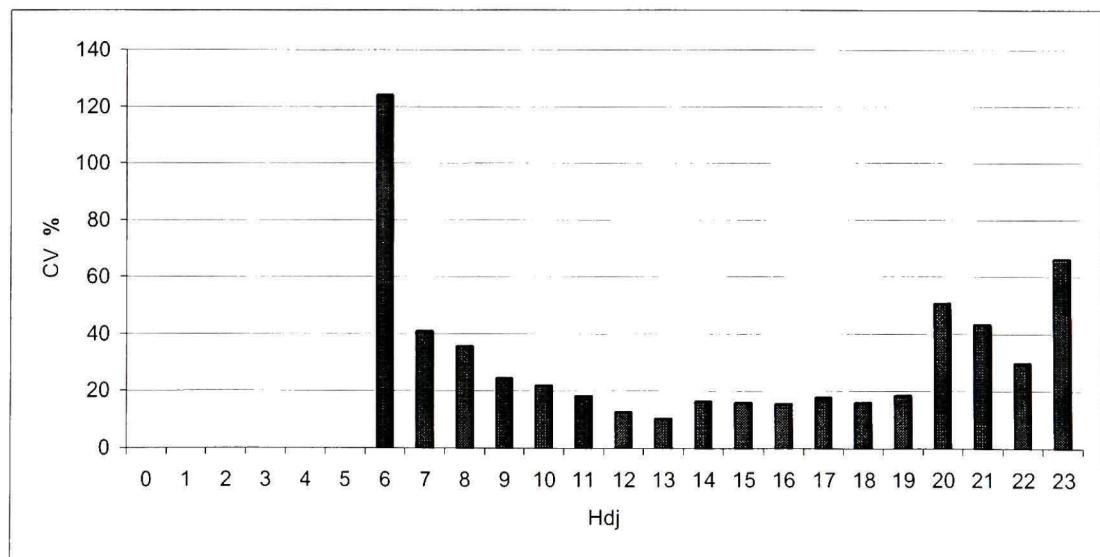


Figure 46 Distribution des CV en fonction de l'heure du jour sans aucune correction.

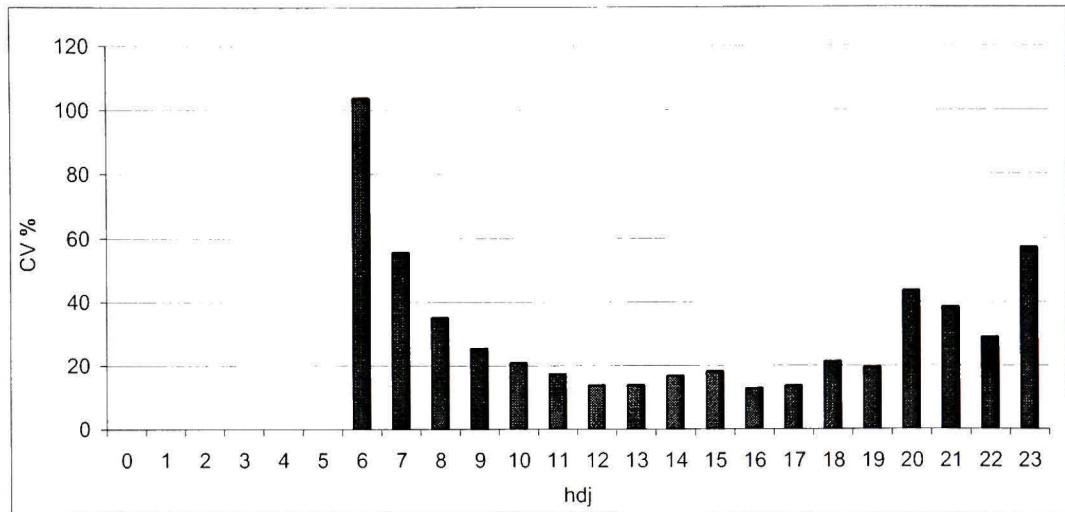


Figure 47 *Distribution des CV en fonction de l'heure du jour avec multi correction.*

5.9 L'effet de la variation des variables de l'entrée sur la qualité de la prédiction

Toutes les simulations de ce chapitre ont été effectuées avec des RNA dont le choix des entrées dans l'échelle du temps est basé sur la précédente étude de régression multivariable (MLR section 4.2). Désormais, avec les résultats obtenus dans ce chapitre on comprend que ce choix d'entrées est incompatible avec la prédiction des charges électrique du refroidisseur basée sur des données réelles. Pour cela, dans cette section on essaye, dans le cas de la prédiction statique, de garder le même nombre de variables d'entrées pour le RNA ($n=9$), pour différent pas dans le temps ($t, t-1, t-2, \dots$)

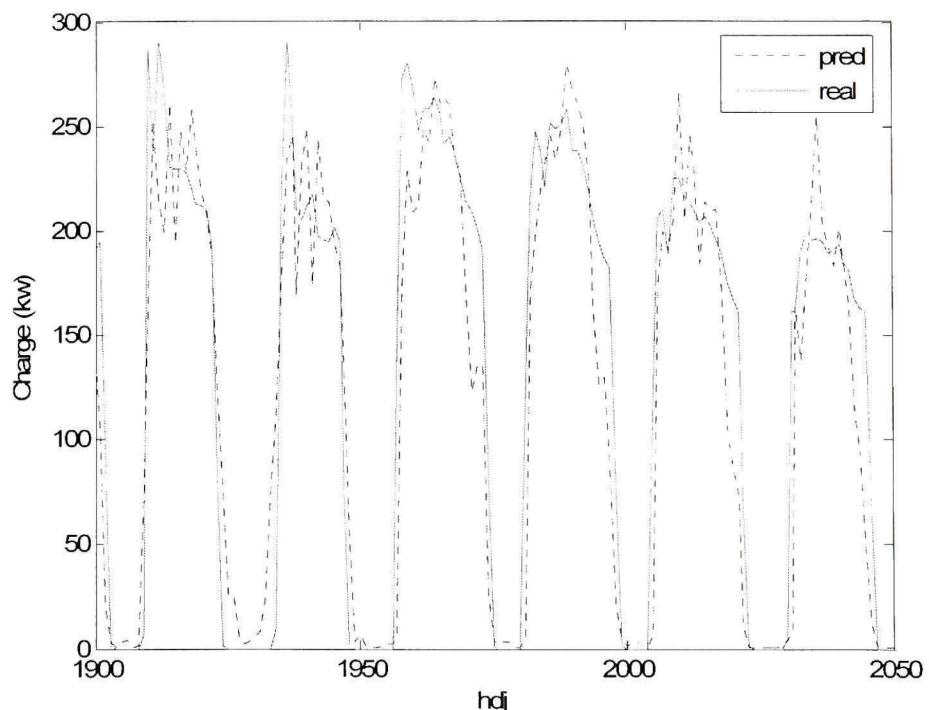
Les résultats dans le tableau ci-dessous (Table 21) présentent les CV des simulations des réseaux neurones statiques sur des données réelles de l'ETS sans aucune correction au niveau des heures de démarrage.

Tableau 22 Résultats de l'effet de la variation des variables d'entrée sur la prédiction

| Cas 1 | Cas 2 | Cas 3 |
|---|---|---|
| Nombre de variables : Hdj, 4 températures, 4 charges | Nombre de variables : Hdj, 6 températures, 2 charges | Nombre de variables : Hdj, 2 températures, 6 charges |
| T : de t-4 à t-1 E : de t-4 à t-1 | T : de t-6 à t-1 E : de t-2 à t-1 | T : de t-2 à t-1 E : de t-6 à t-1 |
| CV=35,9 % | CV=32 % | CV=33,4 % |

Si on compare les deux graphes ci-dessous (Figures 48 et 49), on remarque bien que la qualité de la prédiction avec six températures et deux charges antérieures est meilleure que celle avec deux températures et six charges.

Les graphes prennent en compte six jours de la fin du mois de juillet 2005.

**Figure 48 Réseau incluant 2 températures et 6 charges antérieures.**

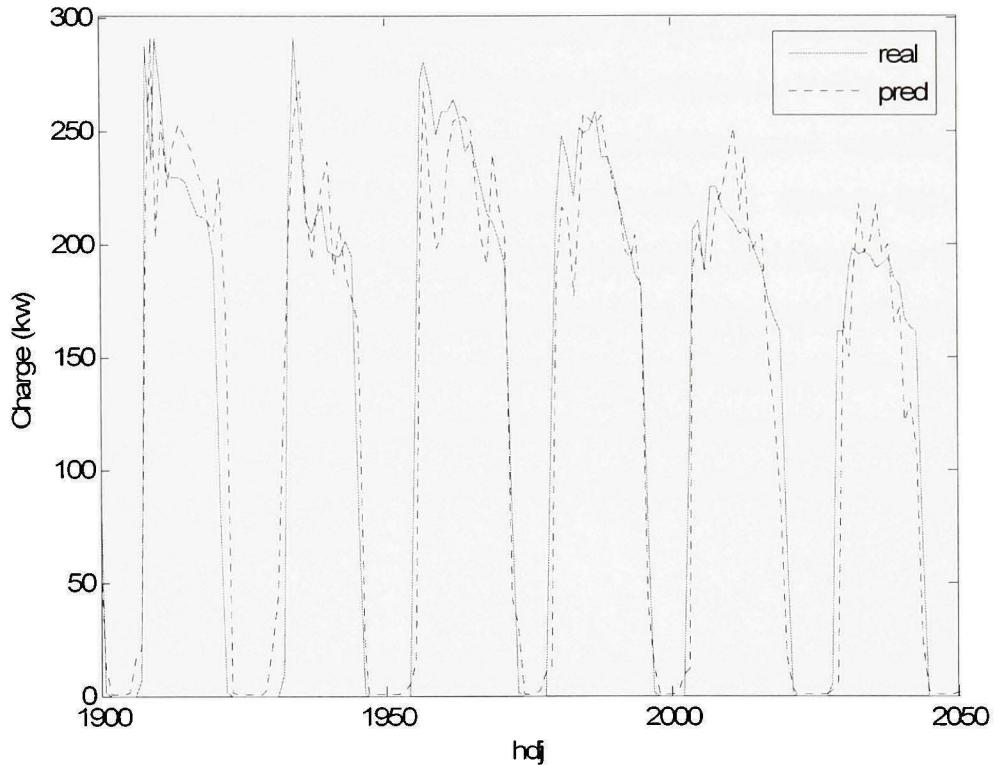


Figure 49 Réseau incluant 6 températures et 2 charges antérieures.

Dans l'annexe 2 de ce mémoire on trouve une analyse complète par graphe sur la distribution des charges prédites en fonction des charges réelles pour chaque heure du jour.

5.10 Prédiction de la charge du refroidisseur avec ajout de type de jour ou suppression de la fin des semaines

Après l'analyse de la distribution des CV en fonction de l'heure du jour, on est persuadé que ce n'est pas juste le démarrage qui peut causer des anomalies au niveau de la prédiction, mais aussi le refroidissement tardif (de 20h à 23h) des locaux du bâtiment en étude.

Une analyse pour les deux bases de données, celles de l'apprentissage et de la validation, a montré que la période de refroidissement tardif (de 20h à 23h) inclut juste les jours de la

semaine et non pas les fins de semaine (samedi et dimanche). Une telle situation peut avoir plusieurs effets sur la qualité de la prédiction, car au niveau de la formation du réseau de neurones, ce dernier ne prend pas en considération le type de jour de la semaine. En conséquent, on propose deux méthodes pour essayer de minimiser l'effet de ce problème. La première consiste à ajouter le type de jour de la semaine comme variable d'entrée au niveau de l'apprentissage du réseau et la deuxième consiste à éliminer les données de samedi et dimanche et garder juste les cinq autres journées de la semaine (du lundi au vendredi). Pour le premier cas, le type de jour est sous une forme binaire (1 : pour la fin de semaine, 2 : pour le reste des jours de la semaine). D'après l'étude précédente, basée sur la variation de nombre de variables entre la température et la charge dans l'ordre du temps, on a adopté la combinaison de six températures et deux charges plus l'heure du jour, comme la mieux adaptée jusqu'à ce moment.

Tableau 23 Résultats de la prédiction avec type de jour ou sans les jours de fin de semaine

| | Avec type de jour (1,2) | Sans les jours de fins de semaine |
|-----------|-------------------------|-----------------------------------|
| RMSE (kW) | 50 | 47,3 |
| CV % | 34,9 | 29,6 |

Si on compare le résultat déjà présenté dans la section (4.8), qui donne un CV de 32% sans inclure ni l'ajout de type de jour ni la suppression des fins de semaines, avec ceux du tableau 23, visiblement le deuxième performe mieux. Le gain de 2,4 % au niveau du CV suppose qu'une prédiction basée sur deux réseaux de neurones : un pour les jours de la semaine et l'autre pour les fins de semaine, serait plus performant.

5.11 Prédiction de la charge du refroidisseur sans les périodes du démarrage ou du refroidissement tardif

La distribution des CV en fonction de l'heure du jour a donné aussi une idée sur sa répartition au long de la journée. En effet pour un apprentissage et une prédiction faits sur le

total des heures de la journée, on a pu avoir un CV de 32 %, mais aussi un autre de 17 % si on prend en compte juste la plage de 9h à 19h pour le même RNA. Pour cela on a pensé à valoriser la qualité de la prédition au niveau du refroidisseur en se limitant sur les données de 9h à 19h, y compris l'apprentissage et la validation du réseau de neurones en question. Le tableau 24 présente la différence entre les deux cas (toute la journée, une partie de la journée) :

Tableau 24 Comparaison entre la prédition partielle (9h-19h) et la prédition pour toute la journée

| | Cas 1 | Cas 2 | Cas 3 |
|-----------------------|---|---|---|
| | Nombre de variables : Hdj, 4 températures, 4 charges | Nombre de variables : Hdj, 6 températures, 2 charges | Nombre de variables : Hdj, 2 températures, 6 charges |
| | T : de t-4 à t-1 E : de t-4 à t-1 | T : de t-6 à t-1 E : de t-2 à t-1 | T : de t-2 à t-1 E : de t-6 à t-1 |
| Pour toute la journée | CV=35,9 % RMSE=51,5 kW | CV=32 % RMSE=45,9 kW | CV=33,4 % RMSE=47,9 kW |
| De 9h à 19h | CV=21,3% RMSE=49,3 kW | CV=21,1% RMSE=48,8 kW | CV=21,6% RMSE=50,1 kW |

Ces résultats suggèrent aussi la possibilité d'avoir une autre combinaison au niveau du processus de la prédition de la charge du refroidisseur de l'ETS. Le développement de trois RNA, le premier pour le démarrage, le deuxième pour le long de la journée et le troisième pour la fin de la journée ou la période du refroidissement tardif. Une telle combinaison ne peut qu'améliorer la qualité de la prédition au niveau du refroidissement, puisqu'elle prend en considération les différents changements au niveau du fonctionnement du refroidisseur et aussi le fait d'atteindre un CV de 21 % pour la période la plus importante de la journée qui est de 9h à 19h (tableau 24).

5.12 L'effet du type de jour sur le CV

La variation de la charge électrique du refroidisseur est souvent influencée par le type de jour qui tient compte de l'occupation du bâtiment qui varie au cours des jours de la semaine aussi les jours de fin des semaines. Pour cela, une étude résumée dans cette section teste la qualité de prédiction suivant la variation du type de jour. La nouvelle simulation consiste à comparer trois modèles différents au niveau de leurs variables d'entrée :

- Le premier modèle prend en considération le type de jour sous forme binaire, afin de distinguer la fin de semaine du reste des jours de la semaine avec 0 et 1 (0 : pour le samedi et dimanche, 1 : pour le reste de la semaine).
- Le deuxième prend aussi le type de jour sous forme binaire, mais l'architecture du réseau pour ce modèle contient 16 variables d'entrées, ce qui implique l'utilisation de 33 neurones au niveau de la couche cachée du RNA [19] : 9 variables de base qui présentent l'heure du jour, la température et la charge électrique.
- Le dernier cas élimine les données de la fin de la semaine et se base juste sur les jours de lundi au vendredi sans prendre en considération le type de jour.

Le tableau 25 montre les différents résultats obtenus.

Tableau 25 L'influence du type de jour sur la qualité de la prédiction

| | Avec type de jour 0 : fin de semaine 1 : jours de la semaine | Avec type de jour 0 : jours inactifs 1 : jour actif de la semaine | Sans les jours de fins de semaine |
|-----------|--|---|-----------------------------------|
| RMSE (kW) | 50 | 60,2 | 47,3 |
| CV % | 34,9 | 41,9 | 29,6 |

Le fait d'ajouter le type de jour sous forme binaire n'a pas vraiment amélioré la qualité de la prédiction surtout dans le deuxième cas (7 variables sous forme binaire) ou le CV augmente jusqu'à 41,9 %. Le meilleur CV reste celui où les fins de semaine ne sont pas considérées (29,6 %).

5.13 Sommaire

L'étude dans ce chapitre utilise les données pour la période d'été des années 2004 et 2005, la première (2004) pour la formation et l'apprentissage du réseau et la deuxième (2005) pour sa validation. Basé sur la section (4.1) le choix des variables d'entrées est resté limité sur l'heure du jour, la température sèche et l'appel de puissance pour toute l'école ou la charge électrique pour le refroidisseur. La formation, l'apprentissage et l'adaptation du RNA ont gardé le même principe que celle des données simulées.

La prédiction en ligne de l'appel de puissance totale de l'ETS a montré un niveau satisfaisant de la qualité de la prédiction via les RNA. L'étude présentée dans cette section a aussi validé l'approche de l'adaptation du réseau même si le CV entre la prédiction statique et la prédiction dynamique a subit une légère variation dû à la bonne qualité de l'apprentissage de base (été 2004). L'ajout du type de jour aux variables d'entrées du RNA influence légèrement la qualité de la prédiction de l'appel de puissance totale de l'école (section 5.4). On peut dire aussi que le type de jour reste un indicateur réel pour la distribution de l'appel de puissance électrique mais il peut être ignoré pour la prédiction via les RNA pour le cas de cette étude.

Cependant, en appliquant le même principe et la même méthode de prédiction utilisée pour l'appel de puissance totale, la prédiction de la charge électrique du refroidisseur est moins performante que celle de la charge totale. L'étude présentée dans la section (5.10) à bien démontré l'influence de démarrage du refroidisseur et le refroidissement tardif le soir sur la qualité de la prédiction. Aussi, plusieurs méthodes ont été élaborées pour résoudre le problème de prédiction de la charge électrique au niveau de la période de démarrage du refroidisseur. Les résultats présentés dans ce chapitre démontrent que la température extérieure n'est pas une variable suffisante pour la prédiction de la consommation électrique du refroidisseur en étude, c'est pour cela que l'on doit prendre en compte aussi de certaines

températures internes des locaux pertinents du bâtiment qui reste malheureusement indisponible pour le moment.

Les résultats cités au cours de ce chapitre concernant la prédition de la charge électrique du refroidisseur suggèrent la possibilité d'implanter trois RNA, un pour la période du démarrage (6h à 9h), l'autre pour le long de la journée (9h à 19h) et le dernier pour la période du refroidissement tardif (20h à 23h).

Cependant, les modèles les plus performants dans ce chapitre restent le RNA dynamique avec fenêtre glissante et sans type de jour pour la prédition de l'appel de puissance de l'École. Aussi, le modèle statique avec une prédition partielle de 9h à 19h incluant 9 entrées (hdj, 6T et 2 Ec) pour la prédition de la consommation électrique du refroidisseur de l'ÉTS.

Les tableaux 26 et 27 englobent successivement l'ensemble des résultats trouvés pour la prédition de l'appel de puissance totale de l'ÉTS et la charge électrique du refroidisseur.

Tableau 26 Résultats des simulations pour l'appel de puissance totale de l'ÉTS

| | | Sans adaptation du réseau | Avec adaptation : base accumulative | Avec adaptation : fenêtre glissante |
|----------------------|-----------|------------------------------|--|--|
| Sans type de jour | CV % | 8,7 | 8,3 | 8,1 |
| | RMSE (KW) | 144,3 | 136,9 | 133,6 |
| Avec type de jour | CV % | 8,7 | 9,4 | 9,2 |
| | RMSE (KW) | 144,2 | 156,1 | 152,9 |

Tableau 27 Résultats des simulations pour la charge électrique du refroidisseur de l'ÉTS

| | CV % | RMSE (kW) |
|---|-------------|-------------|
| Mode statique (8 entrées) | 32.8 | 47.1 |
| Mode dynamique (Base accumulative) | 27.4 | 39.3 |
| Mode dynamique Fenêtre glissante | 27.5 | 39.5 |
| Mode statique (avec indice du mois, 9 entrées) | 34.3 | 49 |
| Mode statique (avec une seule correction) | 34.1 | 49 |
| Mode statique (avec multiples corrections) | 34 | 48.8 |
| Mode statique (9 entrées-4 températures et 4 charges) | 35.9 | --- |
| Mode statique (9 entrées-6 températures et 2 charges) | 32 | --- |
| Mode statique (9 entrées-2 températures et 6 charges) | 33.4 | --- |
| Mode statique (sans les jours de fins des semaines) | 29.6 | 47.3 |
| Mode statique (prédiction partielle de 9h à 19h avec 9 entrées, 6T et 2 Ec) | 21.1 | 48.8 |
| Mode statique avec 10 entrées (ajout de type de jour) | 41.9 | 60.2 |

CONCLUSION

Sommaire

L'objectif de cette recherche était de développer un système de prédition en ligne des besoins énergétiques du bâtiment de l'École de technologie supérieure (ÉTS) en utilisant les réseaux de neurones artificiels. Pour atteindre ce but, deux modèles de prédition ont été mis à l'épreuve : statique et dynamique.

Les deux modes de prédictions sont évalués et testés sur deux types de données, simulées et réelles. Les données simulées englobent les charges électriques du refroidisseur de l'École de technologie supérieure pour l'année 2004 et les données réelles présentent la consommation totale de l'École et la charge électrique du refroidisseur pour les années 2004 et 2005. Les différentes expériences réalisées au cours de cette recherche, ont permis d'établir les conclusions suivantes.

Le choix et le traitement des données d'entrée pour le système sont très importants, lorsqu'on développe un modèle de prédition basé sur les RNA. Il est essentiel que l'ensemble des variables d'entrée soit aussi réduit que possible pour réduire le bruit causé par le superflux et que l'ensemble de ces entrées englobe tous les facteurs pertinents par rapport à la grandeur à modéliser, qui est, dans notre cas d'étude, l'appel de puissance de l'École ou la charge électrique de refroidisseur.

L'utilisation de l'analyse en composantes principales (ACP) et la régression multivariables permettent de donner une idée générale sur les variables les plus influentes dans le système de prédition et sur le pas du temps qu'il faut prendre en compte pour chaque variable d'entrée. Aussi, on a pu présumer que les puissances électriques antérieures sont plus influentes que les données météorologiques, comme les températures sèches ou humides.

La comparaison de deux méthodes de prédiction (régression multilinéaire et les réseaux de neurones artificiels) basée sur les données simulées de la consommation du refroidisseur a montré une différence de 3 % au niveau du CV, ce qui démontre l'avantage de la prédiction via les réseaux de neurones par rapport à la régression multilinéaire (chapitre 4), par conséquent cet avantage a été une motivation pour améliorer l'architecture du RNA utilisée et essayer le mode dynamique pour améliorer le CV.

L'étude met aussi en valeur le mode incrémental de la prédiction de la charge électrique simulée du refroidisseur avec un CV de l'ordre de 21% par rapport à celui du mode statique qui est de l'ordre de 27,5 % (chapitre 4). On constate aussi dans le même chapitre l'importance de bien définir les paramètres caractérisant l'adaptation du RNA, comme les critères du choix des journées qui sort de l'ordinaire ou le nombre de mesures à accumuler avant de déclencher chaque adaptation.

La dernière partie de cette étude est basée sur des données réelles récupérées du système de contrôle de l'ÉTS et confirme l'efficacité des RNA pour prédire l'appel de puissance électrique totale de l'École (chapitre 5). Cependant, la même partie récapitule aussi les différents problèmes qui peuvent limiter le rendement d'un tel modèle, comme la prédiction au cours des heures de démarrage du refroidisseur ou parfois le manque de quelques variables d'entrées estimées pertinentes pour le RNA.

On constate le niveau satisfaisant et la bonne qualité de la prédiction des RNA avec un CV de l'ordre de 8 % et un RMSE de 134 kW pour un appel de puissance totale de l'École qui atteint 2800 kW (section 5.2). Ces résultats qui restent adéquats reflètent la bonne qualité de la prédiction qui est liée à la qualité des données réelles utilisées dans les simulations. Aussi, on a montré dans le même chapitre que l'ajout d'une nouvelle variable à l'entrée comme le type de jour, qui apparaît important dans la prédiction des besoins énergétiques, a influencé négativement la qualité de la prédiction dans ce cas d'étude.

En utilisant la structure des RNA précédents (voir 5.2), et en se limitant aux données réelles de la charge électrique du refroidisseur, un CV dépassant 27 % montre que le modèle de prédiction a une certaine faiblesse à prédire correctement les charges électrique du refroidisseur (5.4). Parmi les anomalies détectées dans cette simulation, on constate la prédiction des charges de l'ordre de 300 kW pour des charges nulles en réalité. Aussi ce qui est notamment remarquable est la perturbation du système de prédiction à chaque démarrage du refroidisseur.

Une étude plus détaillée récapitulée dans 5.6 et 5.7 a donné une explication pour la mauvaise prédiction obtenue et qu'il s'agit des variables d'entrées pertinentes utilisées pour l'apprentissage du RNA en question. On constate que la température extérieure n'est pas une variable suffisante pour la prédiction de la charge électrique du refroidisseur, mais cette dernière est très liée à la température interne des locaux pertinents de l'école.

L'analyse plus détaillée du CV pour la charge électrique du refroidisseur dans les sections 5.8 et 5.11 a confirmé que le problème revient à la période de démarrage et aussi à la période du refroidissement tardif dans la journée, ces deux périodes ne suivent pas une loi stable au niveau de la charge électrique. On a pu obtenir un CV qui ne dépasse pas 21% si on prend en compte seulement la période de 9h à 19h.

On a également constaté le rôle de varier le pas du temps pour les entrées pertinentes du RNA (températures ou charges) tout en gardant le même nombre de variables, cette manipulation a pu améliorer le CV (5.9).

Aussi une autre combinaison de RNA est proposée dans 5.10, qui consiste à adopter une prédiction basée sur deux réseaux de neurones, un pour les jours de la semaine et l'autre pour les fins de semaine. L'étude a montré qu'on peut avoir un gain de 2,4% sur le CV si on exclu les samedis et dimanches et on garde juste le reste des jours de la semaine.

Contributions

Le mémoire de cette recherche présente quelques contributions dont celles-ci :

- Le recensement littérature résume plusieurs articles scientifiques qui donnent une vue générale et détaillée sur les méthodes utilisées dans le domaine de la prédition des besoins énergétiques du bâtiment. Cette partie analyse et compare les différentes méthodes utilisées, tout en mettant l'emphase sur les avantages et les inconvénients de chaque modèle. Ceci facilite la compréhension de la méthodologie de chaque modèle et son application dans la prédition, surtout pour les réseaux de neurones artificiels.
- Dans ce projet, on a aussi montré l'utilité d'autres techniques et méthodes d'analyse comme l'analyse en composantes principales (ACP) pour réduire la dimension des entrées des RNA. Plus que le modèle statistique (ACP), on s'est confié à un modèle mathématique (la régression multivariables) pour déterminer un ensemble plus pertinent des variables d'entrées pour le RNA à l'échelle de temps.
- L'intégration des RNA dynamiques avec ces deux modèles cumulatif et à fenêtre glissante pour améliorer la qualité de la prédition et justifier l'avantage du recourt aux réseaux des neurones artificiels statiques ou dynamiques pour la prédition des besoins énergétique du bâtiment.
- L'implantation de deux algorithmes qui permettent d'ajouter les données des mesures récentes à la base d'adaptation pour les RNA dynamiques cumulatifs ou à fenêtre glissante.
- L'utilisation de la technique des listes chaînées pour trancher entre les nouvelles données influentes ou non qui se présentent pour la mise à jour du RNA dynamique, ce qui accélère le processus de l'adaptation de ce dernier. Cette technique prend en considération les températures et l'appel de puissance électrique antérieures pour la comparaison des entrées.

- Élaboration de différentes solutions pour résoudre des problèmes pour la prédiction de la charge électrique du refroidisseur à partir des données réelles surtout au niveau des heures du démarrage de ce dernier.

Recommandations pour travaux futurs

Cette étude a prouvé l'efficacité des réseaux de neurones artificiels avec ses deux modes (statique et dynamique) dans la prédiction des besoins énergétiques de l'École de technologie supérieure. L'accès à des nouvelles données comme celles de l'année 2006 et 2007 peut augmenter l'efficacité des modèles conçus en améliorant le niveau d'adaptation des RNA utilisés.

Les modèles de prédiction développés au cours de cette recherche ont démontré le potentiel des réseaux de neurones artificiels pour la prédiction des besoins énergétiques du bâtiment de l'ETS. Leur développement a aidé à mettre en application la méthodologie élaborée dans cette recherche. Cependant, d'autres perspectives restent à développer à partir de ce projet qui présente un justificatif de l'efficacité de la prédiction des besoins énergétiques du bâtiment à l'aide des RNA. Cette section présente donc quelques idées pouvant améliorer les modèles présentés dans ce mémoire, leur implantation dans un vrai bâtiment et la conception d'autres modèles applicable pour d'autres types de bâtiment commercial, institutionnel ou industriel.

- Les modèles actuels développés dans cette étude peuvent être améliorés en essayant d'autres types d'architectures au niveau de la connexion neuronale. Par exemple utiliser plus qu'une seule couche cachée, essayer d'autres types de fonction de transfert ou d'autre forme d'apprentissage du RNA.
- L'intégration des nouvelles variables d'entrées pertinentes pour le RNA comme la température des locaux, pourrait augmenter la qualité de la prédiction surtout celle de la charge du refroidisseur. Aussi essayer d'explorer la possibilité de développer des modèles saisonniers pour le chauffage et la climatisation ainsi qu'un modèle

pour les charges auxiliaires. Cette exploration pourrait donner plus d'intérêt à ce type de prédiction.

- L'essai de la mise en œuvre des modèles de prédiction -RNA- standard qui peuvent s'adapter à un ensemble de bâtiment du même genre (institutionnel, commercial,...) où chaque modèle adopte les mêmes variables d'entrées et prédit les besoins énergétiques du bâtiment en question.

ANNEXE I

SPÉCIFICATIONS TECHNIQUES POUR LE REFROIDISSEUR

Spécifications techniques

Le Refroidisseur YORK du pavillon *B* (Refroidisseur centrifuge) :

Refroidisseur à vis de marque YORK, modèle YKDHDGQ&-CNF d'une capacité de 450 tonnes, refroidi à l'eau, utilisant le réfrigérant R-134A, alimentation électrique de 460/3/60.

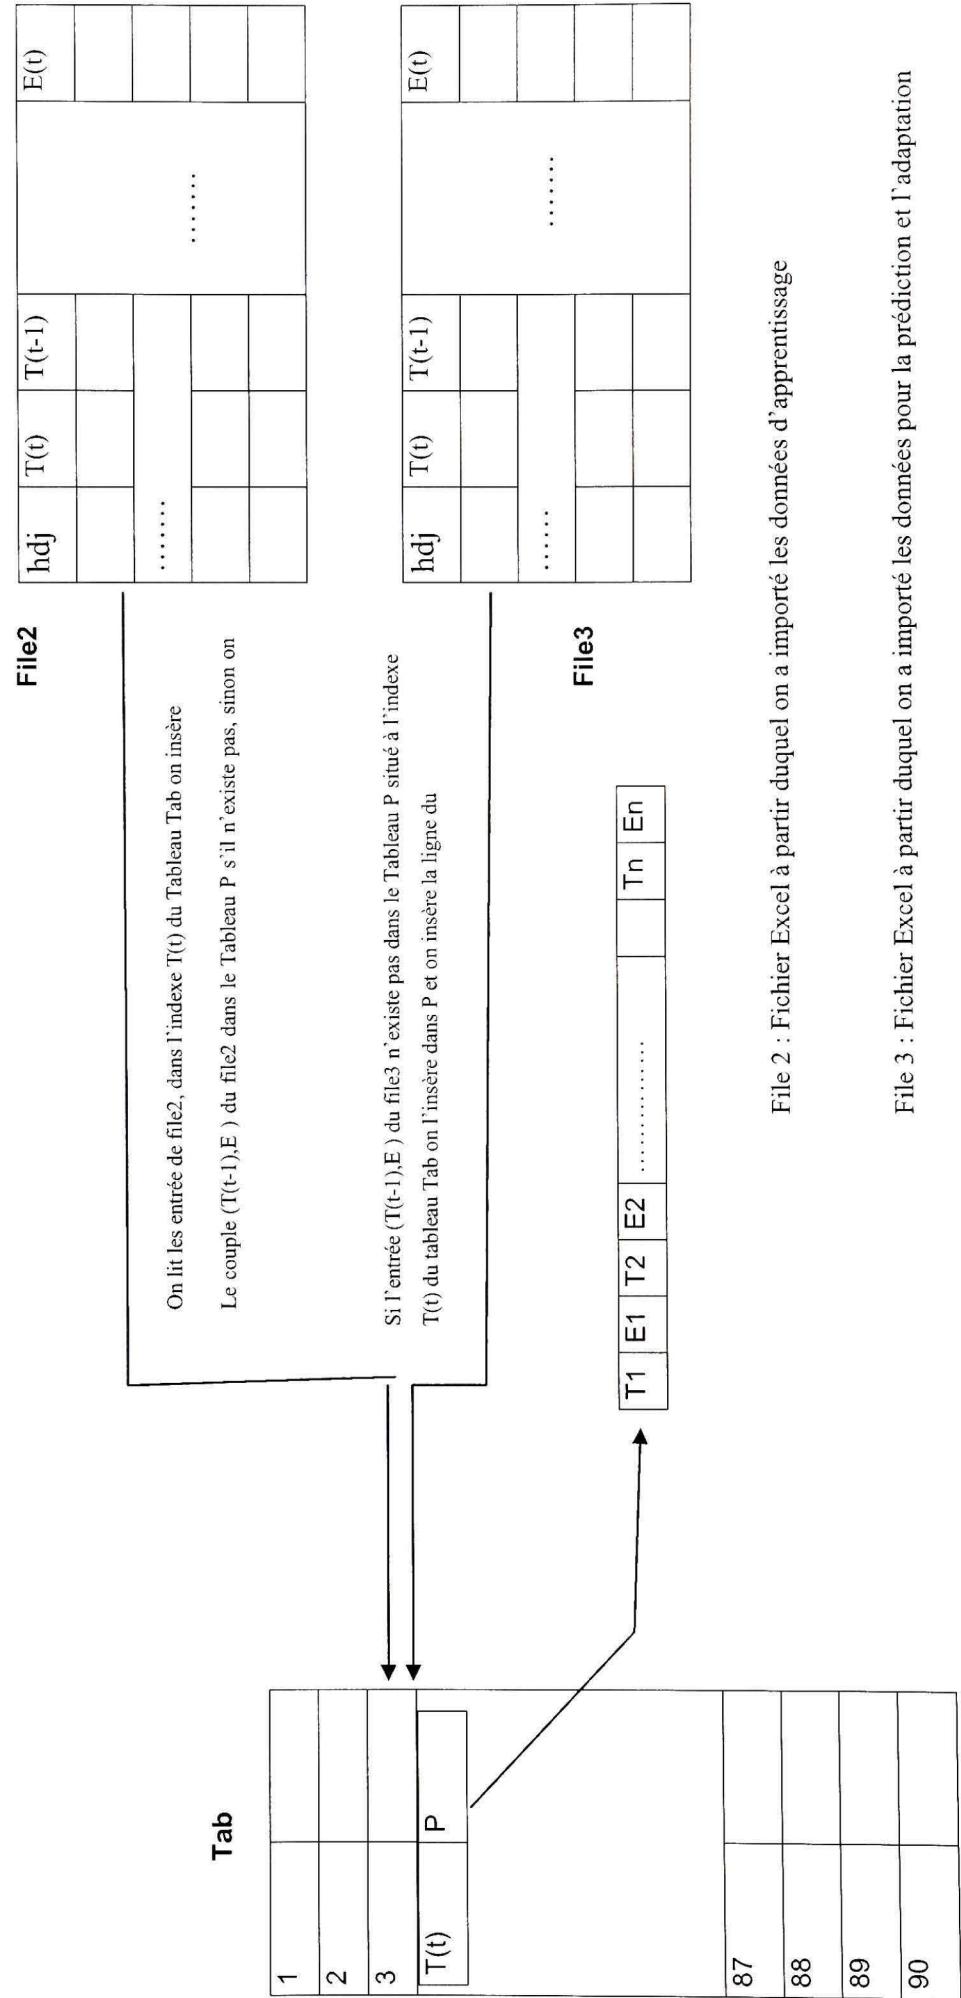
Ce refroidisseur est complet avec :

- compresseur centrifuge, moteur, condenseur, évaporateur, démarreur de style « variateur de vitesse » et panneau de contrôle « Optiview »
- une charge initiale de réfrigérant R-134 A et de l'huile
- l'unité est conçue pour une installation à l'intérieur et livrée en un seul morceau
- **Le compresseur** est de type centrifuge et est entraîné par un moteur électrique de type ouvert. Le contrôle de la capacité est fait par des vannes de pré-rotations à l'entrée de la turbine.
- **L'évaporateur** est de type noyé, et est recouvert d'isolation $\frac{3}{4}$ " épais en usine.
 - o Débit : 1080 gpm
 - o EWT – 55.81 F
 - o LWT – 44 F
 - o Baisse de pression – 30.5 pied d'eau
- **Le condenseur** est de type tube et coquille. Un circuit de sous refroidissement est inclus afin de maximiser la capacité. Une sonde de débit d'eau est fournie.
 - o Débit: 1080 gpm
 - o EWT – 55.81 F
 - o LWT – 44 F
 - o Pressure Drop – 30.5 pied d'eau
- **Panneau de contrôle** « Optiview » sur lequel on retrouve toutes les opérations et les paramètres. (Représentation graphique)

ANNEXE II

SCHÉMA DE STRUCTURE _ LISTES CHAÎNÉES

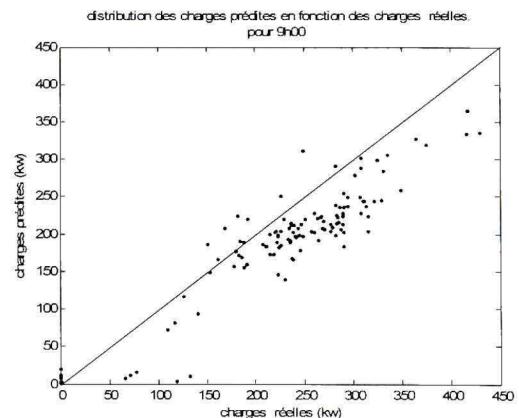
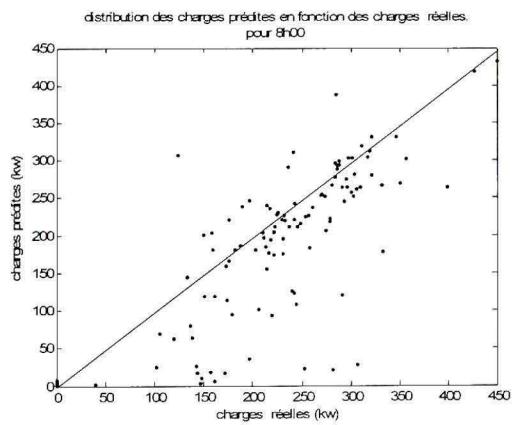
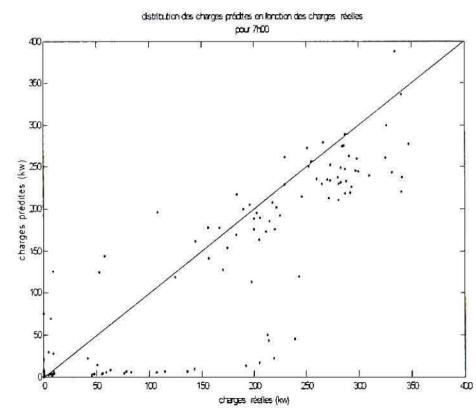
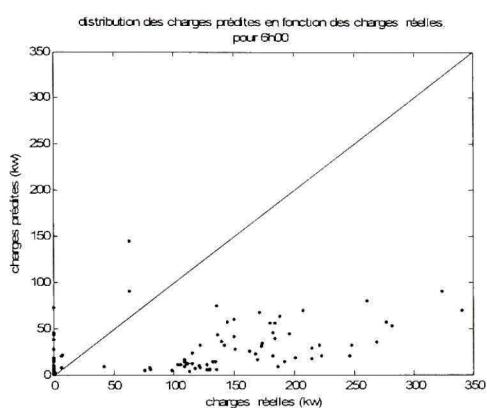
Tab : Tableau de structures (T : température, P : Tableau de couples ($T(t-1)$, E (énergie)) à insérer à partir des fichiers File2 et File3.

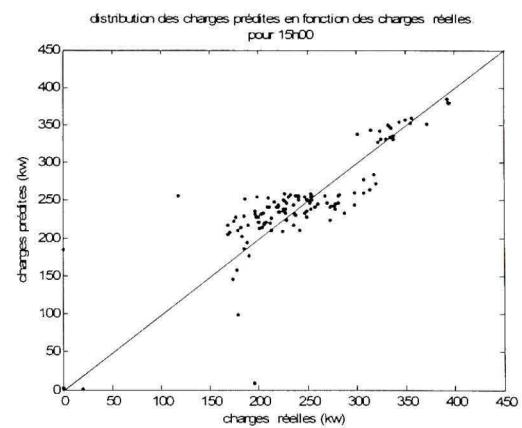
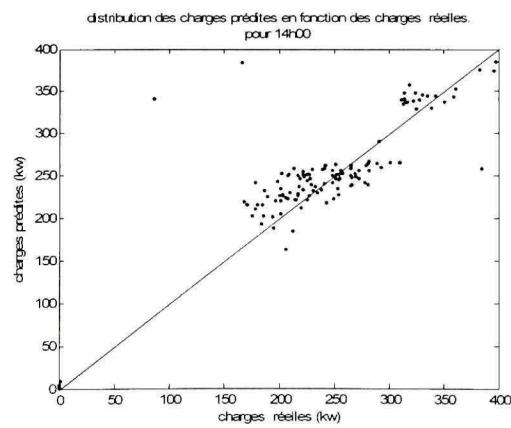
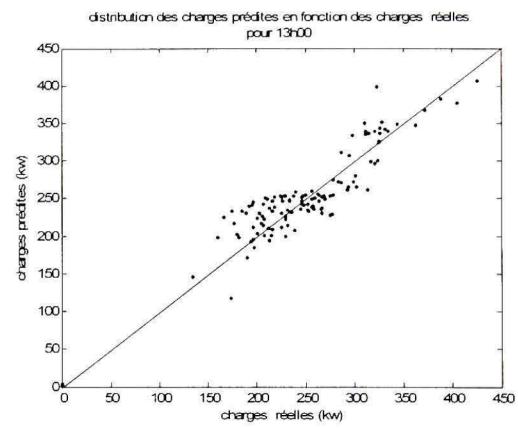
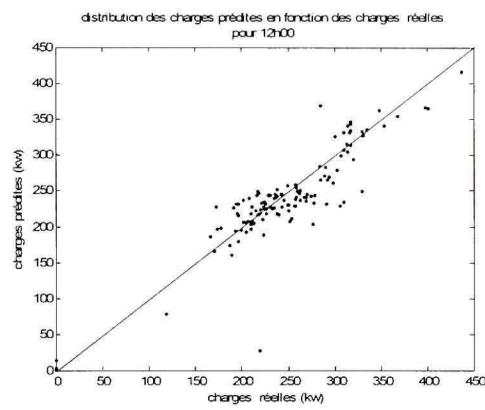
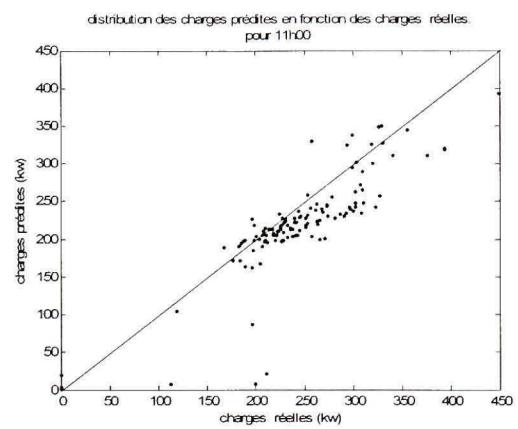
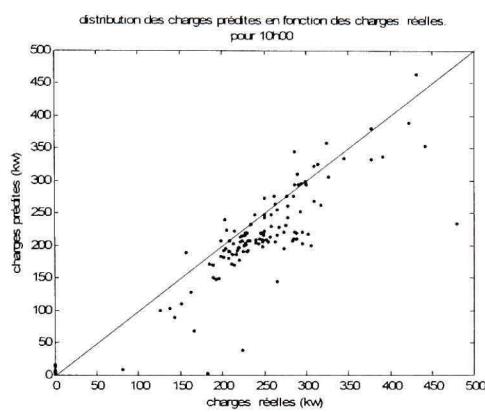


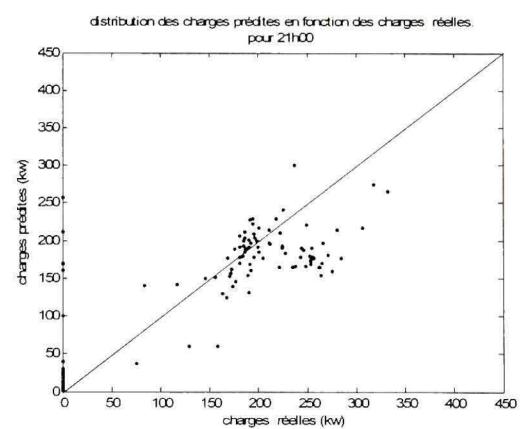
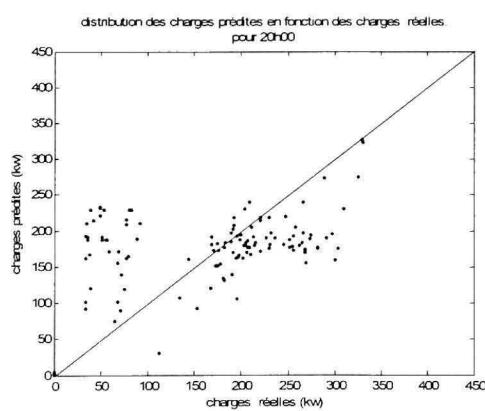
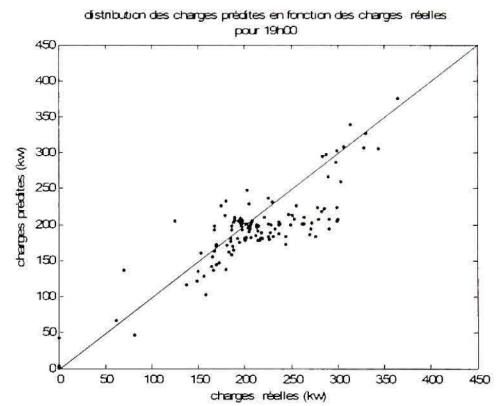
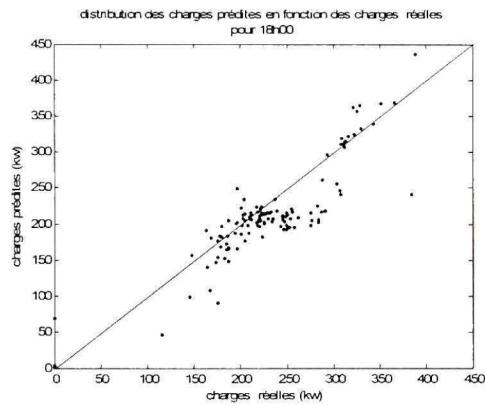
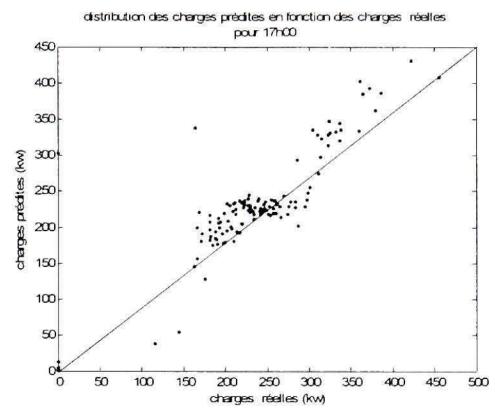
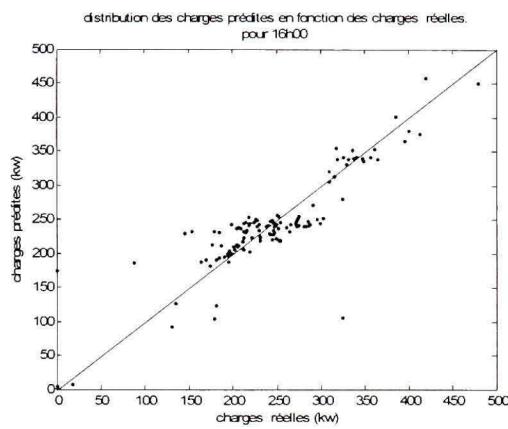
ANNEXE III

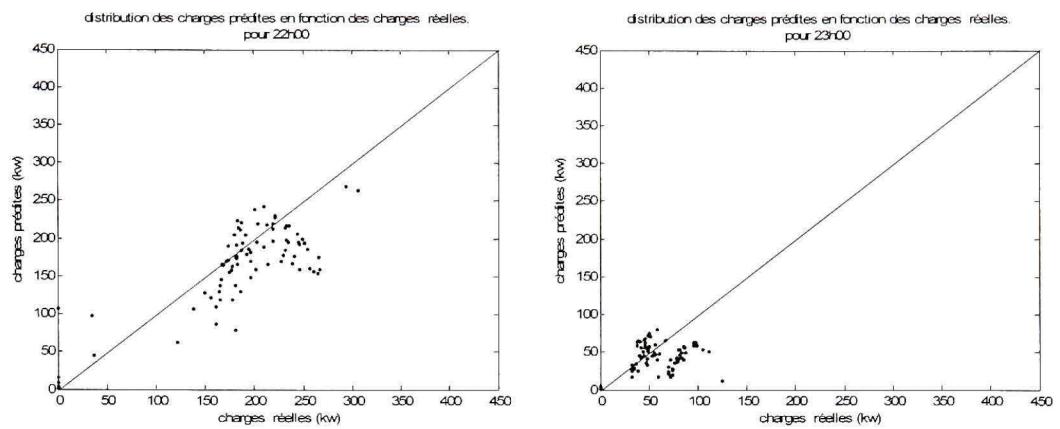
DISTRIBUTION DES CHARGES

Distribution des charges prédictes en fonction des charges réelles pour chaque heure du jour :
Le cas de : 6 températures et 2 charges en arrière.









LISTE DE RÉFÉRENCES

- [1] **KISSOCK**, J., Kelly (Texas A&M Univ); Clardige, David, E.; Haberl, Jeff, S.; Reddy, T., Agami, Measuring retrofit savings for the Texas LoanSTAR program: Preliminary methodology and results, *ASME JSES KSES Int Sol Energy Conf*, pp 299-308, (1992).
- [2] **RUCH**, David (Texas A&M Univ); Claridge, David, E.; Four-parameter change-point model for predicting energy consumption in commercial buildings; *Journal of Solar Energy Engineering, Transactions of the ASME*, v 114, n 2, pp 77-83, (1992).
- [3] **KISSOCK**, K. , Joseph, H.B., McBride, J.R., Effects of varying indoor air temperature and heat gain on the measurement of retrofit savings, *ASHRAE Transactions*, v 104, n 2, pp. 895-900, (1998).
- [4] **KATIPAMULA**, S., REDDY, T.A., CLARIDGE, D.E., Multivariate regression modeling, *Journal of Solar Energy Engineering*, vol. 120, pp. 177-184, (1998).
- [5] **DHAR**, A., Reddy, T.A., Claridge, D.E., Fourier series model to predict hourly heating and cooling energy use in commercial buildings with outdoor temperature as the only weather variable, *Journal of Solar Energy Engineering, Transactions of the ASME*, v 121, n 1, pp 47-53, (1999).
- [6] **DHAR**, A. (Texas A&M Univ); Reddy, T.A.; Claridge, D.E., Improved Fourier series approach to modeling hourly energy use in commercial buildings, *ASME-JSES-JSME International Solar Energy Conference, Solar Engineering*, pp 455-468, (1994a).
- [7] **DHAR**, A. (Enron Corp); Reddy, T.A.; Claridge, D.E., Generalization of the Fourier series approach to model hourly energy use in commercial buildings, *Journal of Solar Energy Engineering, Transactions of the ASME*, v 121, n 1, pp 54-62, (1999b).
- [8] **YALCINTAS**, Melek (Amel Technologies Inc.); Akkurt, Sedat, *Artificial neural networks applications in building energy predictions and a case study for tropical climates*, International Journal of Energy Research, v 29, n 10, pp 891-901, (2005).
- [9] **KAWASHIMA**, Minoru (Inst of Technology at Shimizu Corp), Artificial neural network backpropagation model with three-phase annealing developed for the building energy predictor shootout, *ASHRAE Transactions*, v 100, n 2, pp 1096-1103, (1994).

- [10] **ZAMARRENO**, J.M., Gonzalez, P.A. (Dept. Syst. Eng. & Autom. Control, Univ. of Valladolid, Spain); Prediction of hourly energy consumption in buildings based on a feedback artificial neural network, *Energy and Buildings*, v 37, n 6, pp 595-601, (2005).
- [11] **KRARTI**, M., Kreider, J.F., Cohen, D., Curtiss, P., Estimation of energy savings for building retrofits using neural networks, *Transactions of the ASME. Journal of Solar Energy Engineering*, v 120, n 3, pp 211-216, (1998).
- [12] **KREIDER**, F., Claridge, D.E.; Curtiss, P.; Dodier, R.; Haberl, J.S.; Krarti, M., Building energy use prediction and system identification using recurrent neural networks, *Transactions of the ASME. Journal of Solar Energy Engineering*, v 117, n 3, pp 161-6, (1995).
- [13] **DODIER**, R.H., Henze, G.P., Statistical analysis of neural networks as applied to building energy prediction, *Journal of Solar Energy Engineering. Transactions of the ASME*, v 126, n 1, pp 592-600, (2004).
- [14] **KRARTI**, M., An overview of artificial intelligence-based methods for building energy systems, *Journal of Solar Energy Engineering. Transactions of the ASME*, v 125, n 3, pp 331-342, (2003).
- [15] **KREIDER**, J.F., Curtiss, P.S., Dodier, R., Haberl, S., Krarti, M., Claridge, E., Recurrent neural networks for building energy use prediction and system identification a progress report, *Solar Engineering*, v 1, pp 157-165, (1995).
- [16] **KREIDER**, J.F., Curtiss, P.S., Brandemuehl, M.J., Artificial neural networks proof of concept for local and global control of commercial building HVAC systems, *Solar Engineering*, pp 429-443, (1993).
- [17] **CURTISS**, P.S. (Ecole de Mines in Paris); Brandemuehl, M.J.; Kreider, J.F., Energy management in central HVAC plants using neural networks, *ASHRAE Transactions*, v 100, n 1, pp 476-493, (1994).
- [18] **MOULIN**, L.S., Alves da Silva, A.P., Confidence intervals for neural network-based short-term electric load forecasting, *IEEE Power Engineering Review*, v 20, n 5, pp 79, (2000).
- [19] **KAWASHIMA**, M., Dorgan, C.E., Mitchell, J.W., Hourly thermal load prediction for the next 24 hours by Arima, Ewma, LR, and an artificial neural network, *ASHRAE Transactions*, v 101, n 1, pp 186-200, (1995).
- [20] **KREIDER**, J.F.; Haberl, Jeff S., Predicting hourly building energy usage, *ASHRAE Journal*, v 36, n 6, pp 72-81, (1994).

- [21] **HABERL**, Jeff S., Thamilseran, Sabaratnan, Great Energy Predictor Shootout II: Measuring retrofit savings - overview and discussion of results, *ASHRAE Transactions*, v 102, n 2, pp 419-435, (1996).
- [22] **LEPAGE**, R., Les réseaux de neurones artificiels et leurs applications en imagerie et en vision ordinateur, *École de technologie supérieure*, (2003).
- [23] **MACKAY**, D.J., Bayesian nonlinear modeling for the prediction competition, *ASHRAE Transactions*, v 100, n 2, pp 1053-1062, (1994).
- [24] **FEUSTON**, B.P., Thurtell, J.H., Generalized nonlinear regression with ensemble of neural nets: the great energy predictor shootout, *ASHRAE Transactions*, v 100, n 2, pp 1075-1080, (1994).
- [25] **DREYFUS**, G., Samuelides, M., Martinez, J., Gordon, M., Badran, F., S., Héault, T.L., Réseaux de neurones : Méthodologies et applications, *Eyrolles*, (2004).
- [26] **TREMBLAY**, G., Prévision des augmentations de turbidité à l'eau brute de la ville de Montréal par des réseaux de neurones artificiels, *École polytechnique de Montréal*, (2003).
- [27] **ZURADA**, J.M., Introduction to artificial neural systems, *West Publishing Company*, (1992).
- [28] **SABOURIN**, R., Réseaux de neurones et systèmes flous, *École de technologie supérieure*, (2000).
- [29] **YANG**, J.; Rivard, H.; Zmeureanu, R., On-line building energy prediction using adaptive artificial neural networks, *Energy and Buildings*, v 37, n 12, pp 1250-1259, (2005).
- [30] **TOOLBOX-5-MATLAB 7.0**.
- [31] **WIKIPÉDIA**, Encyclopédie libre en ligne sur internet.