

وزارة التعليم العالي و البحث العلمي

BADJI MOKHTAR-ANNABA UNIVERSITY
UNIVERSITE BADJI MOKHTAR ANNABA



جامعة باجي مختار - عنابة

Année 2009

Faculté des Sciences de l'Ingénieur

Département d'Informatique

MEMOIRE

Présenté en vue de l'obtention du diplôme de *Magistère*

THEME

Comparaison de plusieurs méthodes pour la prédiction de la Charge Electrique Nationale

Option :

Texte, Image et Parole

Par :

Mr Yassine HAMMOUCHE

Directeur de mémoire : M.Tarek KHADIR

Maître de Conférences U. ANNABA

Devant le jury :

Président :

Hassina SERIDI

Maître de Conférences U. ANNABA

Examineurs :

Labiba SOUCI-MESLATI

Maître de Conférences U. ANNABA

Nadir FARAH

Maître de Conférences U. ANNABA

سورة الفاتحة (1)

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ ﴿1/1﴾

الْحَمْدُ لِلَّهِ رَبِّ الْعَالَمِينَ ﴿2/1﴾ الرَّحْمَنِ الرَّحِيمِ ﴿3/1﴾ مَلِكِ يَوْمِ الدِّينِ ﴿1﴾

﴿4/﴾ إِيَّاكَ نَعْبُدُ وَإِيَّاكَ نَسْتَعِينُ ﴿5/1﴾ اهْدِنَا الصِّرَاطَ الْمُسْتَقِيمَ ﴿6/1﴾

صِرَاطَ الَّذِينَ أَنْعَمْتَ عَلَيْهِمْ غَيْرِ الْمَغْضُوبِ عَلَيْهِمْ وَلَا الضَّالِّينَ ﴿7/1﴾

Résumé

Les compagnies de gestion électrique ont besoin d'une prédiction à court terme de la demande de la charge électrique afin de programmer les installations de sa production. Les erreurs de prédiction peuvent mener à des risques et insuffisances dans la génération et distribution de la quantité de la charge électrique vers les utilisateurs.

Les recherches dans cet axe sont nombreuses. Plusieurs pays ont abouti à modéliser la série représentant la variation de leur charge électrique. Ces recherches se basent sur plusieurs approches telles que les modèles Box-Jenkins, les Réseaux de Neurones Artificiels, le filtre de Kalman, etc. Mais la méthode Box-Jenkins et les Réseaux de Neurones Artificiels restent les plus répandues.

Ce travail s'inscrit dans le cadre de la prédiction des séries temporelles, Plus particulièrement, la prédiction de la charge électrique. Des techniques sont appliquées pour prédire la charge électrique Algérienne.

Quatre modèles sont proposés dans le cadre de ce travail. Les deux premiers se focalisent sur la prédiction d'un seul pas en avant. Un modèle se base sur la méthode Box-Jenkins qui représente dans la littérature la base de comparaison de toutes autres techniques. Les résultats obtenus par cette méthode sont comparés avec ceux obtenus par un modèle Réseau de Neurones Artificiels de type Perceptron Multi Couches.

Généralement, un seul pas est insuffisant pour bien fonder la gestion de la ressource. Sur cette base, il est plus intéressant de chercher une prédiction à plusieurs pas en avant. Dans ce contexte, deux modèles sont proposés. Le premier modèle fournit un vecteur de 24 valeurs comme sortie du Réseau de Neurones Artificiels représentant les 24 pas de prédiction. Les résultats sont comparés avec les résultats du deuxième modèle qui consiste à classer les données en 24 classes selon l'heure. Par la suite, on prédit chaque heure séparément pour obtenir 24 prédictions reflétant les 24 pas.

Mots clés : Série Temporelle – Charge Electrique – Box-Jenkins – Réseau de Neurones Artificiels – Perceptron Multi Couches – Prédiction.

Abstract

Companies of electricity management need a short term load forecast in order to program the production tools of Electric Load. Errors in forecast may lead to risks and insufficiencies in the generation and distribution of the quantity of Electric Load to the users.

Researches in this field are numerous. A lot of countries have come to modelise the series representing the variation of their Electric Load. These researches are based on many approaches like Box-Jenkins, Artificial Neuronal Networks, Kalman Filter, etc. but Box-Jenkins method and Artificial Neuronal Network remain the most spread.

This work is in the framework of time series forecast, more particularly, the Electric Load Forecast. Some techniques are applied to forecast the Algerian Electric Load.

Four models are proposed. The first two models concentrate on the forecast of one step onward. One of them is based on Box-Jenkins method, which represents in the literature the basis of comparison of all other techniques. The results obtained by this method are compared with these obtained with the other model which is Artificial Neuronal Network of Multi-Layer Perceptron type.

Generally, only one step is not sufficient to well found the management of the resource. On this basis, it is interesting to look for a forecast of many steps onward. In this context, two models are proposed. This first model supplies one vector of 24 values as output of Artificial Neuronal Network representing the 24 steps of forecast. The results are compared with the results of the second model that consists of classing the data in 24 classer as per the hour. Then, we forecast every hour separately to obtain 24 forecast reflecting 24 steps.

Key words : Time Series – Electric Load – Box-Jenkins – Artificial Neuronal Network – Multi Layer Perceptron –Forecast.

Dédicace

De par ces quelques lignes écourtées

Je transmets un message bien édité

A la mémoire de mes grands parents

A mes parents pour leur amour, patience et leurs sacrifices.

*A mes deux princesses Saïda et Nabila pour qu'un jour elles me voient le
meilleur*

*A l'ange de la maison mon frère Tahar Elyes qui n'arrête jamais de créer
l'ambiance entre nous*

A tous le reste de ma famille adorable

*A tous mes amis de près et de loin surtout: Feriel et son mari Fethi,
Azzeddine, Lamine, Ahmed et Riad pour les beaux
moments de bonheur qu'on a passé ensemble*

*Je réserve une dédicace particulière pour une personne un
peu spéciale, malgré que le destin a séparé
nos chemins, mais sa présence était
toujours une lumière qui me guide, pour toi
Hayet*

Y assine

Remerciements

Au terme de ce travail, je voudrai exprimer ma profonde gratitude envers Dieu le tout puissant qui, grâce à son aide, j'ai pu finir ce travail.

Le travail présenté dans ce mémoire a été réalisé au Laboratoire LABGED à l'Université Badji Mokhtar Annaba sous le précieux suivi de Dr M.T. Khadir. Qu'il me soit permis de lui témoigner toute ma gratitude pour m'avoir si bien suivi dans cette étude, pour m'avoir encadré et pour la confiance qu'il m'a témoigné. Je voudrais également souligner son encouragement, son soutien constant et sa gentillesse incontestable, qu'il veuille trouver dans ce mémoire ma reconnaissance la plus vive et mon grand respect.

Pour m'avoir honoré de sa présence au sein de ce jury, et pour avoir acquiescé sans hésiter d'en assurer la présidence, Madame H. SERIDI est priée d'agréer l'expression de mes sincères remerciements.

Je remercie également Madame L. SOUICI-MESLATI : Maître de Conférence à l'université de Badji Mokhtar, Annaba, ainsi que Monsieur N. FARAH : Maître de Conférence à l'université de Badji Mokhtar, Annaba pour l'intérêt qu'ils portent à ce travail en acceptant de siéger à ce jury et d'en faire ainsi partie.

Ma gratitude s'adresse aussi à tout les enseignants qui ont assuré ma formation du primaire jusqu'à l'université.

Ma gratitude et mon grand respect s'adressent aussi à Mr Mohamed Saad-Laib, pour ces précieux conseils et pour toute aide qui m'a apporté, sans cesse et en permanence.

Pour avoir pris la peine de lire et de corriger ce manuscrit, Azzedine Boussaada est prié de bien vouloir trouver à travers ces modestes lignes mes sentiments sincères de reconnaissance et d'estime.

Je suis particulièrement reconnaissant envers mon amie de toujours, Madame Ferial Debeche-Grid, pour chaque instant passé ensemble en tant que binôme et pour l'aide précieuse et l'appui qu'elle m'a toujours fournis.

Pour l'aide qu'elle m'a apporté pour terminer ce mémoire, je remercie ma sœur Nabila et je souhaite qu'elle trouve tous le bonheur.

Enfin, une pensée distinctive s'adresse à toute ma famille qui n'a ménagé aucun effort pour m'aider et m'apporter du réconfort.

Ne sachant les citer un par un et sans exception aucune, à tout un chacun et toute une chacune dont l'aide et l'assistance m'ont été des plus opportunes.

Liste des tableaux

Tableau 1.1 Les entrées et sorties du Réseau de Neurons Artificiels utilisé dans [43]...	23
Tableau 1.2 Les paramètres des approches utilisées pour la prédiction en Taiwan	28
Tableau 2.1 Les différents modèles de Box-Jenkins	40
Tableau 3.1 Exemples de fonctions d'activation	67
Tableau 3.2 Correspondance type de RNA - Domaine d'application	69
Tableau 4.1 Détail des données de la charge électrique Algérienne utilisées	73
Tableau 4.2 Classification des données utilisées.....	76
Tableau 4.3 Les Ecart-types calculés en appliquant la méthode Box-Jenkins sur la charge électrique Algérienne.....	79
Tableau 4.4 L'erreur FPE et le critère AIC calculés durant l'estimation du modèle Box-Jenkins pour la charge électrique Algérienne.....	82
Tableau 4.5 Les entrées du Réseau de Neurons Artificiels appliqué pour la prédiction d'un seul pas en avant.....	88
Tableau 4.6 Les erreurs de prédiction d'un pas en avant.....	89
Tableau 4.7 les erreurs moyennes de prédictions de 24 pas en avant.....	93
Tableau 4.8 Comparaison des erreurs pour chaque pas obtenu par les deux architectures [8 8 12 24] et [8 8 14 24].....	94
Tableau 4.9 Les entrées pour les 24 modèles utilisés pour la prédiction.....	97
Tableau 4.10 Les erreurs de prédiction pour chaque heure de la journée.....	98
Tableau 4.11 Les erreurs de prédictions pour l'heure 1	134
Tableau 4.12 Les erreurs de prédictions pour l'heure 2	134
Tableau 4.13 Les erreurs de prédictions pour l'heure 3	135
Tableau 4.14 Les erreurs de prédictions pour l'heure 4	135
Tableau 4.15 Les erreurs de prédictions pour l'heure 5	135
Tableau 4.16 Les erreurs de prédictions pour l'heure 6	135
Tableau 4.17 Les erreurs de prédictions pour l'heure 7	136
Tableau 4.18 Les erreurs de prédictions pour l'heure 8	136
Tableau 4.19 Les erreurs de prédictions pour l'heure 9	136

Tableau 4.20 Les erreurs de prédictions pour l'heure 10	136
Tableau 4.21 Les erreurs de prédictions pour l'heure 11	137
Tableau 4.22 Les erreurs de prédictions pour l'heure 12	137
Tableau 4.23 Les erreurs de prédictions pour l'heure 13	137
Tableau 4.24 Les erreurs de prédictions pour l'heure 14	138
Tableau 4.25 Les erreurs de prédictions pour l'heure 15	138
Tableau 4.26 Les erreurs de prédictions pour l'heure 16	138
Tableau 4.27 Les erreurs de prédictions pour l'heure 17	138
Tableau 4.28 Les erreurs de prédictions pour l'heure 18	139
Tableau 4.29 Les erreurs de prédictions pour l'heure 19	139
Tableau 4.30 Les erreurs de prédictions pour l'heure 20	139
Tableau 4.31 Les erreurs de prédictions pour l'heure 21	139
Tableau 4.32 Les erreurs de prédictions pour l'heure 22	140
Tableau 4.33 Les erreurs de prédictions pour l'heure 23	140
Tableau 4.34 Les erreurs de prédictions pour l'heure 24	140

Liste des Figures

Figure 1.1 La charge électrique Algérienne	07
Figure 1.2 Processus général de prédiction	17
Figure 1.3 Processus de prédiction dans [mémoire 07]	22
Figure 3.1 Un neurone biologique et le cerveau humain	52
Figure 3.2 Un neurone formel	54
Figure 3.3 Topologies des Réseaux de Neurones Artificiels	59
Figure 3.4 Un Perceptron monocouche	60
Figure 3.5 Un réseau multicouche	61
Figure 3.6 Réseau de Jordan	63
Figure 3.7 Réseau d'Elman	64
Figure 3.8 Structure de la carte de Kohonen	66
Figure 4.1 La série de la charge électrique Algérienne sur 05 années.....	73
Figure 4.2 La charge électrique Algérienne du Samedi 15 au Vendredi 28 Janvier 2000.....	74
Figure 4.3 Variation de la charge électrique Algérienne pendant la semaine du Samedi 01 au Vendredi 07 Janvier 2000.....	75
Figure 4.4 La moyenne de la charge électrique Algérienne.....	76
Figure 4.5 La variance de la charge électrique Algérienne.....	77
Figure 4.6 La fonction d'auto-corrélations simples de la charge électrique Algérienne ...	78
Figure 4.7 La fonction d'auto-corrélation simple da la série à étudier.....	81
Figure 4.8 La fonction d'auto-corrélation partielle da la série à étudier.....	81
Figure 4.9 La fonction des corrélations des résidus.....	83
Figure 4.10 Les valeurs de la charge électrique Algérienne prédites et réelles pour la période du 03 au 09 Janvier 2004.....	84
Figure 4.11 Les valeurs de la charge électrique Algérienne prédites et réelles pour la période du 07 au 13 Août 2004.....	84
Figure 4.12 Les valeurs de la charge électrique Algérienne prédites et réelles sur l'échelle réelle pour la période du 03 au 09 Janvier 2004.....	85

Figure 4.13	Les valeurs de la charge électrique Algérienne prédites et réelles sur l'échelle réelle pour la période du 07 au 13 Août 2004.....	85
Figure 4.14	Les auto-corrélations des entrées du Réseau de Neurones Artificiels appliqué pour la prédiction d'un seul pas en avant.....	88
Figure 4.15	variation des erreurs d'apprentissage et de validation pour la prédiction d'un pas en avant de la charge électrique Algérienne	90
Figure 4.16	Variation des erreurs d'apprentissage et de validation sur une échelle logarithmique pour la prédiction d'un pas en avant de la charge électrique Algérienne.....	90
Figure 4.17	Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle normalisée pour la période du 03 au 09 Janvier 2004.....	91
Figure 4.18	Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle normalisée pour la période du 07 au 13 Août 2004.....	91
Figure 4.19	Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle réelle pour la période du 03 au 09 Janvier 2004.....	92
Figure 4.20	Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle réelle pour la période du 07 au 13 Août 2004.....	92
Figure 4.21	Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle normalisée pour la journée du 03 Janvier 2004.....	95
Figure 4.22	Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle normalisée pour la journée du 07 Août 2004.....	95
Figure 4.23	Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle réelle pour la journée du 03 Janvier 2004.....	96
Figure 4.24	Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle réelle pour la journée du 07 Août 2004.....	96
Figure 4.25	Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle normalisée pour la journée du 03 Janvier 2004.....	99
Figure 4.26	Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle normalisée pour la journée du 07 Août 2004.....	99
Figure 4.27	Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle réelle pour la journée du 03 Janvier 2004.....	100

Figure 4.28	Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle réelle pour la journée du 07 Août 2004.....	100
Figure 4.29	Comparaison entre les valeurs réelles et prédites par Box-Jenkins et les réseaux de neurones Artificiels de la charge électrique Algérienne pour la journée du 03 Janvier 2004.....	101
Figure 4.30	Comparaison entre les valeurs réelles et prédites par Box-Jenkins et les réseaux de neurones Artificiels de la charge électrique Algérienne pour la journée du 07 Août 2004.....	102
Figure 4.31	Comparaison entre les valeurs réelles et prédites en 24 pas en avance de la charge électrique Algérienne pour la journée du 03 Janvier 2004	103
Figure 4.32	Comparaison entre les valeurs réelles et prédites en 24 pas en avance de la charge électrique Algérienne pour la journée du 07 Août 2004	103
Figure 4.33	La fonction d'auto-corrélations simples de l'heure 1 de la charge électrique Algérienne	120
Figure 4.34	La fonction d'auto-corrélations simples de l'heure 2 de la charge électrique Algérienne	121
Figure 4.35	La fonction d'auto-corrélations simples de l'heure 3 de la charge électrique Algérienne	121
Figure 4.36	La fonction d'auto-corrélations simples de l'heure 4 de la charge électrique Algérienne	122
Figure 4.37	La fonction d'auto-corrélations simples de l'heure 5 de la charge électrique Algérienne	122
Figure 4.38	La fonction d'auto-corrélations simples de l'heure 6 de la charge électrique Algérienne	123
Figure 4.39	La fonction d'auto-corrélations simples de l'heure 7 de la charge électrique Algérienne	123
Figure 4.40	La fonction d'auto-corrélations simples de l'heure 8 de la charge électrique Algérienne	124
Figure 4.41	La fonction d'auto-corrélations simples de l'heure 9 de la charge électrique Algérienne	124
Figure 4.42	La fonction d'auto-corrélations simples de l'heure 10 de la charge électrique Algérienne	125

Figure 4.43 La fonction d'auto-corrélations simples de l'heure 11 de la charge électrique Algérienne	125
Figure 4.44 La fonction d'auto-corrélations simples de l'heure 12 de la charge électrique Algérienne	126
Figure 4.45 La fonction d'auto-corrélations simples de l'heure 13 de la charge électrique Algérienne	126
Figure 4.46 La fonction d'auto-corrélations simples de l'heure 14 de la charge électrique Algérienne	127
Figure 4.47 La fonction d'auto-corrélations simples de l'heure 15 de la charge électrique Algérienne	127
Figure 4.48 La fonction d'auto-corrélations simples de l'heure 16 de la charge électrique Algérienne	128
Figure 4.49 La fonction d'auto-corrélations simples de l'heure 17 de la charge électrique Algérienne	128
Figure 4.50 La fonction d'auto-corrélations simples de l'heure 18 de la charge électrique Algérienne	129
Figure 4.51 La fonction d'auto-corrélations simples de l'heure 19 de la charge électrique Algérienne	129
Figure 4.52 La fonction d'auto-corrélations simples de l'heure 20 de la charge électrique Algérienne	130
Figure 4.53 La fonction d'auto-corrélations simples de l'heure 21 de la charge électrique Algérienne	130
Figure 4.54 La fonction d'auto-corrélations simples de l'heure 22 de la charge électrique Algérienne	131
Figure 4.55 La fonction d'auto-corrélations simples de l'heure 23 de la charge électrique Algérienne	131
Figure 4.56 La fonction d'auto-corrélations simples de l'heure 24 de la charge électrique Algérienne	132

Table des matières

??	i
Résumé	ii
Abstract	iii
Dédicace	iv
Remerciements	v
Liste des tableaux	vi
Listes des figures	viii
Table des matières	xii
Introduction Générale	1
Chapitre 1: Généralités sur les Séries Temporelles & la Charge Electrique	5
1. Introduction	6
2. Définition	8
3. Caractéristiques et propriétés des séries temporelles	8
3.1. Auto covariance	8
3.2. Corrélation et fonction d'auto corrélation	9
3.2.1. Auto corrélation partielle	9
3.2.2. Fonction d'auto corrélation (ACF)	10
3.3. Stationnarité	10
3.4. Ergodicité	10
4. Composantes d'une série temporelle	11
5. Processus classiques	11
5.1. Bruit blanc	12
5.2. Série linéaire	12
6. Intérêt des séries temporelles	12
6.1. Perspective descriptive	12
6.2. Perspective explicative	13

6.3. Perspective prévisionnelle	13
7. Applications des séries temporelles	13
8. La charge électrique	15
8.1. Introduction	15
8.2 Prédiction de la charge électrique	16
8.3. Les types de prédictions	16
8.4. Processus général de prédiction	17
8.5. Techniques de prédiction de la charge électrique	17
8.5.1. Les approches statistiques	19
8.5.2. Les approches de l'Intelligence Artificielle	23
8.5.2.1. Les Réseaux de Neurones Artificiels	23
8.5.2.2. Les approches mixtes	26
9. Conclusion	32
Chapitre 2 : La modélisation linéaire : la méthode Box-Jenkins	33
1. Introduction	34
2. Quelques modèles connus	35
2.1. Le modèle Auto-Régressif (AR)	35
2.2. Le modèle Moyenne Mobile	37
2.3. Processus ARMA (p, q)	38
3. La modélisation avec la méthode Box-Jenkins	38
3.1. Introduction	38
3.2. Algorithme de Box-Jenkins	40
3.2.1. Stationnariser une série	40
3.2.2. Identification du modèle	43
3.2.3. Estimation des modèles dynamiques	43
3.2.4. Evaluation du modèle	45
4. Conclusion	46
Chapitre 3 : Les Réseaux de Neurones Artificiels	47
1. Introduction	48
2. Historique	49

3. Neurone biologique.....	51
4. Neurone formel.....	53
5. Apprentissage.....	54
5.1. Définitions.....	54
5.2. Type d'apprentissage.....	54
5.3. Règles d'apprentissage.....	55
6. Les réseaux de neurones.....	57
6.1. Définitions.....	57
6.2. Propriétés.....	58
6.3. Topologies.....	58
6.3.1 Les réseaux à couches	59
6.3.2 Les réseaux récurrents	62
6.4. Les fonctions de transition et d'activation.....	66
7. Avantages et limites.....	68
8. Applications	69
9. Conclusion.....	70
Chapitre 4 : Modélisation de la Charge Electrique Algérienne.....	71
1. Introduction.....	72
2. Caractéristiques de la charge électrique algérienne.....	73
3. Modélisation de la charge électrique algérienne	75
3.1 Modélisation par la méthode Box-Jenkins.....	76
3.2 Modélisation par les réseaux de neurones Artificiels.....	86
3.2.1. Prédiction a 1 pas en avance.....	87
3.2.2. Prédiction à 24 pas en avant avec 24 sorties.....	93
3.2.3. Prédiction à 24 pas en avant avec 24 modèles.....	97
3.3. Comparaison entre les modèles de prédiction de la Charge Electrique Algérienne.....	101
4. Conclusion.....	104
Conclusion Générale.....	105

Références Bibliographiques.....	109
Annexe 1	119
Annexe 2	133

Introduction Générale

Introduction générale

La prédiction implique la prévision de la valeur d'une variable à un instant donné dans le futur. Plusieurs domaines ont trouvé leur besoin par l'utilisation de la prédiction. Soit dans la planification, la médecine, l'économie ou dans le domaine technique, la prédiction joue un rôle important dans la gestion de ces domaines. Les compagnies d'énergie électrique s'intéressent à la prédiction pour avoir une idée sur les valeurs de la charge électrique, afin de bien gérer la production électrique. Ces compagnies ont besoin d'un prédicteur à court terme à base horaire pour qu'elles puissent commander le dispatching de la charge électrique entre ses clients.

La charge électrique est une ressource non stockable c'est la raison pour laquelle son utilisation demande une importante surveillance de la part des gens qui travaillent sur la gestion de la production électrique. Prédire la valeur future de la charge électrique est le moyen idéal pour diminuer les pertes de charge, à condition qu'elle soit la plus précise. Cette précision nécessite la connaissance des facteurs qui l'influent. La prédiction se fait à l'aide du passé de la charge électrique, c'est-à-dire la consommation des utilisateurs dans les années

précédentes. Il faudra donc répondre à la question suivante : Quelle valeur faut-il garder et quelle valeur faut-il enlever de ce passé? La consommation en terme d'électricité dépend des activités des utilisateurs. Elle dépend donc de leur comportement quotidien, hebdomadaire ou annuel. Selon ce comportement, la charge peut augmenter ou diminuer d'une heure à une autre, d'un jour à un autre ou bien d'une saison à une autre.

Le marché Algérien s'est intéressé à la prédiction de la charge électrique afin de mieux gérer la production électrique Algérienne et pour satisfaire les besoins des clients algériens de la société nationale SONELGAZ, surtout après la déréglementation du marché en 2005. Dans ce projet une comparaison entre plusieurs modèles de prédiction de la charge électrique Algérienne est faite. Les modèles de prédiction se regroupent sous deux catégories: les modèles statistiques et les modèles de l'intelligence artificielle. Dans la première catégorie le modèle de Box-Jenkins a marqué sa puissance en terme de prédiction car il englobe les différents aspects qui peuvent aider à donner une prédiction précise. Il regroupe aussi plusieurs modèles à savoir les modèles auto-régressifs *AR*, les modèles moyenne mobile *MA*, les modèles *ARMA*, *ARIMA*, *SARIMA*, *ARMAX*...etc. Les modèles de l'intelligence artificielle sont les plus répandus en terme de prédiction de la charge électrique avec les Réseaux de Neurones Artificiels comme étant l'approche la plus utilisée.

Dans ce projet, plusieurs modèles sont appliqués sur la charge électrique Algérienne. En premier lieu, le modèle statistique Box-Jenkins est appliqué pour une prédiction d'un seul pas en avant (une heure). Par la suite, il est comparé avec un modèle de l'intelligence artificielle basé sur les Réseaux de Neurones Artificiels. Dans la prédiction de la Charge électrique, il est plus intéressant de prédire plusieurs pas en avant. L'idéale serait d'avoir une prédiction de 24 pas en avant (24 heures). Dans ce travail, deux approches sont utilisées: La première approche est un réseau de neurones artificiels avec 24 sorties reflétant les 24 pas à prédire. L'autre approche se base sur l'utilisation de 24 modèles séparés pour chaque pas à prédire : un modèle pour chaque heure.

Ainsi, ce mémoire s'articule autour de quatre chapitres. Dans le premier chapitre, nous présentons quelques notions liées aux séries temporelles avec comme exemple la charge électrique. Tous les aspects qui entourent la prédiction de la charge électrique sont exposés

en détail, avec un état de l'art sur les différentes approches utilisées dans plusieurs pays. Le second et troisième chapitre présentent d'une manière détaillée les deux techniques utilisées dans ce projet à savoir la méthode Box-Jenkins et les Réseaux de Neurones Artificiels avec toutes leurs caractéristiques.

L'application de ces techniques sur la charge électrique algérienne fera l'objet du quatrième chapitre où nous présentons en premier lieu la charge électrique algérienne. Nous donnons par la suite les résultats des tests obtenus en appliquant les différentes approches de prédiction.

Enfin, ce travail est clôturé par une conclusion et des perspectives.

Chapitre 1 : Généralités sur les Séries Temporelles & la Charge Electrique

- 1. Introduction*
- 2. Définition*
- 3. Caractéristiques et propriétés des séries temporelles*
- 4. Composantes d'une série temporelle*
- 5. Processus classiques*
- 6. Intérêt des séries temporelles*
- 7. Applications des séries temporelles*
- 8. La charge électrique*
- 9. Conclusion*

Chapitre 1 : Généralités sur les Séries Temporelles & la Charge Electrique

1. INTRODUCTION

Les séries temporelles, appelées aussi séries chronologiques ou même chroniques, occupent une place importante dans tous les domaines de l'observation ou de la collection de données. Le terme série est employé pour évoquer des objets (des nombres ou des mots) classés dans un certain ordre. L'ordre utilisé est le temps, plus précisément, on utilise une mesure du temps, exprimée en années, mois, jours, minutes ou n'importe quelle autre mesure. En d'autres termes, les séries temporelles associent des objets divers à des marques temporelles successives plus ou moins équidistantes, c'est-à-dire séparées par la même durée. La série est dite temporelle, parce qu'elle indexe l'objet enregistré (compte, mesure, couleur, etc.) par le temps [1].

Les enregistrements effectués peuvent faire l'objet d'une représentation graphique qui présentera les marques temporelles en abscisse et les valeurs mesurées en ordonnée. La courbe présentée dans la figure 1.1, par exemple, représente les variations de la charge électrique Algérienne. Les mesures sont représentées par rapport à des intervalles horaires.




Figure 1.1 La Charge électrique Algérienne.

Il existe toute une gamme de problèmes spécifiques aux séries chronologiques qui sont familiers aux praticiens de statistiques descriptives et qui nécessitent la mise au point d'un certain nombre de techniques pour un traitement à fondements probabilistes. Parmi ces problèmes on peut citer : la prévision, l'identification et le retrait de la tendance, la correction des variations saisonnières, la détection de rupture, la séparation du court terme et du long terme, l'étude des anticipations des agents, etc. [2].

2. DEFINITION

Une série temporelle est une série d'observations numériques (mesures) indicées par le temps. Ces observations sont représentées par : y_1, y_2, \dots, y_n où $1, 2, \dots, n$ représentent les marques temporelles, y_i est la valeur de la mesure réalisée au temps i [1].

L'étude des séries temporelles a bénéficié de nombreux apports théoriques fondés, essentiellement, sur les progrès de leur modélisation. Il est ainsi d'usage, aujourd'hui, d'aborder ce domaine en évoquant la notion de processus stochastique (ou aléatoire). On peut dire qu'un processus aléatoire est une suite de variables aléatoires indicées par le temps. Ce processus peut être représenté par une notation du type : Y_t avec t une mesure du temps. Il y a autant de variables aléatoires que de valeurs de t [1].

Une série temporelle est une série de nombres indicés par le temps, chacun d'entre eux étant une réalisation d'une variable aléatoire. Ceci peut s'exprimer aussi en disant que la série temporelle est une réalisation d'une famille de variables aléatoires indicées par le temps. Cette famille de variables aléatoires s'appelle un processus aléatoire [1].

3. CARACTERISTIQUES ET PROPRIETES DES SERIES TEMPORELLES

Les séries temporelles et les mécanismes générateurs que sont les processus, ont une structure. En d'autres termes les variables aléatoires composant le processus ne sont pas forcément indépendantes les unes des autres mais établissent certaines relations qui donnent à l'ensemble une sorte de structure [1]. Cette structure est caractérisée par un ensemble de propriétés qui sont : l'autocovariance, la corrélation, la stationnarité et enfin l'ergodicité.

3.1. Autocovariance

Soit Y_t un processus, r et s deux instants. L'autocovariance (ou la fonction d'autocovariance) de Y_t pour les deux instants r et s est, par définition, la covariance des variables Y_r et Y_s .

L'auto-covariance est notée γ_Y et elle est donnée par la formule suivante [1] :

$$\gamma_Y(r, s) = Cov(Y_r, Y_s) \quad (1.1)$$

L'auto-covariance au décalage k est définie par [3] :

$$g(k) = \frac{1}{n} \sum_{j=1}^{n-k} (X_{j+k} - \bar{X})(X_j - \bar{X}) \text{ avec } \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad (1.2)$$

3.2. Corrélation et fonction d'auto-corrélation

Le coefficient de corrélation entre deux variables aléatoires X et Y de moyennes μ_X et μ_Y est défini par [4] :

$$r_{X,Y} = \frac{cov(X, Y)}{\sqrt{var(X) var(Y)}} = \frac{E((X - \mathbf{m}_X)(Y - \mathbf{m}_Y))}{\sqrt{E(X - \mathbf{m}_X)^2 E(Y - \mathbf{m}_Y)^2}} \quad (1.3)$$

Ce coefficient est compris entre -1 et 1. Il mesure la force de la dépendance linéaire entre X et Y .

La notion d'autocorrélation découle de la notion d'autocovariance comme la corrélation de la covariance. Par définition [1] l'auto-corrélation de la série Y_t est :

$$r_Y(h) = \frac{g_Y(h)}{g_Y(0)} = Cor(Y_{t+h}, Y_t) \quad (1.4)$$

pour tout t et pour tout h .

3.2.1. Autocorrélation partielle

L'autocorrélation partielle d'ordre K de la série Y_t est égale au coefficient de corrélation entre $Y_t - E(Y_t / Y_{t-1}, Y_{t-2}, \dots, Y_{t-K+1})$ et $Y_{t-K} - E(Y_{t-K} / Y_{t-1}, Y_{t-2}, \dots, Y_{t-K+1})$.

Ce coefficient, noté $r(K)$ mesure la corrélation entre Y_t et Y_{t-K} , lorsqu'on a éliminé les parties de Y_t et Y_{t-K} , expliquées par les variables intermédiaires [1].

3.2.2. Fonction d'autocorrélation (ACF)

La fonction d'autocorrélation est la fonction qui associe à chaque valeur de k , la valeur de la corrélation $\rho(k)$. On note cette fonction comme étant l'ACF de la série X [3].

3.3. Stationnarité

La stationnarité est la clef de l'analyse des séries temporelles. Une série $\{Y_t\}$ est dite strictement stationnaire si la distribution conjointe de $(Y_{t_1}, \dots, Y_{t_k})$ est identique à celle de $(Y_{t_1+b}, \dots, Y_{t_k+b})$, quel que soit t , où k est un entier positif arbitraire et (t_1, \dots, t_k) une liste de k entiers positifs arbitraires. Autrement dit, la stationnarité stricte dit que la distribution conjointe de $(Y_{t_1}, \dots, Y_{t_k})$ est invariante quand on fait glisser le temps. Cette condition est difficile à vérifier et généralement une version plus faible de stationnarité est utilisée. On dit qu'une série temporelle $\{Y_t\}$ est faiblement stationnaire si la moyenne de Y_t et la covariance entre Y_t et Y_{t-l} sont invariantes par translation du temps. Précisément, $\{Y_t\}$ est faiblement stationnaire [4] si :

- a) $E(Y_t) = \mu$ où μ est une constante indépendante de t .
- b) $Cov(Y_t, Y_{t-l})$ ne dépend que de l'entier l .

La stationnarité faible (ou du second ordre) implique que le graphe de la série en fonction du temps montre des variations autour d'un niveau moyen, ces variations se ressemblent, quel que soit le moment autour de lequel on examine la série.

En général, les processus ne sont pas stationnaires. Aussi, pour étudier un processus, il faut en général, le « stationnariser » [4].

3.4. Ergodicité

Cette notion fondamentale vient de la considération suivante : nous savons qu'une série temporelle est une réalisation particulière d'un processus ; donc chaque observation est l'une des réalisations de la variable aléatoire indicée correspondante ; comment alors calculer

l'espérance, la variance ou la fonction d'autocorrélation du processus alors que nous savons qu'il nous faut connaître beaucoup plus d'un point par variable aléatoire ? [1].

On dira, alors, qu'un processus stationnaire est ergodique, si on peut calculer l'ensemble de ses caractéristiques (moyenne, variance, fonction d'autocorrélation) à partir d'une seule trajectoire, c'est-à-dire à partir d'une observation du processus, par conséquent et de façon pratique, à partir de la série temporelle observée suffisamment longtemps (En bref, on décide que la série observée soit typique au processus) [1].

4. COMPOSANTES D'UNE SERIE TEMPORELLE

L'examen d'une série temporelle (une réalisation d'un processus) permet en général de lui reconnaître trois types de composantes : une tendance, une composante saisonnière et une variation aléatoire. Il est alors utile de séparer ces composantes, et ceci pour deux raisons. La première consiste à répondre à des questions de bon sens comme celles de la croissance ou la décroissance générale du phénomène observé. L'extraction de la tendance et l'analyse de celle-ci répondront à cette question. Il est aussi intéressant de mettre en évidence la présence éventuelle d'une variation périodique grâce à l'analyse de la composante saisonnière. La seconde raisons consiste à débarrasser le phénomène de sa tendance et de ses variations périodiques pour observer plus aisément le phénomène aléatoire [1].

Ainsi, de façon générale [1], la série Y_t peut être écrite de la façon suivante:

$$Y_t = m_t + s_t + e_t \quad (1.5)$$

Où m_t La tendance indicée par le temps
 s_t La variation périodique
 e_t Un bruit.

5. PROCESSUS CLASSIQUES

Les processus sont l'essence même des séries temporelles. Nous passerons en revue brièvement les processus les plus cités.

5.1. Bruit blanc

Familier chez les professionnels de la théorie du signal, le bruit blanc est un processus dont [1] :

- Les espérances (des variables aléatoires constitutives du processus) sont égales à 0.
- Les variances sont égales à s^2 , une constante (donc la même pour toutes les variables).
- La fonction d'autocovariance $\gamma(h)$ est donnée par :
 - $\gamma(h) = s^2$ si $h = 0$.
 - $\gamma(h) = 0$ si $h \neq 0$

Ceci veut dire que les variables sont non corrélées

5.2. Série linéaire

Une série Y_t est dite linéaire si elle peut s'écrire [5] :

$$Y_t = m + \sum_{i=-\infty}^{\infty} y_i e_{t-i} \quad (1.6)$$

Où e_t est un Bruit Blanc $(0, \mathbf{S}_e^2)$

$$y_0 = 1$$

La suite $\{y_i\}$ est absolument sommable, c'est-à-dire $\sum_i |y_i| < \infty$.

6. INTERET DES SERIES TEMPORELLES

D'une façon générale, il est d'usage de considérer l'intérêt des séries temporelles selon trois perspectives : descriptive, explicative et prévisionnelle [1].

6.1. Perspective descriptive

Quand on s'intéresse à une série temporelle, la première étape, comme pour toutes données, est de décrire la série. L'analyse permet de connaître la structure de la série de données étudiée, en utilisant :

- Des diagrammes séquentiels.
- Des histogrammes pour avoir une idée sur la distribution des valeurs.

Sur les graphiques on peut repérer les valeurs atypiques ou aberrantes. On calcule aussi les statistiques descriptives usuelles : moyenne, variance, coefficients d'aplatissement et d'asymétrie.

Une même série temporelle peut être analysée de différentes façons suivant l'objectif poursuivi. Elle peut être utilisée pour comparer une série à d'autres séries.

6.2. Perspective explicative

Les variations d'une série peuvent être expliquées par une autre série (exposition météorologique, pollution atmosphérique, etc.). Il est possible de modéliser une intervention externe grâce à l'analyse de séries temporelles. Cette analyse permet de réaliser des scénarios pour la période contemporaine : en agissant sur une variable explicative, il est possible d'observer le comportement de la variable expliquée.

6.3. Perspective prévisionnelle

La prévision de valeurs à des dates futures connaissant le présent et le passé de la série peut être basée sur un modèle ou bien construite sans référence à un modèle. La prévision a priori permet la planification. La prévision a posteriori permet d'estimer l'impact d'une perturbation (dépistage par exemple) sur la variable expliquée. Des scénarios pour le futur peuvent être réalisés.

7. APPLICATIONS DES SERIES TEMPORELLES

Parmi les multiples applications de l'analyse des séries temporelles, il est possible d'en distinguer neuf principales [6].

Prévoir : La fonction première pour laquelle il est intéressant d'observer l'historique d'une variable vise à en découvrir certaines régularités afin de pouvoir extrapoler et établir une prévision. Il s'agit ici de comprendre la dynamique qui relie une observation à celles qui l'ont

précédé et de supposer que les mêmes causes produisent les mêmes effets. Avec une analyse fine, il est même possible d'établir des prévisions "robustes" vis-à-vis de ruptures brusques et de changements non anticipés.

Relier les variables : Il est important de savoir a priori si certaines relations sont "économétriquement" possibles et d'éviter les équations qui ne présentent aucun sens. L'analyse des séries temporelles permet de savoir quelles équations sont a priori inadéquates.

Déterminer la causalité : Une approche dynamique permet aussi de s'intéresser aux relations de causalité. Pour qu'un mouvement provoque un autre, il est nécessaire qu'il le précède. Une simple concomitance de deux événements révèle davantage une source commune. L'utilisation de retard d'une variable dans les équations, c'est à dire ses valeurs aux périodes précédentes, autorise la mesure des effets de causalité et permet également de connaître la durée de transmission entre une source et son effet.

Distinguer entre court et long terme : Certaines lois de comportement ne sont jamais vérifiées en pratique car elles ne s'appliquent que sur les équilibres de long terme. A plus courte échéance, des variations contrarient perpétuellement leur mise en oeuvre. Cependant, des ajustements transitoires s'opèrent continuellement afin de s'approcher de ces équilibres. On reformule alors le modèle sous la forme d'un mécanisme dit de correction d'équilibre (ou d'erreur), selon lequel un écart (une erreur) positif par rapport à l'équilibre de long terme entraîne une variation de court terme négative, afin de réduire cet écart.

Etudier les anticipations des agents : Comment prendre en compte les anticipations des agents ? Dans une décision entre épargne et consommation, ce ne sont pas seulement les revenus actuels et passés qui comptent, mais aussi l'idée qu'on se fait de l'avenir. Il faut donc dans certaines équations faire intervenir des valeurs avancées des variables, via leur anticipation en utilisant la manière dont celles-ci ont été formées dans le passé.

Repérer les tendances et cycles : Des méthodes dynamiques repèrent des tendances mouvantes des données par différence. L'écart entre le niveau de la variable (localement monotone) et la position de sa tendance est en moyenne nul : il repère la position dans le

cycle. Selon le modèle de tendance utilisé, il est possible d'analyser les interactions entre diverses variables afin d'atteindre un équilibre entre méthodes économétriques et purement statistiques.

Corriger des variations saisonnières : La correction des variations saisonnières devient plus complexe quand les comportements évoluent davantage ; écart entre deux trimestres consécutifs peut se modifier et la série apportera alors une information supplémentaire.

Détecter les chocs structurels : Un choc structurel est défini comme une modification permanente ou temporaire de la façon dont une variable est générée. Il est fréquent, souvent non-anticipable et difficile à mesurer. Il est cependant essentiel de savoir qu'une telle rupture a eu lieu car sa présence change les interactions et les équilibres, souvent radicalement. L'ignorer engendre alors des effets contraires aux buts poursuivis.

Contrôler les processus : Le but poursuivi est la formulation d'un modèle statistique qui soit une représentation congruente du processus stochastique (inconnu) qui a généré la série observée.

8. LA CHARGE ELECTRIQUE

8.1. Introduction

Le système d'énergie est un système dynamique. La charge électrique change continûment. Elle est affectée par l'heure du jour, le jour du mois, le climat (la température, l'humidité, la quantité de pluie, la neige ou la vitesse du vent), les événements spéciaux (vacances, fêtes nationales et religieuses) [7-8]. Elle peut être vue comme étant une série temporelle discrète [9].

Un des problèmes majeurs de l'utilisation de la charge électrique est la connaissance de sa valeur future (demande de l'utilisateur) [10], car elle ne peut être stockée. L'énergie électrique est générée, transmise, distribuée et consommée en même temps [11-12].

L'objectif principal d'un système de planification de générateur d'énergie est de fournir une prédiction de la valeur de la charge électrique [13], d'après l'historique de ses valeurs [14]. Pour cette raison, le processus de prédiction est considéré comme une partie essentielle dans le système chez les fournisseurs d'énergie [15].

8.2. Prédiction de la charge électrique

Prédire la charge électrique veut dire trouver un moyen automatique pour estimer les valeurs qui vont représenter les consommations des utilisateurs en énergie électrique dans le futur. Une prédiction précise aide les systèmes de gestion d'opérations de charge électrique à faire des décisions opérationnelles. Elle est à la base des programmations économiques : de capacité à fournir, de l'évaluation et de la planification des transactions électriques, de l'analyse de sécurité, des achats de carburants et de la maintenance à court terme [16-19].

8.3. Les types de prédictions

Selon le temps, minute, heure, jour, semaine, mois ou plus d'un an la prédiction de la charge électrique se classifie en court terme, moyen terme et long terme [20].

Les prédictions de la charge électrique à long terme se rapportent à des prévisions sur une échelle annuelle. Elles concernent les consommations électriques annuelles, les ventes ou la demande annuelle maximale. Ces prédictions sont exigées pour la planification financière ou le réseau de transmission. A cause de l'annualité de l'échelle de prédiction, les données n'ont aucune caractéristique saisonnière ou comportement cyclique [21].

Pour les prédictions de la charge électrique à moyen terme, on se rapporte à une échelle moins d'une année et supérieure à une journée. On utilise ce genre de prédictions pour prévoir la totalité d'une demande électrique hebdomadaire ou une charge mensuelle. Ces prédictions sont utiles pour la fourniture du carburant et la programmation de la maintenance.

Les prédictions à court terme de la charge électrique se rapportent typiquement à des bases horaires. Dans le domaine de l'industrie on s'intéresse le plus souvent à la prédiction à court terme [22].

8.4. Processus général de prédiction

Peu importe l'approche utilisée pour prédire une variable, l'algorithme de prédiction est le même. Il est schématisé dans la figure 1.2 [23].

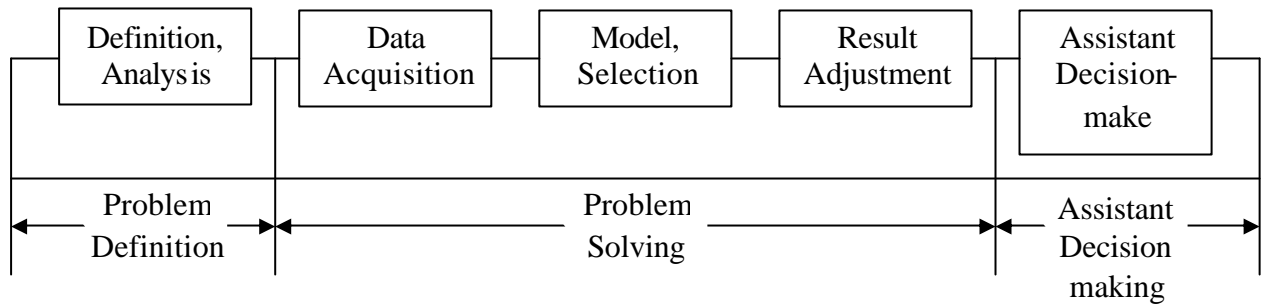


Figure 1.2 Processus général de prédiction.

Premièrement, les données de variables utilisées durant la prédiction sont rassemblées avec leurs caractéristiques. En deuxième lieu, une approche est sélectionnée à la base de ce qu'on a conclu dans l'étape précédente. Les paramètres du modèle choisi seront établis dans cette phase. Ensuite, la prédiction est réalisée. A la fin, les résultats de la prédiction seront analysés et peut être ajustés pour avoir la décision finale du système de prédiction [24].

8.5. Techniques de prédiction de la charge électrique

Une large variété de techniques pour la prédiction de la charge électrique existe dans la littérature. Elles sont classées en approches statistiques et approches de l'Intelligence Artificielle [25].

Statistiquement, deux façons sont utilisées : Statique et dynamique [9]. Les modèles statiques considèrent la charge électrique comme une combinaison linéaire, exponentielle ou polynomiale de fonctions temporelles. Elles décrivent les variations de la charge électrique [9]. La décomposition est souvent faite à l'aide d'une étude sur les valeurs de la charge électrique [15].

Malgré la simplicité de cette technique elle présente une forte limite d'utilisation à cause de la non-linéarité de la charge électrique [15], l'incapacité de montrer l'effet des caractéristiques climatiques [9] ou les changements d'événements inattendus ou sociaux [26].

Les modèles dynamiques se focalisent sur l'analyse des séries temporelles [27]. Pour cette méthode introduite, on cherche des caractéristiques dans le passé de la série et on essaye de les faire induire dans le futur [28]. L'analyse des séries temporelles est l'approche la plus utilisée dans la prédiction de la charge électrique [29]. Mais le fait que la technique impose la stationnarité de la série, chose qui n'est pas tout le temps vraie en pratique, rend les résultats obtenus par cette méthode non trop satisfaisants [30-31].

Avec le développement de l'Intelligence Artificielle, les Systèmes Experts ont marqué leur succès en terme de prédiction. Ils prédisent à base de règles fournies par un expert humain dans le domaine [26]. L'inconvénient trouvé dans ces méthodes est la difficulté de bien représenter les connaissances humaines en règles [32].

Les Réseaux de Neurones Artificiels ont émergés pour être des outils d'apprentissage pour la modélisation, la classification et l'approximation de fonction [33-34]. Dans les dernières années, ils ont été utilisés dans la prédiction de la charge électrique pour pallier aux problèmes trouvés dans les anciennes approches [28]. L'avantage des Réseaux de Neurones Artificiels est leur capacité d'apprendre du passé et de faire une généralisation [35] qui a rendu la prédiction de la charge électrique plus précise [15]. Leur principe se base sur l'extraction du lien qui existe entre les entrées et sorties du système [36]. Ils interprètent la dépendance qui existe entre les valeurs de la charge électrique (son passé) et les facteurs qui influent [37-38].

Ces avantages ont rendu les Réseaux de Neurones Artificiels des approches plus prometteuses dans le domaine de la prédiction de la charge électrique, surtout en les combinant avec d'autres techniques de L'Intelligence Artificielle comme la Logique Floue, les Algorithmes Génétiques ou les Ondelettes [39].

Dans ce qui va suivre, on présentera quelques approches pour la prédiction de la charge électrique.

8.5.1. Les approches statistiques

Un modèle statistique, pour prédire 24 heures en avant de la charge électrique, est proposé dans [40]. Il est de la forme :

$$Y(t) = Y_B(t) + Y_T(t) + Y_R(t) + e(t) \quad (1.7)$$

Où : $Y(t)$ La valeur de la charge électrique horaire à l'heure t .

$Y_B(t)$ La Composante de base de la charge, qui reflète les changements réguliers de la charge électrique indépendamment des conditions météorologiques à l'heure t .

$Y_T(t)$ La Composante sensible à la météorologie de la charge à l'heure t .

$Y_R(t)$ La Composante des changements aléatoires de la charge à l'heure t .

$e(t)$ Un Bruit Blanc avec une moyenne nulle et une variance constante.

La composante de base utilise un modèle GES (General Exponential Smoothing / lissage exponentiel) basé sur les changements quotidiens hebdomadaires de la charge électrique. Elle est calculée par la formule suivante, fondée sur la notion de série de Fourier :

$$Y_B(t) = a_0 + \sum_{i=1}^n [a_i \sin(\mathbf{w}_i t) + b_i \cos(\mathbf{w}_i t)] \quad (1.8)$$

Où : $\mathbf{w}_i = (2\mathbf{p} / 168)k_i$, k_i est un entier

Pour modéliser la composante météorologique, le modèle suivant est utilisé:

$$Y_T(t) = c_0 + \sum_{j=1}^{L_1} \sum_{k=1}^{M_j} \sum_{i=0}^{L_2} c_{ijk} T_j(t-i)^k \quad (1.9)$$

Où : L_1 Nombre de variables météorologiques à modéliser.

M_j Constante reflétant la non linéarité de la relation entre les variables météorologiques et la composante météorologiques.

c_{ijk} Coefficient du k^{ieme} ordre de la j^{ieme} variable météorologique au i^{ieme} retard horaire.

$T_j(t)$ Valeur de la j^{ieme} variable météorologique à l'heure t .

L_2 Constante reflétant l'effet temporel des changements météorologiques.

Il a été prouvé que la température est la plus importante variable influant sur la charge électrique. La composante aléatoire est calculée par la formule :

$$Y_R(t) = Y_T(t) - \tilde{a}_0 - \sum_{i=1}^n [\tilde{a}_i \sin(\mathbf{w}_i t) + \tilde{b}_i \cos(\mathbf{w}_i t)] - \sum_{j=1}^{L_1} \sum_{k=1}^{M_j} \sum_{i=1}^{L_2} \tilde{c}_{ijk} T_j(t-i)^k \quad (1.10)$$

Où les paramètres avec '~' représentent les valeurs estimées.

Cette composante sera modélisée par un processus AR de la forme :

$$\mathbf{q}(B)Y_R(t) = \mathbf{e}(t) \quad (1.11)$$

et

$$\mathbf{q}(B) = 1 - \sum_{i=1} \mathbf{q}_{q_i} B^{q_i} \quad (1.12)$$

Où : \mathbf{q}_{q_i} Les coefficients du processus AR.

B L'opérateur de retard.

q_i Le i^{ieme} terme en retard de q heure avant l'heure actuelle.

Après le test et l'implémentation de la méthode sous FORTRAN77, le modèle approuvé est celui-ci :

- Pour les harmoniques du modèle GES :

{1,2,3,6,7,8,13,14,15,20,21,22,28,35,49}

- Pour le modèle non linéaire sensible à la température :

$$Y_T(t) = \sum_{j=1}^3 [c_{1j} T_a(t)^j + c_{2j} T_a(t-1)^j + c_{3j} T_a(t-2)^j] \quad (1.13)$$

- Pour le modèle AR :

$$Y_R(t+1) = (\mathbf{q}_0 + \mathbf{q}_1 B + \mathbf{q}_{23} B^{23}) Y_R(t) \quad (1.14)$$

L'erreur moyenne absolue (formule 1.29) et l'erreur de variation standard (formule 1.28) sont utilisées pour tester les résultats obtenus par l'application du modèle. Les données ont été divisées en quatre (04) classes, selon les mois de l'année : Janvier : Mars, Avril : Juin, Juillet : Septembre et Octobre : Décembre. Pour les quatre classes, les résultats prouvent l'efficacité de la méthode proposée en arrivant à des erreurs inférieures à 1.5%.

Dans [41], Un modèle autorégressif (AR) est présenté, pour la prédiction de 04 heures en avant de la charge électrique en Island. Premièrement, la charge électrique est divisée en une composante annuelle L_A (saisonnière), une composante journalière L_D et une composante stochastique L_S . Chaque composante est calculée, respectivement, par :

$$\hat{L}_A(w+1) = L_A(w) \quad (1.15)$$

Où : w est le numéro de la semaine

$$L_D(w; d, h) = \frac{1}{n_w} \sum_{w'=w_0}^w L_D(w', d, h) \quad (1.16)$$

Où : d est le numéro du jour ($d=1, 2, \dots, 7$)

h est le numéro de l'heure ($h=1, 2, \dots, 24$)

$$L_S(w', d, h) = L(w', d, h) - L_A(w') - L_D(w', d, h) \quad (1.17)$$

L'erreur RMS calculée pour tester les résultats obtenus est acceptable. Elle atteint 0.85 pour 04 pas en avant contre 0.55 pour un seul pas en avant.

Dans [42], un modèle ARMA, mais modifié, est étudié. Un test sur la nature du processus, Gaussien ou non, est inclus dans le processus de modélisation. Le test utilise la formule de calcul de Bispectrum donné par la formule (1.18). Le processus complet de la méthode proposée est schématisé dans la figure 1.3.

$$B_y(w_1, w_2) = \sum_{m=-\infty}^{\infty} \sum_{n=-\infty}^{\infty} c_{3y}(m, n) \exp[-i(w_1 m + w_2 n)] \quad (1.18)$$

Où $0 \leq w_1 \leq p, w_2 \leq w_1, 2w_1 + w_2 \leq 2p$

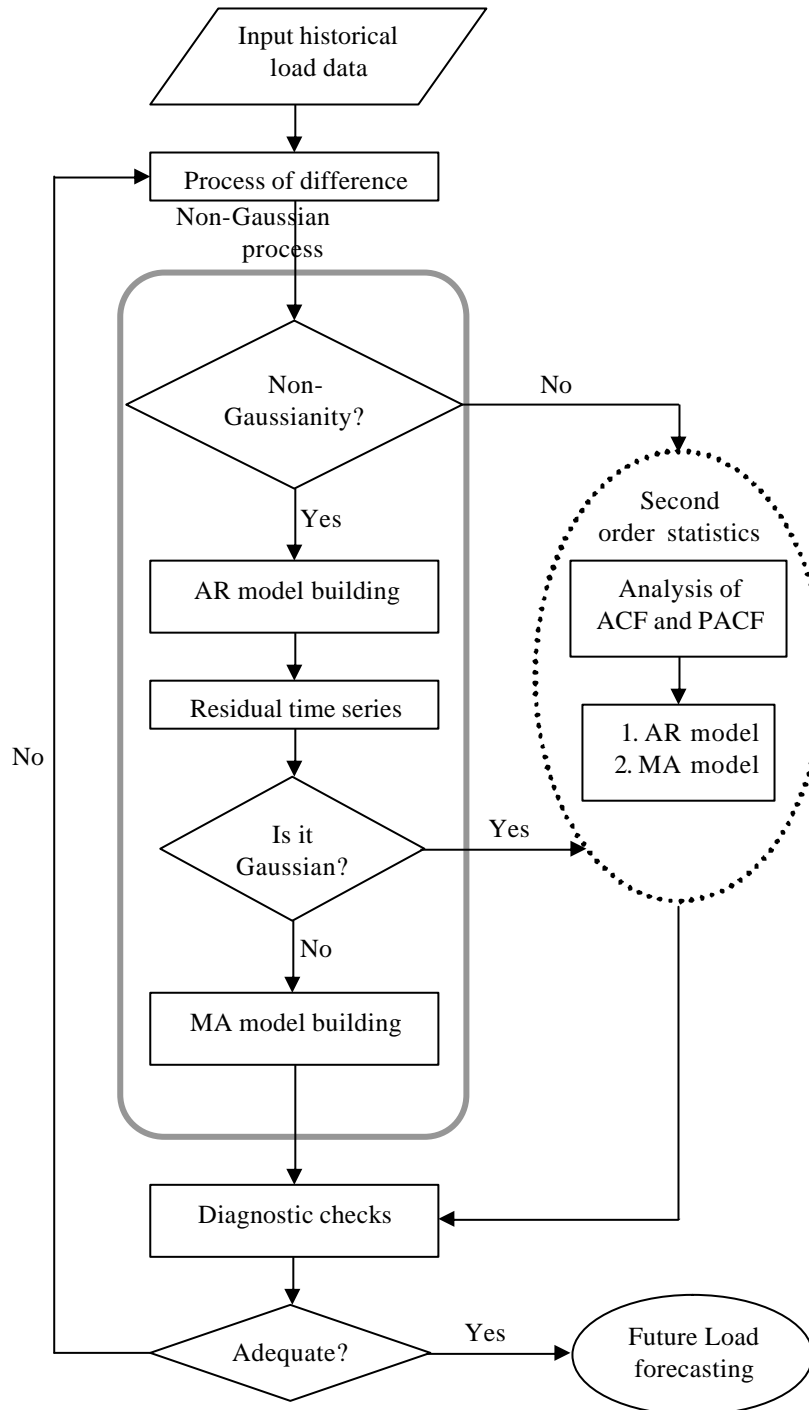


Figure 1.3 Processus de prédiction dans [42].

La méthode proposée a été comparée avec une ARMA et un Réseau de Neurones Artificiels, pour prédire la charge électrique de 24 heures en avant. L'erreur absolue moyenne (formule 1.28) est utilisée pour tester le modèle. Au premier lieu, les données sont prises aléatoirement. Ensuite, la méthode est appliquée pour chaque saison de l'année séparément. Dans tous les cas, la méthode proposée présente des erreurs de prédiction acceptable par rapport aux autres méthodes appliquées.

8.5.2. Les approches de l'Intelligence Artificielle

8.5.2.1. Les Réseaux de Neurones Artificiels

Un modèle de prédiction de la charge électrique basé sur les Réseaux de Neurones Artificiels pour une prédiction horaire d'une journée (24 heures en avant) en Grèce est donné dans [43]. Après les expérimentations avec plusieurs architectures de Réseaux de Neurones Artificiels une architecture est proposée. C'est une architecture à une seule couche cachée avec 70 neurones, 63 entrées et 24 sorties. Le tableau 1.1 présente les entrées et sorties utilisées pour cette approche. Après l'apprentissage et la validation du modèle maintenu, une erreur de prédiction annuelle moyenne de 2.61% a été trouvée.

Tableau 1.1 Les entrées et sorties du Réseau de Neurones Artificiels utilisé dans [43].

Les entrées	Description
1 – 24	$\{L(d-1, h) \quad h = 1, 24\}$
25 – 48	$\{L(d-2, h) \quad h = 1, 24\}$
49 – 52	$\{T_{\max}(d-1, W) \quad T_{\min}(d-1, W) \quad W = N, S\}$
53 – 56	$\{T_{\max}(d, W) \quad T_{\min}(d, W) \quad W = N, S\}$
57 – 63	Jours de semaine
Les sorties	Description
1 – 24	$\{L(d-1, h) \quad h = 1, 24\}$

Dans [44], un modèle régressif et un autre régressif intégré avec les Réseaux de Neurones Artificiels sont proposés, pour la prédiction de la charge électrique à Hong Kong. Les deux modèles ont, respectivement, les formules suivantes :

$$x_{t+1} = h(x_{t-1}, x_{t-2}, \dots, x_{t-24}, w_t) + e_{t+1} \quad (1.19)$$

$$\hat{x}_{t+l} = x_{t+l-d} + \hat{h}(x_{t-1}, x_{t-2}, \dots, x_{t-24}, w_t) + e_{t+l} \quad (1.20)$$

Où : x_t La consommation électrique

w_t Les informations climatiques.

e_t Un bruit à l' instant t.

l varie de 1 à 24.

La validation des méthodes utilise les deux formules suivantes :

$$s = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_t^i - \hat{x}_t^i)^2} \quad (1.21)$$

$$e = \frac{1}{N} \sum_{i=1}^N \frac{|x_t^i - \hat{x}_t^i|}{x_t^i} 100 \quad (1.22)$$

Après le calcul des erreurs obtenus par l'application des modèles pour une prédiction de 24 heures en avant, le modèle intégré présente des erreurs inférieures à celles obtenues par le modèle non intégré. Les erreurs sont en moyenne inférieures à 2%.

Dans [45], un modèle basé sur les Réseaux de Neurones Artificiels est utilisé pour la prédiction de la charge électrique en Egypte. Le modèle est constitué d'une seule couche cachée. Les entrées jugées intéressantes pour cette approche sont de l'ordre de 11, à savoir :

1. Le type du jour.
2. Le temps du jour.
3. La charge de l'heure précédente.
4. La charge du jour passé de la même heure.
5. La charge moyenne du jour passé.
6. La charge minimale du jour passé.
7. La charge pik du jour passé.
8. Les 4 dernières mesures pour la semaine passée.

La couche de sortie contient un seul neurone qui utilise une fonction d'activation linéaire. La couche cachée contient 9 neurones avec une fonction d'activation de type tangente hyperbolique. Les résultats obtenus par le modèle ont été comparés avec un modèle statistique multilinéaire régressif (MLR) pour une prédiction de 24 heures en avant.

Les données ont été divisées en 03 classes : les jours du travail, le Vendredi et le Dimanche. Ce qui peut être observé dans les résultats, est que les Réseaux de Neurones Artificiels est plus adéquat que la méthode statistique.

Une comparaison entre modèle ARIMA et un modèle basé Réseaux de Neurones Artificiels est proposée dans [46], pour la prédiction de la charge électrique en Tchèque. Les résultats sont validés par :

$$NMSE = \frac{\sum_{t=n+1}^N (x_t - \hat{x}_t)^2}{\sum_{t=n+1}^N (x_t - \bar{x})^2} = \frac{1}{\hat{s}^2} \frac{1}{N-n} \sum_{t=n+1}^N (x_t - \hat{x}_t)^2 \quad (1.23)$$

$$MAPE = \frac{1}{N-n} \sum_{t=n+1}^N \frac{|x_t - \hat{x}_t|}{x_t} \quad (1.24)$$

$$\max APE = \max_{t=n+1, \dots, N} \frac{|x_t - \hat{x}_t|}{x_t} \quad (1.25)$$

Le modèle ARIMA est de la forme :

$$(1 - \mathbf{q}_1 B^1) (1 - \mathbf{q}_2 B^{24}) (1 - \mathbf{q}_3 B^{168}) w_t = (1 - \mathbf{f}_1 B^1) (1 - \mathbf{f}_2 B^{24}) (1 - \mathbf{f}_3 B^{168}) e_t \quad (1.26)$$

L'architecture du Réseau de Neurones Artificiels utilisée est un réseau feedforward avec 15 entrées qui représentent les valeurs du passé de la charge électrique de 1 jusqu'à 6h ; 23h ; 24h ; 25h ; 48h ; 72h ; 96h ; 120h ; 144h ; 240h.

Les résultats obtenus, par l'application de ce modèle pour une prédiction de 36 heures en avant, montre la puissance du Réseau de Neurones Artificiels à partir du 24^{ième} pas en terme de prédiction.

La prédiction de la charge électrique dépend souvent des paramètres climatologiques comme la température. Un troisième modèle est proposé basé sur les Réseaux de Neurones Artificiels en gardant la même architecture et en ajoutant 3 entrées : la température d'aujourd'hui, celle d'hier et de la semaine passé (température journalière). L'utilisation de ce modèle minimise les erreurs de prédiction par rapport aux autres modèles appliqués à partir du premier pas.

8.5.2.2. Les approches mixtes

Parmi les approches de prédiction de la charge électrique. Il existe des méthodes qui combinent les Réseaux de Neurones Artificiels avec d'autres approches, pour mieux explorer le phénomène de la prédiction de la charge électrique.

Un modèle basé sur les Réseaux de Neurones Artificiels combinés avec un système expert est présenté dans [47], pour la prédiction de la charge électrique en Egypte. Le Réseau de Neurones Artificiels utilisé est un Perceptron Multi Couches avec une seule couche cachée activée par une fonction tan-sigmoïde. Il utilise la règle de retro-propagation du gradient comme règle d'apprentissage. Les entrées sont rangées comme suit :

1. Type du jour.
2. L'instant à prédire.
3. La charge prédite l'heure passée.
4. La charge du jour passé dans la même heure.
5. La charge moyenne du jour passé.
6. La charge minimale du jour passé.
7. La charge maximale du jour passé.
8. les 4 dernières entrées pour la semaine passée.

Le système expert intervient quand le système trouve une anomalie dans les résultats. Cette dernière est causée par un événement qui n'est pas programmé, comme par exemple les

fêtes religieuses. A travers les règles du système expert, le système va tenter de corriger le résultat obtenu par le Réseau de Neurones Artificiels. Les résultats obtenus par cette approche ont été comparés avec une méthode statistique multilinéaire régressive (MLR) en utilisant :

$$\% \text{erreurs}(n) = \frac{\text{Forecasted load}(n) - \text{Actual load}(n)}{\text{Actual load}(n)} \quad (1.27)$$

$$S.D. = \sum_{n=1}^N \frac{\% \text{erreurs}(n) - M}{N} \quad (1.28)$$

Le modèle utilise trois (03) classes de données : les jours du travail, le Vendredi et le Dimanche. L'approche a présenté des bons résultats en arrivant à 2.63% comme erreur de prédiction contre 4.69% pour l'approche statistique.

Dans [48], le même modèle que [47] est proposé, pour la prédiction de la charge électrique en Taiwan. Le Réseau de Neurones Artificiels utilisé contient une seule couche cachée avec deux entrées, une pour la charge au temps $(t - 1)$ et l'autre contient le résultat obtenu par le système expert concernant la charge prédite à l'instant t . La méthode est appliquée pour prédire 06 heures en avant. Elle est comparée avec 02 approches : un Système Expert et un Réseau de Neurones Artificiels. Elle présente des erreurs acceptables par rapport à ces deux techniques.

Dans [49], une méthode basée sur les Réseaux de Neurones Artificiels combinés avec les algorithmes génétiques, pour la prédiction de la charge électrique en Taiwan est proposée. Les Algorithmes Génétiques sont utilisés pour choisir parmi leurs générations établies, ceux qui sont les mieux pour initialiser les poids du Réseau de Neurones Artificiels utilisés dans l'apprentissage. Le tableau 1.2 présente les paramètres de l'architecture adaptée pour cette approche. En appliquant l'approche pour une prédiction en 24 heures en avant, une erreur moyenne de 1.83% est atteinte.

Tableau 1.2 Les paramètres des approches utilisées pour la prédiction en Taiwan.

Algorithme Génétique		Perceptron Multicouches	
Taille de la population	100	Neurones en entrée	12
Nombre de générations	5	Neurones en Sortie	1
Taux de Crossover	0.8	Neurones en couche cachée	5
Taux de mutation	0.001	Taux d'apprentissage	0.4

Dans [50], une approche Réseaux de Neurones Artificiels pour la prédiction de la charge électrique, est proposée. Les algorithmes génétiques sont utilisés pour mieux raffiner les résultats obtenus par le Réseau de Neurones Artificiels. Le meilleur réseau obtenu possède une architecture avec une seule couche cachée, trois entrées qui sont la température de l'heure du jour à prédire, la moyenne horaire de la charge des valeurs des trois semaines du même jour et la moyenne de la charge de l'heure précédente des valeurs des trois dernières semaines. Les résultats du modèle obtenus sont comparés avec une méthode statistique par l'erreur du pourcentage absolue moyenne (MAPE) donnée par la formule (1.29). La comparaison démontre l'efficacité de l'approche présentée.

$$MAPE = \frac{1}{N} \left(\sum_{t=1}^N \left[\left| \frac{actual_t - forecast_t}{actual_t} \right| \times 100\% \right] \right) \quad (1.29)$$

Dans [51], une hybridation entre les Réseaux de Neurones Artificiels et les Algorithmes Génétiques est présentée, pour la prédiction en 24 pas en avant de la charge électrique à Ontario. Le Réseau de Neurones Artificiels utilisé est un Feedforward avec une seule couche cachée qui a une fonction d'activation de type Sigmoidale. Les Algorithmes Génétiques sont utilisés dans le but d'une optimisation ; c'est-à-dire choisir la meilleure architecture réseau. L'idée de l'approche est de ressortir les similarités entre les heures à prédire. Pour évaluer la méthode un MAPE (Formule (1.30)) est utilisée. La technique a présenté des résultats acceptables durant la simulation qui atteint 1.8%.

$$MAPE = \frac{1}{24N_p} \sum_{t=t_0}^{t_0+N_p-1} \sum_{i=1}^{24} \frac{|L_t^i - \hat{L}_t^i|}{L_t^i} \times 100\% \quad (1.30)$$

Dans [52], un modèle pour la prédiction de la charge électrique est proposé. Il est basé sur les Réseaux de Neurones Artificiels avec une seule couche cachée qui utilise les Ondelettes comme fonction de transfert. Deux fonctions d'Ondelette sont utilisées, celle de Mexican Hat et l'autre de Morlet. Elles sont données respectivement par les deux formules suivantes :

$$y(X) = \left(\frac{2}{\sqrt{3}} p^{-1/4} \right) (1 - X^2) e^{-x^2/2} \quad (1.31)$$

$$y(X) = C e^{-x^2/2} \cos(5x) \quad (1.32)$$

L'utilisation des Ondelettes avec les Réseaux de Neurones Artificiels a marqué une amélioration dans les résultats et dans le temps d'apprentissage par rapport aux autres techniques utilisées.

Dans [53], un modèle pour prédire 24 heures en avant de la charge électrique est proposé. Il est basé sur les Réseaux de Neurones Artificiels et les Ondelettes. En premier lieu, une transformation avec les Ondelettes se fait sur les données. Deux classes sont obtenues : une approximation à prédire et une déviation à calculer. La prédiction se fait à l'aide d'un Réseau de Neurones RBF et la déviation est calculée avec la formule (1.33). A la fin, une sommation des deux valeurs obtenues se fait.

$$D(i) = \sum_{k=1}^n b_k \cdot \frac{D(k,i)}{n} \quad (1.33)$$

Où : $D(i)$ Détail du $i^{\text{ème}}$ temps pour le jour à prédire.

$D(k, i)$ Détail du $i^{\text{ème}}$ temps pour le $k^{\text{ème}}$ jour.

b_k Poids du $k^{\text{ème}}$ jour. $\sum_{k=1}^n b_k = 1$

Les données sont partagées en deux : les données de l'été et celles de l'hiver, Les résultats obtenus par le calcul de l'erreur du pourcentage absolue (formule (1.28)) sont acceptables pour les deux classes de données.

Dans [54], un modèle Ondelette combiné avec les Réseaux de Neurones Artificiels est proposé. Au début, une analyse sur la charge électrique est effectuée. Elle sera décomposée en quatre classes (Algorithme de Mallat). Ensuite, pour chaque classe on applique un Réseau de Neurones Artificiels. Un pour chaque heure afin d'avoir les 24 heures en avant de prédiction. Pour évaluer le modèle, les erreurs suivantes sont utilisées :

$$E(i) = \left(\sum_{t=1}^{24} \left| \frac{\bar{y}(i,t) - y(i,t)}{y(i,t)} \right| \right) / 24 \times 100 \quad (\%) \quad (1.34)$$

$$E_p(i) = \left| \frac{\bar{y}(i)_p - y(i)_p}{y(i)_p} \right| \times 100 \quad (\%) \quad (1.35)$$

L'approche est comparée avec un Réseau de Neurones Artificiels. Les résultats sont acceptables en arrivant à une erreur de 2.17% pour la méthode hybridé contre 4.66 pour le Réseau de Neurones Artificiels.

Dans [55], une approche Réseaux de Neurones Artificiels combinée avec la Logique Floue pour prédire la charge électrique en Wishita-Kensas est proposée. La logique floue est utilisée pour déterminer la relation entre la charge électrique et les variables climatologiques sous forme de règles floues pour mieux raffiner le résultat obtenu par le Réseau de Neurones Artificiels. Ce dernier est un ensemble de 12 réseaux, un pour chaque mois. Chacun contient 63 entrées avec une seule couche cachée qui utilise la règle de propagation de gradient comme règle d'apprentissage et la fonction sigmoïde comme règle d'activation. Les résultats obtenus en appliquant le modèle sont comparés avec d'autres approches, l'erreur de pourcentage absolu moyen (formule (1.29)) et la déviation standard (formule (1.28)) sont utilisées pour l'évaluation. Les résultats obtenus sont acceptables.

Dans [56], une comparaison entre quatre approches de prédictions de charge électrique en Grèce est réalisée ; un régresseur qui utilise un passé court, un autre avec un passé long, un Réseau de Neurones Artificiels et une nouvelle approche qui se base sur le principe de combinaison bayésienne entre les trois types mentionnés avant. Le régresseur passé court

utilise un passé de $(24 \times M+2 \times N)$ entrées où M est le nombre de valeurs passées de la charge électrique (en 24 heures) et N le nombre de valeurs de la température passée (maximale et minimale). Pour le régresseur passé long, 24 prédicteurs sont utilisées pour chaque heure. Le nombre d'entrées est de $(M+N)$ où M est le nombre de valeurs passées de la charge et N le nombre de valeurs de la température.

Le Réseau de Neurones Artificiels utilisé est un MLP avec 57 entrées et 24 sorties pour les 24 heures à prédire et une seule couche cachée. Les entrées sont la valeur horaire de la charge électrique pour les deux jours d'avant, la température maximale et minimale du jour d'avant et les sept dernières entrées sont le type du jour (en binaire).

Le combinateur bayésien utilise les formules suivantes, pour prédire la charge électrique :

$$y_t = y_t^k (y_{t-1}, y_{t-2}, \dots, y_1) + e_t^k \quad , \quad k=1, 2, 3 \quad (1.36)$$

Où: y_t La charge électrique.

y_t^k La prédiction.

e_t^k L'erreur de prédiction.

$$p_t^k = \frac{\frac{1}{\sqrt{2\pi s}} p_{t-1}^k e^{-\frac{(y_t - y_t^k)^2}{s}}}{\sum_{m=1}^3 \frac{1}{\sqrt{2\pi s}} p_{t-1}^m e^{-\frac{(y_t - y_t^m)^2}{s}}} \quad (1.37)$$

$$y_t^* = p_t^1 y_t^1 + p_t^2 y_t^2 + p_t^3 y_t^3 z \quad (1.38)$$

Pour une prédiction de 24 heures en avant, l'approche passé court présente des résultats acceptables pour les premiers pas. A partir du 09^{ieme} pas, l'approche passé long présente des erreurs inférieures à celles obtenu par l'approche précédente. Les Réseau de Neurones présente des résultats rapprochés. La nouvelle méthode proposée présente des résultats ambitieux en arrivant à 2.07% d'erreur en moyenne.

Une approche Réseau de Neurones Artificiels est proposée dans [57], pour la prédiction de la charge électrique en Chine. Une optimisation au niveau des entrées et au niveau de l'apprentissage est ajoutée. Un prétraitement est effectué en premier lieu. Ce dernier consiste à étudier tous les facteurs qui influent sur la charge électrique (49 facteurs après les expérimentations sont trouvés). En second lieu une analyse en composante principale est effectuée pour réduire ce nombre. Le résultat obtenu pour l'analyse sera utilisé pour faire l'apprentissage du réseau de neurones avec l'utilisation de la méthode ACO (Ant Colony Optimization) pour l'optimisation de l'apprentissage au niveau de la convergence et du minimum local. Cette méthode est comparée avec deux modèles ; le premier est le modèle proposé mais sans optimisation au niveau de l'apprentissage et le deuxième est un réseau de neurone sans prétraitement et sans optimisation au niveau de l'apprentissage. La méthode proposée présente des erreurs plus intéressantes par rapport aux autres méthodes.

9. CONCLUSION

Les séries temporelles regroupent tout ce qui est chiffrable et varie dans le temps. Elles ont été utilisées dans plusieurs applications industrielles, vu leur large utilisation. La charge électrique est l'un des domaines qui a profité des avantages de l'analyse des séries temporelles. Une prédiction précise de cette ressource est un souci majeur pour toute application industrielle énergétique. Pour cette raison, deux grands axes de recherches se sont développés : l'utilisation des méthodes statistiques, basées sur l'approche de Box-Jenkins et les techniques de l'Intelligence Artificielle avec les Réseaux de Neurones Artificiels qui s'imposent comme les approches les plus utilisées.

Chapitre 2 : La modélisation linéaire: la méthode Box-Jenkins

- 1. Introduction*
- 2. Quelques modèles connus*
- 3. La modélisation avec la méthode Box-Jenkins*
- 4. Conclusion*

Chapitre 2 : La modélisation linéaire : la méthode Box-Jenkins

1. INTRODUCTION

On appelle processus linéaire toute série temporelle qui peut être représentée par un modèle linéaire après transformation, par exemple $\log(y_t) = \mathbf{a} + \mathbf{b}t + \mathbf{e}_t$. Il est toujours surprenant de constater la simplicité de la plupart des modèles linéaires quand on pense à la complexité des modèles dans d'autres disciplines en physique par exemple. En réalité, un modèle linéaire est une approximation des modèles complexes. Il a la particularité d'être très flexible et estimable avec un faible nombre d'observations [06].

La modélisation d'un processus n'est pas unifiée même si elle repose la plupart du temps sur la méthodologie de Box-Jenkins et le recours aux processus (S)ARIMA (AutoRégressif Moyenne Mobile Intégré avec composante Saisonnière). Il existe deux catégories de modèles pour interpréter une série temporelle. La première considère que les

données sont une fonction du temps ($y = f(t)$) ; les approches de cette catégorie sont constituées par l'analyse spectrale directement importée de la physique : on décompose un processus X_t en composantes périodiques en adoptant le critère de fréquences. Les approches de l'autre catégorie cherchent à déterminer chaque valeur de la série en fonction des valeurs qui la précèdent ($y_t = f(y_{t-1}, y_{t-2}, \dots)$). Dans ce cas, on fait appel à l'analyse temporelle proprement dite qui consiste à étudier directement les corrélations entre X_t et les valeurs passées de X . Le premier type de modélisation est particulièrement pratique pour la description des différentes composantes d'un processus. Il peut être donné sous la forme suivante [58] :

$$X_t = m_t + s_t + u_t \quad (2.1)$$

Où : m_t est la tendance (évolution à long terme)

s_t est la composante saisonnière (purement périodique, évolution à court ou moyen terme)

u_t est la composante conjoncturelle (résultat de perturbations, c'est la partie purement aléatoire du processus).

On peut envisager d'autres combinaisons des composantes que la forme précédente additive (multiplicative, mixte...). Cette modélisation nécessite d'avoir identifié au préalable les différentes composantes.

La seconde catégorie de modélisation fait appel aux processus de Box-Jenkins qui sera présenté en détail dans les paragraphes suivants. Il fait partie d'une classe plus générale de modèles dite "autoprojective" qui est de la forme [59] :

$$X_t = f(X_{t-1}, f(X_{t-2}, \dots, g(u_t)) \quad (2.2)$$

2. QUELQUES MODELES CONNUS

2.1. Le modèle Auto-Régressif (AR)

Les modèles auto-régressifs supposent que y_t est une fonction linéaire des valeurs précédentes (équation 2.3) [60].

$$Y_t = \mathbf{m} + \mathbf{f}_1 Y_{t-1} + \mathbf{f}_2 Y_{t-2} + \mathbf{f}_3 Y_{t-3} + \mathbf{e}_t \quad (2.3)$$

Littérairement, chaque observation est constituée d'une composante aléatoire (choc aléatoire, \mathbf{e}) et d'une combinaison linéaire des observations précédentes. Les constantes \mathbf{f}_1 , \mathbf{f}_2 et \mathbf{f}_3 dans l'équation (2.3) sont les coefficients d'auto-régression. Il faut noter que cette équation porte soit sur des données brutes, soit sur des données différenciées si une différenciation est nécessaire.

Remarque : les deux notions d'opérateur de retard et de différenciation seront expliquées dans les points suivants.

Processus autorégressif d'ordre 1 (AR(1)) : On dit que $\{Y_t\}$ est un processus autorégressif d'ordre 1 s'il obéit à l'équation suivante [4] :

$$Y_t = \mathbf{m} + \mathbf{f}_1 Y_{t-1} + \mathbf{e}_t \quad (2.4)$$

Si une différenciation a été faite, on aura:

$$Y_t - Y_{t-1} = \mathbf{m} + \mathbf{f}_1 (Y_{t-1} - Y_{t-2}) + \mathbf{e}_t \quad (2.5)$$

Processus autorégressif d'ordre p AR(p) : Une extension immédiate du modèle AR(1) est le modèle AR(p). Un processus $\{Y_t\}$ est dit autorégressif d'ordre p s'il s'écrit sous [4] :

$$Y_t = \mathbf{m} + \mathbf{f}_1 Y_{t-1} + \mathbf{f}_2 Y_{t-2} + \dots + \mathbf{f}_p Y_{t-p} + \mathbf{e}_t \quad (2.6)$$

Avec l'opérateur retard on peut écrire cette autorégression d'ordre p comme suit :

$$(1 - \mathbf{f}_1 B - \mathbf{f}_2 B^2 - \dots - \mathbf{f}_p B^p) Y_t = \mathbf{m} + \mathbf{e}_t \quad (2.7)$$

$$\Phi(B) Y_t = \mathbf{m} + \mathbf{e}_t \quad (2.8)$$

2.2. Le modèle Moyenne Mobile

Les modèles à moyenne mobile suggèrent que la série présente des fluctuations autour d'une valeur moyenne. On considère alors que la meilleure estimation est représentée par la moyenne pondérée d'un certain nombre de valeurs antérieures. Ceci revient en fait à considérer que l'estimation est égale à la moyenne vraie, à laquelle on rajoute la somme pondérée des erreurs ayant entaché les valeurs précédentes (équation 2.9) [60].

$$Y_t = m + e_t - q_1 e_{t-1} - q_2 e_{t-2} - q_3 e_{t-3} \quad (2.9)$$

Littérairement, chaque observation est composée d'une composante d'erreur aléatoire (choc aléatoire, e) et d'une combinaison linéaire des erreurs aléatoires passées. Les constantes q_1 , q_2 et q_3 sont les coefficients de moyenne mobile du modèle. Comme précédemment cette équation porte soit sur des données brutes, soit sur des données différenciées si une différenciation est nécessaire.

Processus moyenne mobile d'ordre 1 MA(1) : On dit que $\{Y_t\}$ est un processus moyenne mobile d'ordre 1, s'il obéit à l'équation [4] :

$$Y_t = m + e_t - q_1 e_{t-1} \quad (2.10)$$

Si une différentiation a été faite, on aura :

$$Y_t - Y_{t-1} = m + e_t - q_1 e_{t-1} \quad (2.11)$$

Processus moyenne mobile d'ordre q MA(q) : Un processus $\{Y_t\}$ est dit processus moyenne mobile d'ordre q si [4] :

$$Y_t = m + e_t - q_1 e_{t-1} - q_2 e_{t-2} - \dots - q_q e_{t-q} \quad (2.12)$$

On peut noter la formule (2.12), de façon équivalente, en utilisant l'opérateur de retard :

$$Y_t = m + (1 - q_1 B - q_2 B^2 - \dots - q_q B^q) e_t \quad (2.13)$$

$$Y_t = m + q(B) e_t \quad (2.14)$$

2.3. Processus ARMA (p, q)

La notion de processus ARMA réunit celles de "processus autorégressif" et de "processus moyenne mobile". Dans les modèles ARMA, la valeur prise au temps t par la variable étudiée est une fonction linéaire de ses valeurs passées et des valeurs actuelles et passées de l'erreur qui suit un bruit blanc.

La forme générale d'un modèle ARMA (p, q) se présente de la façon suivante :

$$Y_t - f_1 Y_{t-1} - f_2 Y_{t-2} - \dots - f_p Y_{t-p} = e_t - q_1 e_{t-1} - \dots - q_q e_{t-q} \quad (2.15)$$

Le processus ARMA (p, q) peut être représenté aussi, en utilisant l'opérateur de retard, par la forme suivante [1] :

$$\Phi_p(B) Y_t = q_q(B) e_t \quad (2.16)$$

Où B l'opérateur de retard.

$\Phi_p(B)$ le polynôme $1 - f_1 B - f_2 B^2 - \dots - f_p B^p$

$q_q(B)$ le polynôme $1 - q_1 B - q_2 B^2 - \dots - q_q B^q$

3. LA MODELISATION AVEC LA METHODE BOX-JENKINS

3.1. Introduction

Box et Jenkins (1970) ont créé les bases de l'analyse classique des séries temporelles. Leurs techniques ont été employées dans plusieurs applications de prédiction de la charge électrique. Elles sont souvent employées comme ligne de base pour la comparaison avec d'autres techniques [20].

La technique de Box-Jenkins essaye d'interpréter une série temporelle en fonction de ses entrées précédentes, des erreurs du rendement passé et des entrées externes. Cependant, la série temporelle à prévoir doit être stationnaire. Une série chronologique stationnaire est une série pour laquelle les propriétés statistiques sont invariables à n'importe quel endroit de la série [61].

La forme générale du modèle de Box-Jenkins est connue sous une fonction de transfert. Elle peut être exprimée en fonction des valeurs précédentes de la série chronologique, des entrées externes et des erreurs précédentes comme le montre l'équation (2.17) [62] :

$$A(q)x(k) = \frac{B(q)}{F(q)}u(k-t) + \frac{C(q)}{D(q)}e(k) \quad (2.17)$$

Où $x(k)$ est la série chronologique stationnaire à modéliser au temps k

$u(k)$ est une entrée externe avec le retard t entre l'entrée et $x(k)$,

$e(k)$ est l'erreur dans le modèle au temps k

A, B, F, C, D sont des polynômes en fonction du retard q tels que, par exemple, A peut être développé comme suit:

$$A(q)x(k) = (1 - a_1q^{-1} - a_2q^{-2} - \dots - a_{na}q^{-na})x(k) \quad (2.18)$$

où $a_1..a_{na}$ sont les coefficients du polynôme et na son ordre. B, F, C et D peuvent être développés de la même façon avec respectivement les coefficients $b_1..b_{nb}, f_1..f_{nf}, c_1..c_{nc}, d_1..d_{nd}$ et les ordres nb, nf, nc, nd .

Les autres modèles proposés par Box et Jenkins peuvent être dérivés directement de l'équation (2.17) en remplaçant les polynômes F et D par 1, comme le montre le tableau 21 [20].

En outre, si la série stationnaire, qui est sensée être prédite, a été produite en utilisant une technique de stationnarité sur la série originale, le modèle s'appellera un modèle intégré et la lettre 'I' sera ajoutée au nom du modèle. Par exemple, un modèle ARMAX devient un modèle ARIMAX et un modèle AR devient un modèle ARI, etc.

Tableau 2.1 Les différents modèles de Box-Jenkins.

Nom du modèle	A	B	C
AR (Auto Regressive)	$1 - a_1 q^{-1} \dots - a_{na} q^{-na}$	0	1
ARX (AR eXogeneous)	$1 - a_1 q^{-1} \dots - a_{na} q^{-na}$	$b_1 + b_2 q^{-1} \dots + a_{nb} q^{-nb+1}$	1
MA (Moving Average)	1	0	$1 + c_1 q^{-1} \dots + c_{nc} q^{-nc}$
MAX (MA eXogeneous)	1	$b_1 + b_2 q^{-1} \dots + a_{nb} q^{-nb+1}$	$1 + c_1 q^{-1} \dots + c_{nc} q^{-nc}$
ARMA (AR - MA)	$1 - a_1 q^{-1} \dots - a_{na} q^{-na}$	0	$1 + c_1 q^{-1} \dots + c_{nc} q^{-nc}$
ARMAX (ARMA eXogeneous)	$1 - a_1 q^{-1} \dots - a_{na} q^{-na}$	$b_1 + b_2 q^{-1} \dots + a_{nb} q^{-nb+1}$	$1 + c_1 q^{-1} \dots + c_{nc} q^{-nc}$

3.2. Algorithme de Box-Jenkins

L'algorithme de Box-Jenkins vise à formuler un modèle permettant de représenter une série. Son idée principale est le concept de parcimonie, ou de la minimisation du nombre de paramètres. En pratique, ces derniers étant inconnus, ils sont donc remplacés par leurs valeurs estimées : plus il y a de paramètres, plus nombreuses sont les chances de se tromper. Il s'agit de procéder en quatre étapes [63] :

1. Transformer les données de manière à ce que l'hypothèse de stationnarité faible soit raisonnable.
2. Etablir une hypothèse initiale concernant les ordres des polynômes du modèle.
3. Estimer les paramètres du modèle.
4. Etablir une analyse de diagnostic qui confirme que le modèle est valable, sinon revenir à l'étape 2.

3.2.1. Stationnariser une série

L'estimation du modèle Box-Jenkins suppose qu'on travaille sur une série stationnaire. Ceci signifie que la moyenne de la série doit être constante dans le temps, ainsi que sa variance. N'importe quelle série chronologique linéaire peut être transformée en série chronologique stationnaire. La correction d'une non-stationnarité en terme de variance peut être réalisée par des transformations de type logarithmique, si la variance croît avec le temps. Dans le cas contraire, des transformations exponentielles seront faites. Cette correction doit être réalisée avant n'importe quelles transformations [03].

Pour rendre une série stationnaire, beaucoup de techniques de transformation existent, on présente dans ce qui suit les plus utilisées :

Opérateur de retard : Soit $\{y_t\}$ un processus. On définit l'opérateur de retard L (ou B) par [06] :

$$Ly_t = y_{t-1} \quad (2.19)$$

$$L^j y_t = y_{t-j} \text{ pour tout } j \in \mathbb{N} \quad (2.20)$$

On peut utiliser l'opérateur L comme un chiffre, il peut être multiplié ou divisé.

$$\text{Si } Ly_t = y_{t-1} \text{ alors } y_t = L^{-1} y_{t-1} .$$

On peut ainsi écrire un polynôme à l'aide de l'opérateur retard comme suit :

$$\sum_{k=0}^p a_k X_{t-k} = \left(\sum_{k=0}^p a_k L^k \right) X_t \quad (2.21)$$

Opérateur de différence : La meilleure méthode pour éliminer toute tendance est de différencier, c'est-à-dire de remplacer la série originale par la série des différences adjacentes. Une série temporelle qui a besoin d'être différenciée pour atteindre la stationnarité est considérée comme une version intégrée d'une série stationnaire [60].

Une différenciation d'ordre 1 suppose que la différence entre deux valeurs successives de y est constante. On aura alors :

$$Y_t - Y_{t-1} = \mathbf{m} + \mathbf{e}_t \quad (2.22)$$

Dans la formule (2.22), \mathbf{m} est la constante du modèle. Elle représente la différence moyenne en y. Elle peut être représentée comme un accroissement linéaire en fonction du temps. Si μ est égale à 0, la série est stationnaire [59].

Les différenciations d'ordre 2 travaillent non plus sur les différences brutes, mais sur les différences des différences. La seconde différence de y au moment t est égale à la différence entre $(y_t - y_{t-1})$ et $(y_{t-1} - y_{t-2})$, c'est-à-dire à $y_t - 2y_{t-1} + y_{t-2}$.

On obtient donc :

$$Y_t - 2Y_{t-1} + Y_{t-2} = m + e_t \quad (2.23)$$

Détermination de l'ordre de différenciation : Pour atteindre la stationnarité d'une série, on est forcé de différencier à plusieurs reprises. Les fonctions des autocorrélations simples et partielles sont le moyen pour déterminer l'ordre de différenciation [64].

Pour prouver les changements effectués sur une série temporelle, afin de la rendre stationnaire, plusieurs points doivent être observés [60] :

- Une série temporelle stationnaire fluctue autour d'une valeur moyenne et sa fonction d'autocorrélation décline rapidement vers zéro.
- Si une série temporelle présente des auto-corrélations positives pour un grand nombre de décalages (par exemple 10 ou plus), elle nécessite alors d'être différenciée.
- La différenciation tend à introduire des auto-corrélations négatives.
- Si l'auto-corrélation de décalage 1 est négative ou égale à 0, la série n'a pas besoin d'être différenciée.
- Si l'auto-corrélation de décalage 1 est inférieure à -0.5 , la série est surdifférenciée.
- L'ordre optimal de différenciation est souvent celui pour lequel l'écart-type est minimal. Un accroissement de l'écart-type doit donc être considéré comme un symptôme de surdifférenciation.
- Un troisième symptôme de sur-différenciation est le changement systématique de signe d'une observation à l'autre.

Un modèle sans différenciation suppose que la série originale est stationnaire. Un modèle avec une différenciation d'ordre 1 suppose que la série originale présente une tendance constante. Un modèle avec une différenciation d'ordre 2 suppose que la série originale présente une tendance variante dans le temps.

La différenciation dont on a parlé est dite non-saisonnnière, dans le sens où elle porte sur des données adjacentes. Une différenciation saisonnière peut être nécessaire pour rendre compte des variations systématiques, circadiennes, hebdomadaires, mensuelles ou annuelles.

Cette notion de temps est considérée comme le degré de saisonnalité. La différenciation l'utilise pour supprimer la tendance saisonnière. Dans ce cas, on réalise une différenciation de chaque valeur de la série temporelle par la valeur passée qui correspond à la saisonnalité [65].

3.2.2. Identification du modèle

Après avoir stationnarisée la série, l'étape suivante consiste à identifier les termes AR et MA nécessaires pour corriger les auto-corrélations résiduelles. Cette analyse est basée sur l'examen des fonctions d'auto-corrélation simple ACF et d'auto-corrélation partielle $PACF$. Rappelons que l'autocorrélation est la corrélation des valeurs d'une série entre elles, selon un décalage (lag) défini [64].

Etablir une hypothèse : Il est essentiel d'établir une hypothèse maximale du nombre de coefficients à utiliser, c'est-à-dire, les valeurs p_{\max} et q_{\max} . Pour ce faire, on utilise les propriétés suivantes :

$$MA(q) : p_j = 0 \text{ si } j > q$$

$$AR(p) : p_j \text{ tend graduellement vers } 0$$

Et

$$AR(p) : a_j = 0 \text{ si } j > p$$

$$MA(q) : a_j \text{ tend graduellement vers } 0$$

Ainsi pour un $AR(p)$ pur, on observe un seuil de PACF pour $j \leq p$, a_j est non nul et il devient nul pour $j > p$. Pour un $MA(q)$ pur, le comportement est le même, mais cette fois-ci en utilisant ACF et q comme valeur de coupure [66].

3.2.3. Estimation des modèles dynamiques

Après avoir établi une théorie sur les ordres des polynômes, il nous reste à estimer les coefficients de ces polynômes. En l'absence de composante MA (i.e. $q = 0$ dans $ARMA(p, q)$) la méthode à utiliser correspond aux moindres carrés ordinaires ou résolution des équations de Yule-Walker (formule 2.24) en remplaçant les autocorrélations théoriques par leurs estimateurs [06].

$$\left. \begin{aligned}
 \mathbf{r}_1 &= \mathbf{a}_1 + \mathbf{a}_2 \mathbf{r}_1 + \dots + \mathbf{a}_p \mathbf{r}_{p-1} \\
 \mathbf{r}_2 &= \mathbf{a}_1 \mathbf{r}_1 + \mathbf{a}_2 + \dots + \mathbf{a}_p \mathbf{r}_{p-2} \\
 &\cdot \\
 &\cdot \\
 &\cdot \\
 &\cdot \\
 \mathbf{r}_p &= \mathbf{a}_1 \mathbf{r}_{p-1} + \mathbf{a}_2 \mathbf{r}_{p-2} + \dots + \mathbf{a}_p
 \end{aligned} \right\} \Rightarrow \mathbf{r}_1, \dots, \mathbf{r}_p, \quad (2.24)$$

Pour $k > p$,

$$\mathbf{r}_k = \mathbf{a}_1 \mathbf{r}_{k-1} + \mathbf{a}_2 \mathbf{r}_{k-2} + \dots + \mathbf{a}_p \mathbf{r}_{k-p},$$

En revanche, si $q \neq 0$, il est nécessaire de recourir à la méthode du maximum de vraisemblance (exact ou conditionnel). Cette méthode part de l'hypothèse que l'échantillon Y_t (y_0, \dots, y_t) observé suit une distribution dont les paramètres sont à estimer. Il faut donc supposer que la distribution est connue (de fonction de densité $f(\cdot)$), seuls ses paramètres ne le sont pas. Il est alors possible d'écrire que, pour \mathbf{q} donné, la probabilité d'observer l'échantillon Y_t est donnée par [67] :

$$P(Y_t) = f(Y_t, \mathbf{q}) \quad (2.25)$$

Ainsi la probabilité d'observer Y_t dépend des paramètres \mathbf{q} . Le principe de la méthode est de rechercher le \mathbf{q} qui fournit la probabilité maximale d'observer Y_t . On définit alors la fonction de vraisemblance, qui est une fonction qui dépend de l'échantillon observé et dont le seul paramètre est \mathbf{q} , on la note :

$$L(\mathbf{q}) = f(Y_t, \mathbf{q}) \quad (2.26)$$

Il s'agit alors simplement de rechercher le \mathbf{q} qui maximise $L(\cdot)$ et on obtient l'estimateur [68] :

$$\hat{\mathbf{q}} = \arg \max_{\mathbf{q}} L(\mathbf{q}) \quad (2.27)$$

3.2.4. Evaluation du modèle :

L'objectif de la modélisation est de déterminer combien de paramètres auto-régressifs (p) et moyennes mobiles (q) sont nécessaires pour obtenir un modèle effectif et parcimonieux du processus. Un indicateur simple et courant pour mesurer la fiabilité du modèle est de comparer la précision des estimations basées sur des données partielles, afin que les prévisions puissent être comparées avec les dernières observations connues de la série (initiale).

Toutefois, un bon modèle ne doit pas seulement produire des prévisions suffisamment précises, il doit également être parcimonieux et produire des résidus statistiquement indépendants, ne contenant que du bruit, sans aucune composante régulière (par exemple, le corrélogramme des résidus ne doit pas révéler d'autocorrélations). Un bon test du modèle consiste :

- (a) à tracer les résidus et à les examiner pour voir s'il existe des tendances systématiques.
- (b) à étudier l'autocorrélogramme des résidus (il ne doit pas y avoir d'autocorrélations entre les résidus).

Ce que l'on cherche à savoir est, si les résidus ne sont pas distribués de façon systématique dans la série (par exemple, systématiquement négatifs dans une première partie de la série puis proches de zéro dans une seconde) ou s'ils ne sont pas autocorrélés ce qui tendrait à montrer que le modèle est inadéquat. L'analyse des résidus d'un modèle Box-Jenkins constitue un test important pour le valider. La procédure d'estimation postule que les résidus ne sont pas (auto-) corrélés et qu'ils sont distribués normalement [66].

L'erreur carrée moyenne de prévision décroît monotoniquement à mesure si les ordres du modèle augmentent, pour l'échantillon utilisé dans l'estimation. Cependant en dehors de l'échantillon, elle ne l'est pas. Elle accroîtra quand la complexité du modèle dépasse celle du processus produisant la série temporelle. Plusieurs critères existent pour pénaliser la complexité d'un modèle relativement aux erreurs produites par le modèle. Le critère d'information d'Akaike (AIC) donné par la formule (2.28), est le plus utilisé dans ces

approches. Parmi plusieurs modèles obtenus, celui qui minimise le plus ce critère sera retenu [69-71].

$$AIC = \frac{1}{N} \sum_{k=1}^N (\mathbf{e}(k))^2 \left(1 + \frac{2np}{N} \right) \quad (2.28)$$

Où N est la taille des données utilisées.

$\mathbf{e}(k)$ est l'erreur de prévision pour le point k

np est la somme des ordres du modèle.

4. CONCLUSION

Modéliser un processus est une tâche importante dans les procédés industriels. La modélisation linéaire est la plus répandue dans ce milieu. Pour cette modélisation, on fait référence dans la plus part du temps à la modélisation Box-Jenkins. C'est une approche robuste dans ce domaine ce qui lui a permis de devenir une base de comparaison avec les autres modèles de modélisation.

Dans ce chapitre, on a présenté quelques notions liées à la modélisation linéaire, à savoir quelques processus classiques ainsi que l'algorithme complet de la modélisation Box-Jenkins.

Chapitre 3 : Les Réseaux de Neurones Artificiels

- 1. Introduction*
- 2. Historique*
- 3. Neurone biologique*
- 4. Neurone formel*
- 5. Apprentissage*
- 6. Les réseaux de neurones*
- 7. Avantages et limites*
- 8. Applications*
- 9. Conclusion*

Chapitre 3 : Les Réseaux de Neurones Artificiels

1. INTRODUCTION

Comment l'être humain fait-il pour raisonner, parler, calculer, apprendre, etc.?
Comment s'y prendre pour créer de l'intelligence artificielle ? Deux types d'approches ont été
essentiellement explorés :

- L'objectif essentiel de la première approche est l'étude des activités mentales, c'est-à-dire le stockage (mémorisation), la récupération et l'utilisation de l'information ou des connaissances. Cette approche est basée sur l'étude de la mémoire et de la perception [72]. C'est une discipline qui cherche à étudier logiquement les tâches relevant de la cognition humaine et leur traitement par les êtres humains et tenter de les reconstituer par des programmes à simuler pour des ordinateurs. C'est cette approche qui a été privilégiée par l'Intelligence Artificielle et la psychologie cognitive classique. Cette démarche est connue sous le nom de *cognitivism* [73].
- La deuxième approche se base sur l'étude de l'organe responsable d'un traitement donné qui est le « *neurone biologique* ». Cette approche cherche à s'inspirer du comportement du cerveau humain lors du traitement des informations. L'approche a conduit à l'étude des réseaux de neurones formels, créés comme étant un parallèle automatique et artificiel aux neurones biologiques. Ils cherchent à réaliser un comportement artificiel et automatique du cerveau humain en se basant sur la simulation de son architecture de base [74]. On désigne par *connexionnisme* la démarche consistant à vouloir rendre compte de la cognition humaine par des réseaux de neurones [73].

2. HISTORIQUE

Les premières tentatives de modélisation du cerveau sont anciennes et précèdent même l'informatique, voici quelques dates qui ont marqué l'histoire du domaine connexionniste [75-77] :

- En 1890, W. Jones a introduit le concept de mémoires associatives et proposa ce qui est devenu par la suite la loi de fonctionnement et d'apprentissage des réseaux de neurones, connue plus tard sous le nom de « *Loi de Hebb* ».
- Le neurologue Warren Sturgis McCulloch et le logicien Walter Pitts ont mené les premiers travaux sur les réseaux de neurones à la suite de leur article fondateur : « *What the frog's eye tells to the frog's brain* » en 1943. Ils ont constitué un modèle simplifié de neurone biologique appelé neurone formel. Ils ont montré théoriquement que les neurones formels

simples peuvent réaliser des fonctions logiques, arithmétiques et symboliques complexes. Ils voulaient prouver que le cerveau est équivalent à une machine de Turing.

- En 1949, D. Hebb a présenté dans son ouvrage « The Organization of Behavior » une règle d'apprentissage. De nombreux modèles de réseaux aujourd'hui s'inspirent encore de la règle de Hebb.
- Le premier succès est apparu en 1957 quand Frank Rosenblatt a inventé le premier modèle artificiel nommé « le Perceptron ». C'est un réseau de neurones inspiré du système visuel. Il possède deux couches de neurones : une couche de perception et une couche liée à la prise de décision. C'était le premier système artificiel qui pouvait apprendre par expérience, y compris lorsque son instructeur commettait des erreurs.
- L'année 1960 a été marquée par la création d'un modèle ressemblant à celui de Rosenblatt mais dont la loi d'apprentissage est différente, ce modèle fut développé par B. Widrow et Hoff, il est connu sous le nom de modèle « *Adaline* » (*Adaptative Linear Element*). Ce modèle sera par la suite le modèle de base des réseaux multicouches. Sa loi d'apprentissage est à l'origine de l'algorithme de « *Rétro propagation du gradient* ».
- Le succès des modèles connexionnistes a vite atteint ses limites technologiques. En 1969 Marvin Lee Minski et Seymour Papert publièrent un ouvrage nommé « Perceptrons ». Ils ont montré les limitations théoriques des modèles de Perceptron et plus particulièrement de l'impossibilité de traiter par ce modèle des problèmes non linéaires. Ils ont étendu implicitement ces limitations à tous les modèles de réseaux de neurones artificiels. Face à ces obstacles les recherches dans ce domaine se sont déguisées sous le couvert de divers domaines comme par exemple : Le traitement adaptatifs du signal, la reconnaissance des formes, la modélisation en neurobiologique, etc. [78]. Jusqu'en 1972, où T. Kohonen a présenté ses travaux sur les mémoires associatives et proposa des applications à la reconnaissance des formes.
- Dès le début des années 80, l'approche connexionniste s'est relancée grâce aux travaux de J. J. Hopfield ; qui a présenté son étude sur un réseau complètement rebouclé. Depuis, un

avancement considérable fut reconnu et beaucoup de modèles ont été mis au point ; dont on peut citer : La Machine de Boltzmann en 1983, l'algorithme de Rétro propagation du gradient en 1985, celui de l'estimation par Rétro propagation de l'erreur par Hopkins en 1982, l'analogie de la phase d'apprentissage avec les modèles Markoviens des systèmes de particules de la mécanique statistique par Hopfield en 1982.

À nos jours l'approche connexionniste connaît un développement considérable, ceci en considérant le nombre de congrès et de publications spécialisés dans cette approche en plus de la diversité des domaines d'applications [79-80].

3. NEURONE BIOLOGIQUE

Bien que le cerveau humain et l'ordinateur soient tous les deux des machines dédiées pour le traitement de l'information, l'analogie comparant les deux paraît inadéquate. En effet l'observation de leurs comportements suffit pour s'en convaincre. La différence entre ces deux « machines » réside dans leurs structures, ces dernières sont la base du courant connexionniste [81].

Un réseau de neurone artificiel est un modèle de calcul dont l'inspiration originelle était un modèle biologique, c'est-à-dire le modèle du cerveau humain. Le cerveau humain est composé d'un grand nombre de cellules nerveuses. La cellule nerveuse humaine contient des neurones. Ces derniers ont une partie cellulaire et une partie de noyau. La partie cellulaire, nommée *Somma*, se ramifie pour former ce que l'on nomme les *Dendrites*. C'est par les dendrites que l'information s'achemine vers le corps du neurone (*le Somma*).

Une fois l'information traitée par le neurone, elle est transmise aux autres neurones qui communiquent entre eux via les « *Axones* ». Les neurones ne sont pas directement attachés entre eux, ce qui revient à dire que les transmissions ne sont pas directes. Il existe un espace intercellulaire qui sépare l'axone d'un neurone et les dendrites du neurone voisin, cette jonction est appelée « *Synapse* » [82].

Sur la figure 3.1 [83], un neurone biologique est présenté.

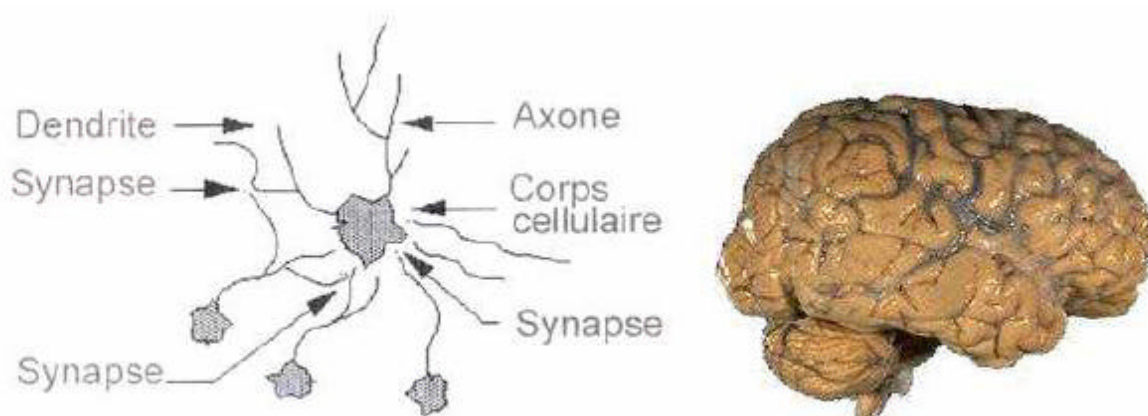


Figure 3.1 Le neurone biologique et le cerveau humain

Dans ce qui suit, nous présentons quelques informations concernant les Réseaux de Neurones :

- Le cerveau contient environ 100 milliards de neurones.
- On ne dénombre que quelques dizaines de catégories distinctes de neurones.
- Aucune catégorie de neurones n'est propre à l'homme.
- La vitesse de propagation des influx nerveux est de l'ordre de 100m/s. C'est à dire bien inférieure à la vitesse de transmission de l'information dans un circuit électronique.
- On compte quelques centaines à plusieurs dizaines de milliers de contacts synaptiques par neurone. Le nombre total de connexions est estimé à environ 10^{15} .
- La connectique du cerveau ne peut pas être codée dans un << document biologique >> tel l'ADN pour de simples raisons combinatoires. La structure du cerveau provient donc en partie des contacts avec l'environnement. L'apprentissage est donc indispensable à son développement.
- Le nombre de neurones décroît après la naissance. Cependant, cette affirmation semble remise en question.
- On observe par contre une grande plasticité de l'axone, des dendrites et des contacts synaptiques. Cette plasticité est très importante surtout après la naissance (observer chez le chat, un accroissement des contacts synaptiques de quelques centaines à 12000 entre le 10^{ème} et le 35^{ème} jour), elle est conservée tout au long de l'existence.

- Les synapses entre des neurones qui ne sont pas simultanément actifs sont affaiblies puis éliminés.
- Il semble que l'apprentissage se fasse par un double mécanisme : des connexions sont établies de manière redondante et aléatoire puis seules les connexions entre des neurones simultanément actifs sont conservées (phase de sélection) tandis que les autres sont éliminées. On parle de stabilisation sélective.

4. NEURONE FORMEL

D'une manière très réductrice, un neurone biologique est une cellule qui se caractérise par :

- Des synapses, les points de connexions avec les autres neurones, fibres nerveuses.
- Les dendrites, les entrées du neurone.
- L'axone, ' la sortie' du neurone vers d'autres neurones ou fibres musculaires.
- Le noyau qui active la sortie en fonction des stimulus en entrée.

Par analogie, le neurone formel (voir figure 3.2) est une fonction non linéaire, paramétrée, à valeurs bornées, il se caractérise par un état interne $s \in S$, des signaux d'entrée x_1, \dots, x_N et une fonction de transition d'état f comme suit :

$$s = h(x_1, \dots, x_N) = f\left(w_0 + \sum_{j=1}^N w_j x_j\right) \quad (3.1)$$

La fonction de transition est une transformation d'une combinaison des signaux d'entrée. Cette combinaison est déterminée par un vecteur de poids (w_0, \dots, w_N) associé à chaque neurone et dont les valeurs sont estimées dans la phase d'apprentissage, w_0 étant appelé le biais du neurone, il constitue la mémoire ou la connaissance répartie du réseau [84-85].

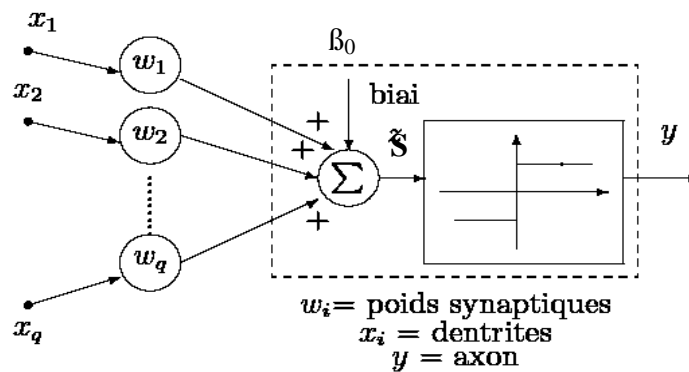


Figure 3.2 Un neurone formel

5. APPRENTISSAGE

La notion d'apprentissage est claire et intuitive pour les humains ou les animaux : c'est une procédure cognitive qui doit faire en sorte que l'individu réalise de manière autonome une tâche donnée, typiquement à partir d'exemples.

5.1. Définitions

L'apprentissage est une phase de développement d'un réseau de neurones durant laquelle une modification du comportement du réseau se fait jusqu'à l'obtention d'un comportement désiré. L'apprentissage neuronal fait appel à des exemples de comportement. Durant cette phase les poids synaptiques seront modifiés, donc d'une manière plus simple, on peut dire que l'apprentissage est une action de mise à jour des poids des connexions dans le but d'atteindre la sortie du réseau pour les exemples présentés en entrée [86].

5.2. Type d'apprentissage

Au niveau des algorithmes d'apprentissage, il existe trois types selon l'intervention ou non d'un superviseur [73] :

- **L'apprentissage supervisé** : ce mode est le plus courant, l'utilisateur dispose d'un comportement de références précis qu'il désire faire apprendre au réseau. Schématiquement, il consiste à évaluer les poids synaptiques minimisant l'erreur sur une base d'apprentissage, cette base comprend un ensemble d'observations pour lesquelles on connaît à la fois les entrées et les sorties souhaitées.
- **L'apprentissage semi- supervisé** : cet apprentissage est identique au précédent dans la mesure où il se base sur la présence d'un concepteur, cependant la valeur exacte de la sortie n'est pas disponible, en général la seule information disponible est un signal d'échec ou de succès.
- **L'apprentissage non supervisé** : ce mode d'apprentissage est moins intuitif, il correspond au cas où l'on ne dispose pas de bases d'apprentissage, par exemple lorsqu'on ne sait pas à priori déterminer ponctuellement si une sortie est ou non valable. L'apprentissage repose alors sur un «critère interne » de conformité du comportement du réseau par rapport à des spécifications générales et non sur des observations.

5.3. Règles d'apprentissage

L'apprentissage d'un Réseau de Neurones Artificiels se base sur des règles d'apprentissage. Nous citons ci-après les règles les plus répandues [83]:

- La règle de Hebb, vue dans le livre « *Organisation of Behavior* » en 1949. Elle permet de modifier la valeur des poids synaptiques en fonction de l'activité des unités qui les relient. Le but principal est le suivant : si deux unités s'activent en même temps la connexion qui les lie est renforcée (c'est une connexion excitatrice) sinon elle est affaiblie (c'est une connexion inhibitrice).
- La règle delta qui calcule la différence entre la valeur de la sortie et la valeur désirée pour ajuster les poids synaptiques. Elle emploie une fonction d'erreur, nommée « *la moindre carré moyen* », basée sur les différences utilisées pour l'ajustement des poids.

- La règle d'apprentissage compétitif qui ne concerne qu'un seul neurone. Son principe est de regrouper les données en catégorie. Les neurones similaires vont donc être rangés dans une même classe en se basant sur des corrélations des données et seront représentés par un seul neurone. L'architecture d'un tel réseau possède une couche d'entrée et une couche de compétition. Une forme est présentée à l'entrée du réseau. Elle est projetée ensuite, sur chacun des neurones de la couche compétitive. Le neurone gagnant est celui qui possède un vecteur de poids le plus proche de la forme présentée en entrée. Chaque neurone de sortie est connecté aux neurones de la couche d'entrée et aux autres cellules de sortie (c'est une connexion inhibitrice) ou à elle-même (c'est une connexion excitatrice). La sortie dépend alors de la compétition entre les connexions inhibitrices et excitatrices.

- La règle de corrélation en cascade, qui est une technique d'apprentissage, ajoute progressivement des neurones cachés au réseau jusqu'à ce que l'effet bénéfique de ces nouveaux neurones ne soit plus perceptible. Cette règle suit les deux étapes suivantes :
 1. On entraîne le système par un apprentissage classique qui s'effectue premièrement dans un petit réseau sans couche cachée.
 2. On entraîne par la suite un petit groupe des neurones supplémentaires qui doit diminuer l'erreur résiduelle du réseau. La règle d'apprentissage utilisée modifie les poids de ces neurones. Le neurone qui réussit le mieux est retenu, et intégré au réseau. L'étape 1 est relancée encore une fois, pour permettre au réseau de s'adapter à la nouvelle ressource.

- La règle de correction d'erreurs qui est caractérisée par les étapes suivantes :
 1. On commence avec des valeurs des poids de connexions qui sont pris au hasard.
 2. On introduit un vecteur d'entrée de l'ensemble des échantillons pour l'apprentissage.
 3. Si la sortie ou la réponse n'est pas correcte, on modifie toutes les connexions pour atteindre la bonne réponse

- La règle de rétro-propagation inventée par Rumelhart, Hinton et Williams en 1986. Elle s'utilise pour ajuster les poids de la couche d'entrée à la couche cachée. Cette

règle peut aussi être considérée comme une généralisation de la règle delta pour des fonctions d'activation non linéaire et pour des réseaux multicouches. Les poids dans le réseau de neurones sont au préalable initialisés avec des valeurs aléatoires. On considère ensuite un ensemble de données qui vont servir comme un échantillon d'apprentissage. Chaque échantillon possède ses valeurs cibles qui sont celles que le réseau de neurones doit atteindre lorsqu'on lui présente le même échantillon.

6. LES RESEAUX DE NEURONES

6.1 Définitions

Dès leur apparition, les Réseaux de Neurones Artificiels ont été appliqués à plusieurs domaines. Quelque soit le domaine adopté, les Réseaux de Neurones Artificiels peuvent être définis comme suit :

Définition 1 : Les Réseaux de Neurones Artificiels sont des réseaux fortement connectés de processeurs élémentaires, fonctionnant en parallèle. Chaque processeur calcule une sortie unique sur la base des informations qu'il reçoit, toute structure hiérarchique de réseaux est évidemment un réseau [87-88].

Définition 2 : Les Réseaux de Neurones Artificiels sont des modèles statistiques adaptatifs, basés sur une analogie avec le cerveau humain. Leur adaptabilité revient du fait qu'ils peuvent apprendre à estimer les paramètres d'un ensemble de données en utilisant un nombre d'exemples. Dans sa structure de base, un Réseau de Neurones Artificiels est constitué d'un ensemble d'unités simples qui sont les neurones. Ces dernières sont interconnectées à l'aide d'un ensemble de connexions pondérées, chaque unité correspond à une caractéristique d'une forme à analyser [73].

Les Réseaux de Neurones Artificiels sont généralement organisés en couches. La première couche est la couche d'entrée. Elle est responsable de la transmission de l'information à analyser vers le réseau. La dernière couche est la couche de sortie. Elle reçoit le résultat final qui est la réponse du réseau. Les couches intermédiaires sont les couches cachées, le nombre de ces couches est défini selon le type du problème à résoudre. Elles relient les deux couches d'entrée et de sortie [89-90].

6.2. Propriétés

Les Réseaux de Neurones Artificiels sont considérés comme des simulateurs du système biologique. Ils doivent prendre en considération les points suivants :

- **Le parallélisme** : Les Réseaux de Neurones Artificiels sont constitués à base de neurones simples fortement interconnectés, dont le but est la réalisation d'une fonction de type bien défini ce qui rend le traitement de l'information massivement parallèle [86].
- **Les poids synaptiques** : La pondération des liaisons synaptiques entre les neurones influence sur l'efficacité et la fiabilité du réseau du point de vue rapidité et exactitude des résultats fournis [73].
- **L'apprentissage** : L'apprentissage est vraisemblablement la propriété la plus intéressante des Réseaux de Neurones Artificiels, elle ne concerne cependant pas tous les modèles mais les plus utilisés, son principal problème est d'arriver à trouver un ensemble de valeurs d'entrée des connexions afin d'atteindre les résultats voulus [91].

6.3. Topologies

On appelle topologie des réseaux la façon dont les neurones sont connectés entre eux à travers les différentes couches. En général on peut distinguer deux grandes classes de Réseaux de Neurones Artificiels selon leurs topologies : les réseaux à couches qui sont des réseaux de neurones dans lesquels l'information se propage couche par couche sans retour en arrière possible et les réseaux récurrents qui sont des réseaux de neurones dans lesquels il y a une liaison vers l'arrière. Les connexions de ces réseaux forment des boucles. Ainsi la fonction d'activation peut circuler le long de ces boucles et affecter le réseau pendant une période

arbitrairement longue. Pour cette raison les comportements des réseaux récurrents sont potentiellement plus complexes que ceux des réseaux à couches [83]. La figure 3.3 [73] présente les différentes topologies d'un Réseau de Neurones Artificiels.

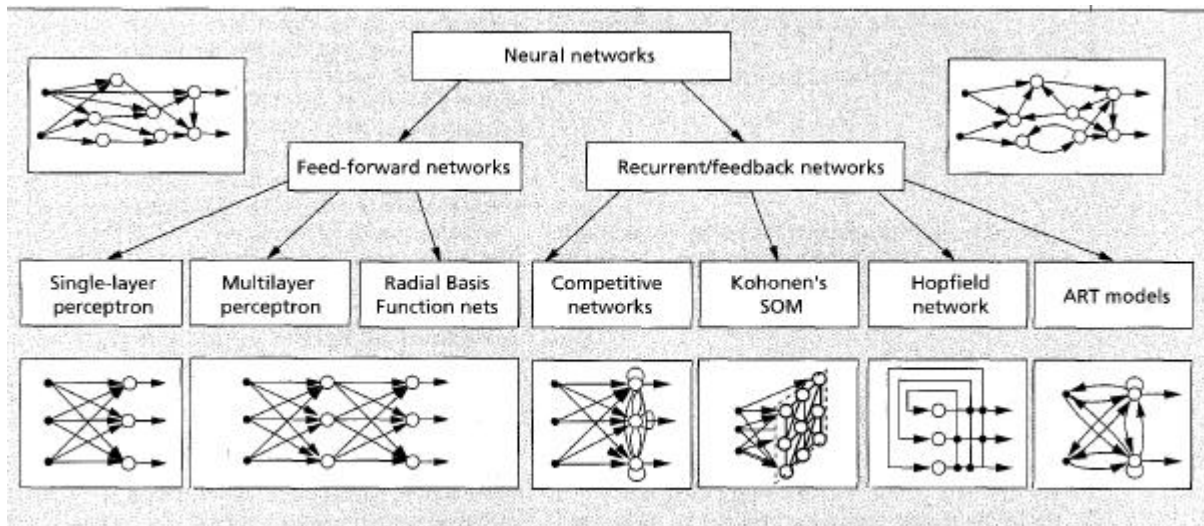


Figure 3.3 Topologies des Réseaux de Neurones Artificiels

6.3.1 Les réseaux à couches

Les réseaux à couches peuvent se diviser en réseaux sans couches cachées et les réseaux avec une ou plusieurs couches cachées.

Les réseaux sans couches cachées sont les réseaux les plus simples. Ils sont utilisables pour des problèmes de classification ou d'approximation. Ils ont un avantage majeur, leur apprentissage converge vers une solution optimale. Cela est dû au fait que c'est un système linéaire. Leur inconvénient est qu'ils peuvent seulement classifier ou approximer les problèmes linéaires et ne peuvent résoudre un problème non linéaire [83].

L'exemple classique pour ce type de réseau est le Perceptron monocouche, inventé par Rosenblatt [92]. C'est un modèle très simple, basé sur l'orientation physico-physiologique. Il ne dispose que de deux couches :

- Une couche d'entrée qui s'appelle la rétine et qui est une aire sensorielle ;
- Une couche de sortie qui donne la réponse correspondante à la simulation présentée à l'entrée.

Le fonctionnement du réseau est comme suit : une donnée est présentée au réseau en activant la rétine. L'activation se propage vers la couche de sortie où on peut noter la réponse du système. Cette réponse suit la formule suivante :

$$y = \mathbf{j} \left(\sum_{j=1}^2 w_j x_j + \mathbf{q} \right) \quad (3.2)$$

- Où
- \mathbf{j} La fonction d'activation utilisée.
 - w_j Les poids du neurone.
 - x_j Les entées.
 - \mathbf{q} Le seuil du neurone.

La figure 3.4 montre la structure du Perceptron monocouche, avec une sortie y et deux entrées x_1 et x_2 qui forme la rétine du réseau.

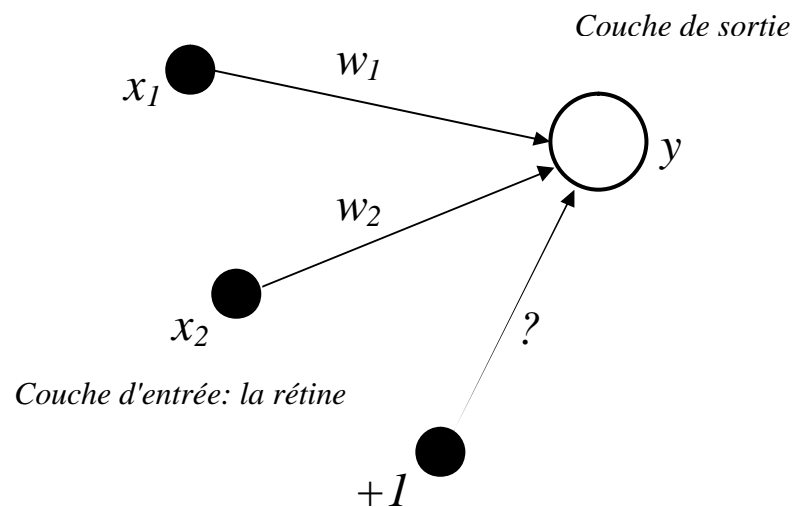


Figure 3.4 Un Perceptron monocouche

Ces réseaux suivent un apprentissage supervisé selon la règle d'apprentissage delta ou la règle de correction d'erreurs. Les deux règles ajustent les poids et les seuils de la même manière. Pour chaque poids la nouvelle valeur est calculée par l'addition d'une correction de valeur ancienne :

$$w_j(\text{nouveau}) = w_j(\text{ancien}) + \Delta w_j \quad (3.3)$$

$$\Theta(\text{nouveau}) = \Theta(\text{ancien}) + \Delta \Theta$$

Un réseau monocouche ne permet pas de résoudre des problèmes non linéaires. Les réseaux multicouches qui sont des systèmes non linéaires ont été inventés pour remédier à ce problème. Les réseaux de ce type possèdent trois sortes de couches :

- Une couche d'entrée avec N_i unités d'entrées.
- Des couches cachées avec N_h unités; elles démultiplient la puissance de calcul et permettent d'aborder des problèmes plus difficiles.
- Une couche de sortie avec N_o unités de sorties.

On peut voir la structure d'un tel réseau sur la figure 3.5 [83].




Figure 3.5 Un réseau multicouche

Le Perceptron multicouche et le réseau à fonction radiale (RBF) sont deux types de ce réseau.

Le Perceptron multicouche est un modèle possédant une grande capacité de calcul. Sa structure est composée d'une couche d'entrée, une couche de sortie, interprétée comme étant la réponse du réseau et d'une ou plusieurs couches intermédiaires dites « couches cachées ». Un neurone d'une couche inférieure ne peut être relié qu'à des neurones des couches suivantes. Il suit un apprentissage supervisé et utilise la règle d'apprentissage de rétro propagation. En général, les neurones du Perceptron multicouche sont animés par une fonction d'activation non linéaire (au moins dans une des couches). Les choix classiques pour cette fonction sont :

- La fonction tangente hyperbolique $\mathbf{j}(x) = \tanh(x)$ (c'est le choix standard).
- La fonction sigmoïde $\mathbf{j}(x) = \frac{1}{1 + e^{-x}}$.

Le réseau à fonction radiale (RBF) a la même structure que le Perceptron multicouche. A l'exception de sa fonction d'activation qui est une fonction de type Gaussienne. Ce réseau, à cause de son architecture, utilise le plus souvent la règle d'apprentissage de correction d'erreur et la règle par apprentissage compétitif. Il peut avoir un apprentissage qui combine en même temps l'apprentissage supervisé et l'apprentissage non supervisé. Il est caractérisé par un apprentissage plus rapide et plus simple.

6.3.2 Les réseaux récurrents

Les réseaux récurrents constituent la deuxième grande catégorie de Réseaux de Neurones Artificiels. Trois classes importantes de ce type sont les plus utilisées: les réseaux récurrents à couches (le réseau de Elman et le réseau de Jordan), les réseaux à compétition (réseaux ART et réseaux de Kohonen, « Self-organisation mapping ») et les réseaux à connexions symétriques (réseaux de Hopfield).

Le réseau de Jordan [93] est le réseau récurrent le plus ancien. Sa structure est présentée sur la figure 3.6.

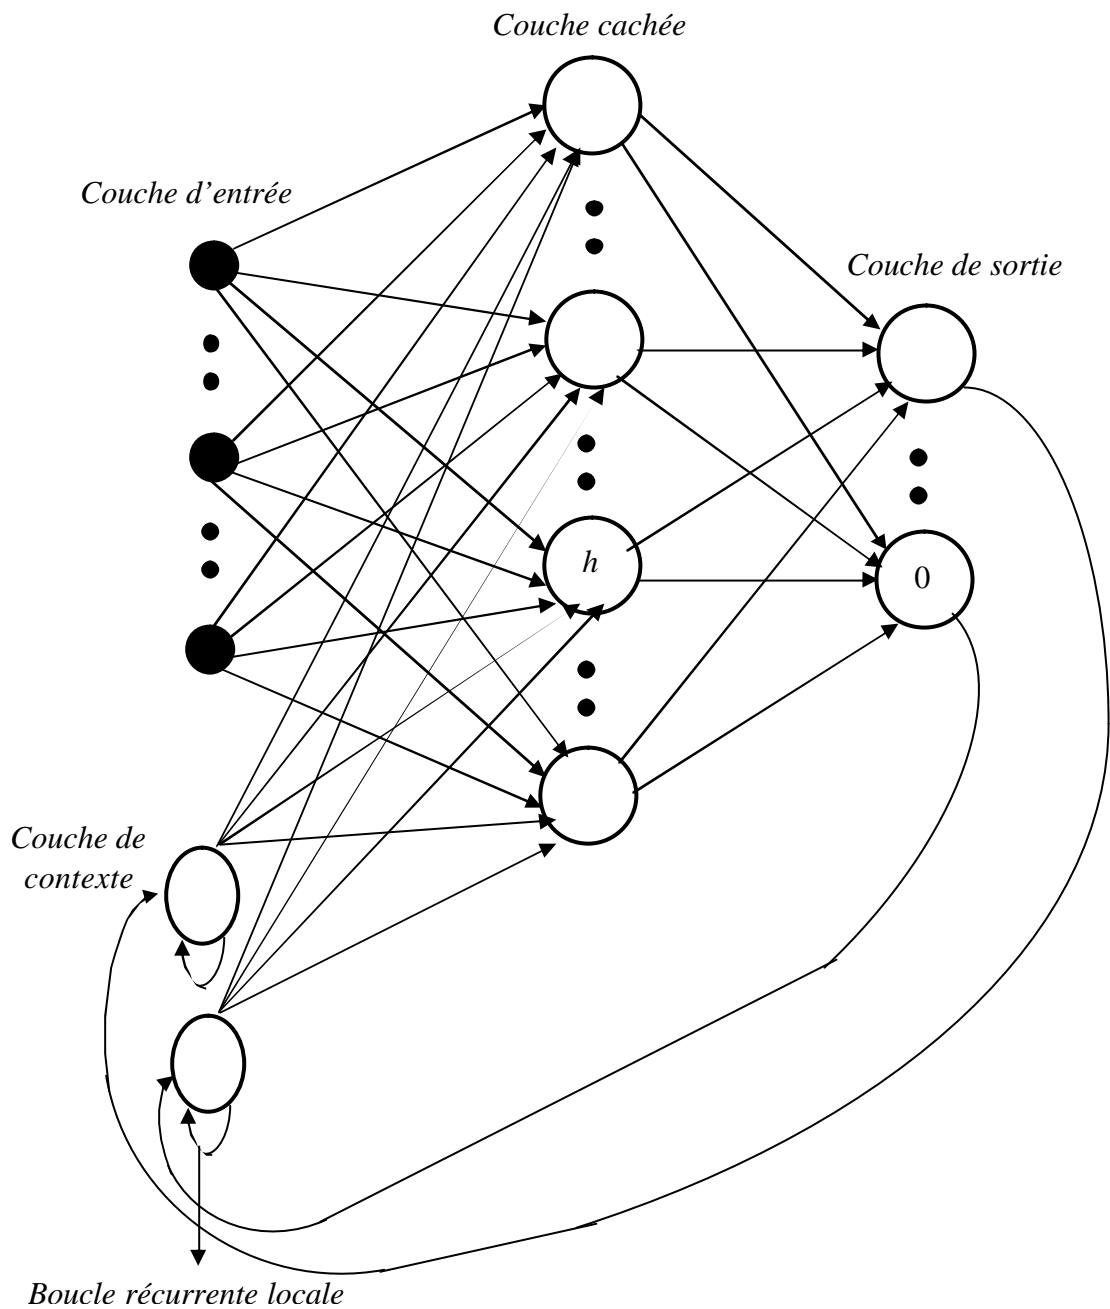


Figure 3.6 Réseau de Jordan

Le but de ce réseau est d'effectuer une séquence d'actions par rapport à une tâche donnée par l'utilisateur. La tâche est constante durant l'exécution de la séquence ; le réseau doit toutefois retenir sa position dans la séquence. Pour mener la tâche à bien, il lui faut donc une mémoire du contexte représentée par une couche nommée « couche de contexte », qui a comme rôle de retenir l'état du réseau au temps précédent et sa propre activation par une boucle récurrente locale. Le nombre de neurones de cette couche dépend du nombre de

neurones de sortie qui sont reliés entre eux. Il en résulte que la couche de contexte retient une trace des événements passés. On peut utiliser toutes les règles d'apprentissage décrites par un Perceptron multicouche pour entraîner ce réseau.

Le réseau d'Elman [94] a été introduit par Elman en 1990 (voir la figure 3.7). Ce réseau est très semblable au réseau de Jordan, mais son architecture est plus adaptée au traitement de séquence structurée. Le réseau de Jordan boucle ses sorties sur ses entrées. Par contre, le réseau d'Elman boucle sa couche cachée sur elle-même. Dans ce cas, la couche du contexte a pour objectif de retenir l'état de la couche cachée. Comme dans le réseau de Jordan, cette boucle récurrente permet de retenir une trace d'événements passés (Figure 3.7). Pour l'apprentissage, le réseau applique une rétro propagation classique pour corriger les poids, sans tenir compte de la recopie de l'activation de la couche cachée vers la couche de contexte.

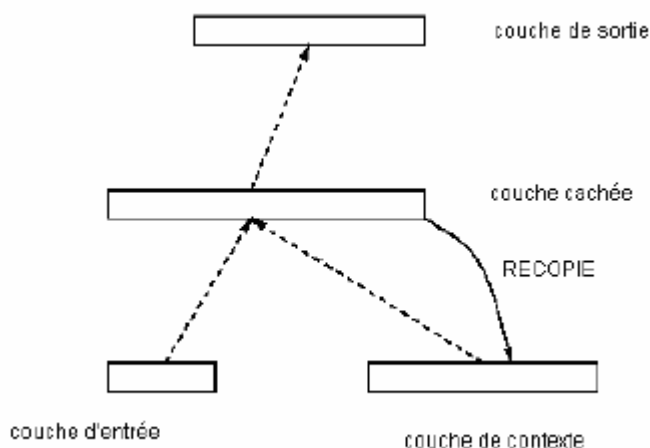


Figure 3.7 Réseau d'Elman

Les réseaux à compétition sont composés d'une couche de neurones qui reflète passivement les données d'entrée présentées au réseau, et une couche de neurones de sortie en compétition. L'utilisation du réseau se fait de la façon suivante : une donnée d'entrée est présentée au réseau, provoquant des réponses variées dans les neurones de sortie. La compétition s'installe alors entre ces derniers, et prend la forme d'un combat d'influence qui doit éventuellement se stabiliser grâce à la force des liens inhibiteurs. A la fin de la compétition, les neurones de sortie les plus activés sont déclarés "vainqueurs". Les réseaux

ART (Adaptive Resonance Theory) et les réseaux de Kohonen (Self-organisation mapping) sont deux exemples de ce type de réseau.

Le problème majeur qui se pose dans les réseaux à compétition est le compromis stabilité/plasticité. En effet dans l'apprentissage rien ne garantit que les catégories formées restent stables. La seule possibilité pour assurer une stabilité, serait que le taux d'apprentissage tend vers zéro, mais dans ce cas le réseau perd sa plasticité. C'est pour résoudre ce problème, que les réseaux ART sont utilisés. Les valeurs de poids ne sont adaptées que s'il y a une approximation suffisante entre l'entrée du réseau et le prototype déjà connu par le réseau. Il existe alors une résonance. Sinon, si l'entrée du système est très éloignée du prototype, on crée alors une nouvelle classe. Le mode d'apprentissage peut être supervisé ou non. Deux types de ces réseaux sont connus :

1. ART-1 est un système binaire dont la fonction est d'associer à une donnée d'entrée binaire un seul neurone de sortie. Le but le plus connu de ce réseau est de modéliser la reconnaissance d'un objet perçu, ainsi que de stocker une information. Mais ces réseaux sont très sensibles aux bruits qui apparaissent sur les données. Pour y échapper, on doit mettre en place une couche de filtrage.
2. ART-2 traite des valeurs continues, mais il a le même but que le réseau précédent. Cependant les calculs utilisés sont beaucoup plus difficiles à effectuer.

Les réseaux de Kohonen (Self organisation mapping) utilisent la carte de Kohonen. Cette carte est composée de deux couches dont la première constitue l'entrée du réseau et la seconde la sortie. On peut voir la structure de cette carte sur la figure 3.8 [83]. Les neurones de la carte sont disposés en une topologie déterminée. Plusieurs topologies sont possibles, par exemple une carte carrée ou un carte rectangulaire.




Figure 3.8 Structure de la carte de Kohonen

Enfin dans les réseaux à connexions symétriques, il est possible de comprendre un système complexe, non pas en s'attardant sur le comportement individuel de ses composants, mais en étudiant le comportement collectif du système dans son ensemble.

Le réseau de Hopfield est un exemple des réseaux de ce type. Ce réseau est potentiellement utile en pratique, dès qu'il est possible de dicter par apprentissage les états stables du réseau. Dans une application, l'état d'activation initial du réseau est fixé de façon à exprimer le problème à résoudre. Le réseau évolue ensuite par une succession de propagations synchrones, jusqu'à un point fixe. Cet état stable est alors interprété comme le résultat du calcul (et donc la solution du problème). On remarque généralement que tous les neurones du réseau participent à la description du problème et à sa résolution. Ainsi, le réseau de Hopfield ne contient pas de neurones cachés [95].

6.4. Les fonctions d'activation

La fonction d'activation est une transformation linéaire ou non linéaire, elle permet la liaison entre la sortie et son entrée. Vu la variété des modèles de Réseaux de Neurones Artificiels, différentes fonctions ont été proposées, parmi lesquelles on peut citer [73] :

- **Les modèles linéaires et sigmoïdaux** : ces modèles sont très adaptés aux algorithmes d'apprentissage comme celui de rétro propagation du gradient car leur fonction de transition est différentiable.
- **Le modèle à seuil** : ce modèle est très proche et conforme à la réalité biologique mais il pose des problèmes d'apprentissage.
- **Le modèle stochastique** : ce type de modèle est utilisé pour les problèmes d'optimisation globale des fonctions perturbées ou encore pour les analogies avec les systèmes de particules.

Le tableau 3.1 illustre quelques importantes fonctions d'activation [77] [88] [91].

Tableau 3.1 Exemples de fonctions d'activation

Fonction D'activation	Formule	Dérivation	Commentaire
Sigmoïde	$a = f(u)$ $f(u) = \frac{1}{1 + e^{-u/T}}$	$df(u) / d(u)$ $f(u)[1 - f(u)]/T$	La dérivée partielle est calculée à partir de f(u)
Tangente hyperbolique	$f(u) = \tanh\left(\frac{u}{T}\right)$	$(1 - f(u)^2) / T$	T: paramètre de température
Tangente inverse	$f(u) = \frac{2}{\pi} \tan^{-1}\left(\frac{u}{T}\right)$	$\frac{2}{\pi T} \cdot \frac{1}{1 + \left(\frac{u}{T}\right)^2}$	Moins utilisée
Fonction à seuil	$f(u) = \begin{cases} 1 & u > 0 \\ -1 & u < 0 \end{cases}$	Pas de dérivée à u=0	
GRB Gaussian Radial Basis	$f(u) = \exp\left[-\ u - m\ ^2 / s^2\right]$	$2 - (u - m) \cdot f(u) / s^2$	m et s ² sont des paramètres à spécifier.
Lineaire	$f(u) = a \cdot m + b$	a	

7. AVANTAGES ET LIMITES

Les Réseaux de Neurones Artificiels ont plusieurs avantages dont on peut citer [73] [83]:

- **L'apprentissage** : la possibilité d'apprendre et de généraliser les connaissances acquises.
- **Le parallélisme massif** : l'architecture d'un réseau de neurone permet le traitement parallèle et rapide des informations.
- Une tolérance à l'incertitude très élevée.
- Etant une multiple copie d'unités simples (les neurones), ils sont donc facilement extensibles.
- Une facilité d'utilisation car ne nécessitant pas une compréhension approfondie.
- Un choix de types, d'architecture et de fonction d'activation de réseaux diverses.
- etc.

Bien que les réseaux de neurones soient capables d'effectuer beaucoup de tâches, ils souffrent néanmoins de certaines limites dont on peut citer [73] [83] :

- **L'architecture et le paramétrage du réseau** : Il est difficile de définir pour un problème donné l'architecture et le type adéquat du réseau à utiliser en plus des bons paramètres de réglage.
- **Initialisation et codage** : L'état initial du réseau est très important car il a une très grande influence sur la fiabilité et le temps de calcul et de réponse du réseau, donc un mauvais choix des poids initiaux peut conduire à un blocage d'apprentissage et de convergence du réseau vers la solution désirée.
- **Boîte noire** : Les Réseaux de Neurones Artificiels sont des boîtes noires, dans la mesure où l'on ne peut connaître et interpréter directement les connaissances acquises par le réseau, donc ces connaissances sont inintelligibles pour l'utilisateur ou l'expert [96].
- Une facilité d'application donnant lieu à de nombreuses implémentations et des choix pas toujours justifiés.
- La surface d'erreur des réseaux complexes possède beaucoup de sommets (des maximums locaux) et de vallées (des minimums locaux). A cause de leur nature non

linéaire, les réseaux peuvent être piégés dans un minimum local où les performances ne sont pas optimales.

8. APPLICATIONS

Depuis leur apparition, les réseaux de neurones ont été largement utilisés dans plusieurs domaines. On peut citer [97] :

- ✚ Les prédictions et les prévisions avec les prévisions météorologiques et les estimations de probabilité de succès.
- ✚ Les applications de reconnaissance des formes dans la lecture automatique des codes postaux, la reconnaissance et synthèse de la parole ou la Reconnaissance automatique d'image (La détection et la reconnaissance des visages, imagerie satellitaire, etc.).
- ✚ Le traitement du signal avec l'égalisation non linéaire, l'élimination du bruit et de l'écho et la Reconnaissance de signaux radar.
- ✚ La bio- ingénierie pour prédire les propriétés chimiques des molécules.
- ✚ L'automatique pour l'identification/modélisation des systèmes non linéaires, la modélisation des procédés industriels et la Robotique (pilotage automatique des véhicules autonomes, Modélisation d'un actionneur hydraulique d'un bras d'un robot).
- ✚ La fouille de données (Extraction des connaissances et les problèmes d'optimisation et de classification).

Le tableau 3.2, représente la correspondance entre chaque domaine d'application et le type de Réseau de Neurones Artificiels le plus approprié [98].

Tableau 3.2 Correspondance type de RNA - Domaine d'application

Domaine d'application	Type de RNA
Reconnaissance de formes	MLP, Hopfield, Kohonen, PNN
Mémoires Associatives	Hopfield, MLP recurents, Kohonen
Optimisation	Hopfield, ART, CNN
Approximation de fonctions	MLP, RBF
Modélisation et control	MLP, MLP récurrent, FLN
Traitement d'images	CNN, Hopfield
Classification et Clustering	MLP, Kohonen, RBF, ART, PNN

9. CONCLUSION

Les Réseaux de Neurons Artificiels sont considérés comme des approches très intéressantes dans le domaine de l'Intelligence Artificielle. Ils sont connus par leur puissance d'apprentissage et généralisation. Les Réseaux de Neurons Artificiels sont appliqués dans les reconnaissances des formes, comme dans l'approximation de fonctions. Dans ce chapitre, un aperçu général est donné sur la notion de Réseaux de Neurons Artificiels, en passant par la définition, la structure et le fonctionnement. Les différents types de réseaux sont présentés aussi avec le domaine d'applications.

Chapitre 4 : Modélisation de la Charge Electrique Algérienne

- 1. Introduction*
- 2. Caractéristiques de la charge électrique algérienne*
- 3. Modélisation de la charge électrique algérienne*
- 4. Conclusion*

Chapitre 04 : Modélisation de la Charge Electrique Algérienne

1. INTRODUCTION

Dans ce chapitre, les méthodes vues précédemment (chapitre 2 et 3) sont appliquées pour la prédiction de la charge électrique Algérienne à savoir la méthode Box-Jenkins et les Réseaux de Neurones Artificiels. Cette dernière est considérée comme une ressource importante pour l'économie du pays. Elle présente des caractéristiques liées directement au comportement des être-humains. Ces caractéristiques influent sur la façon par laquelle les méthodes de prédiction vont être appliquées.

2. CARACTERISTIQUES DE LA CHARGE ELECTRIQUE ALGERIENNE

La source des données utilisées dans ce projet est issue de la Société Nationale de l'Electricité et du GAZ "SONELGAZ". Elle nous a fourni les valeurs de la charge électrique Algérienne consommées par les utilisateurs durant 05 années. Un aperçu de ces valeurs est résumé dans le tableau 4.1.

Tableau 4.1 Détail des données de la charge électrique Algérienne utilisées

Gamme de données	Du Samedi 01 Janvier 2000 Au Vendredi 31 Décembre 2004
Délai	Horaire
Nombre de point de données	43848




Figure 4.1 La série de la charge électrique Algérienne sur 05 années

La figure 4.1 présente les variations de la série représentant la charge électrique Algérienne pour 05 années. Ce qui peut être remarqué de cette figure est l'existence d'une tendance croissante qui reflète l'accroissement des activités économiques durant cette période. Une variation cyclique annuelle peut être aussi repérée. Elle est due au changement climatique qui varie et se répète chaque année. Ce changement influe directement sur le comportement des êtres humains et par conséquent sur les valeurs de la charge électrique Algérienne.

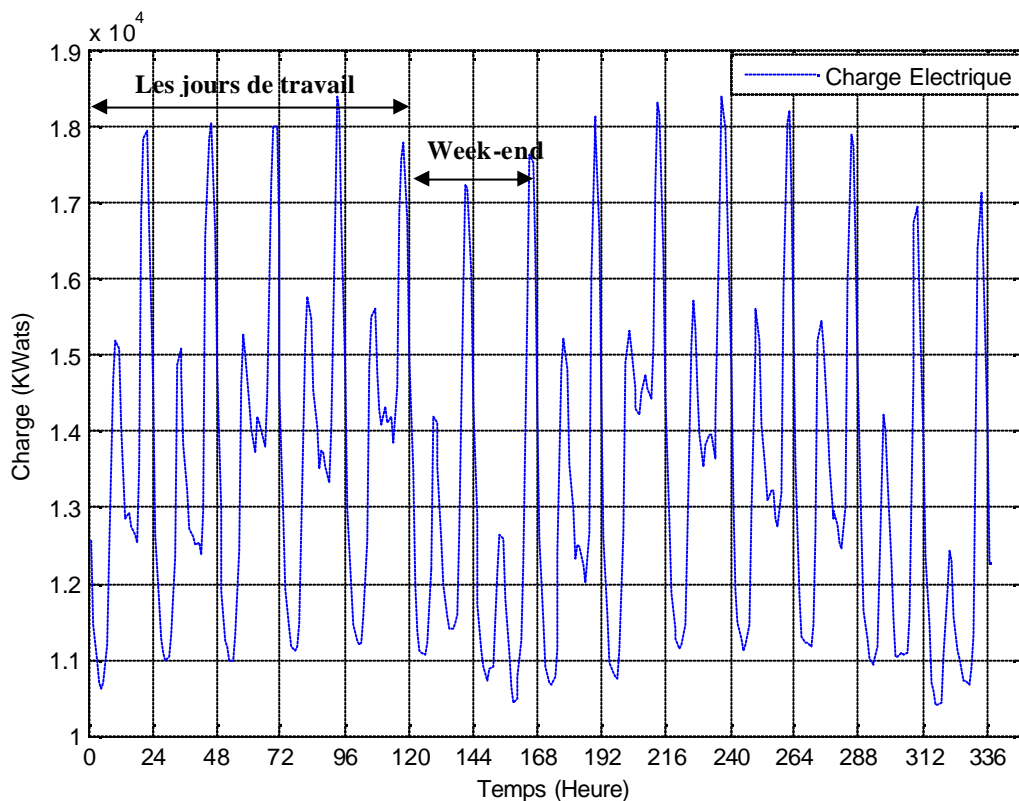


Figure 4.2 La charge électrique Algérienne du Samedi 15 au Vendredi 28 Janvier 2000.

La variation cyclique n'est pas seulement annuelle, elle est aussi hebdomadaire. Elle est montrée par la variation représentée sur la figure 4.2 pendant les deux dernières semaines du mois de Janvier 2000. Sur cette figure, des variations similaires sont repérées. Si on prend la variation des valeurs de chaque jour d'une semaine superposées (figure 4.3) on conclut qu'il existe des jours où les variations sont presque les mêmes. Par exemple, les courbes des jours de la semaine du Samedi vers le Mercredi ont la même forme.




Figure 4.3 Variation de la charge électrique Algérienne pendant la semaine du Samedi 01 au Vendredi 07 Janvier 2000.

Ce qui peut être extrait à travers les courbes sur les figures 4.1, 4.2 et 4.3 est que la charge électrique dépend du comportement des utilisateurs durant les journées et même durant la même journée.

3. MODELISATION DE LA CHARGE ELECTRIQUE ALGERIENNE

Pour la bonne estimation et vérification des méthodes de prédiction, les données sont divisées en deux classes. La première classe, regroupant les données de la charge électrique Algérienne sur une période de 04 années, est réservée pour l'estimation du modèle. L'autre classe est utilisée pour vérifier le modèle estimé. Cette classe regroupe les données qui restent de la charge électrique Algérienne d'une période d'une année (voir figure 4.1). Le tableau 4.2 illustre la distribution des données.

Tableau 4.2 Classification des données utilisées

Données	Période
Données d'estimation	01 Janvier 2000 – 31 Décembre 2003
Données de vérification	01 Janvier 2004 – 31 Décembre 2004

Pour ce projet, la méthode Box-Jenkins est utilisée en premier lieu suivi des Réseaux de Neurones Artificiels.

3.1 Modélisation par la méthode Box-Jenkins

Dans le chapitre 2, la méthode Box-Jenkins est expliquée sous tous ses aspects. Elle est appliquée sur les données représentant la charge électrique Algérienne. Un des critères à vérifier, avant l'application de la méthode, est la stationnarité de la série étudiée. La croissance de la charge électrique Algérienne observée sur la figure 4.1 est un signe de la non stationnarité de cette dernière. Les figures 4.4 et 4.5 représentent respectivement, les variations de la moyenne et de la variance de la charge électrique Algérienne dans le temps.




Figure 4.4 La moyenne de la charge électrique Algérienne




Figure 4.5 La variance de la charge électrique Algérienne

Ce qui peut être tiré des deux courbes sur les figures 4.4 et 4.5 est que ni la moyenne, ni la variance ne sont stables. Des transformations doivent être faites sur la série pour la rendre stationnaire, pour pouvoir ensuite appliquer la méthode Box-Jenkins.

La fonction d'auto-corrélations simples est le moyen pour contrôler et déterminer si une série est stationnaire ou non. La fonction d'auto-corrélation simple de la charge électrique Algérienne est représentée sur la figure 4.6. Cette fonction montre des corrélations positives sur tous les retards. Ces corrélations sont fortes pour des retards périodiques d'ordre 24. C'est le signe de la saisonnalité hebdomadaire de la série. La charge électrique Algérienne nécessite une différentiation, d'après les remarques mentionnées dans le paragraphe 3.2.1 du chapitre 02 concernant la différentiation d'une série temporelle.

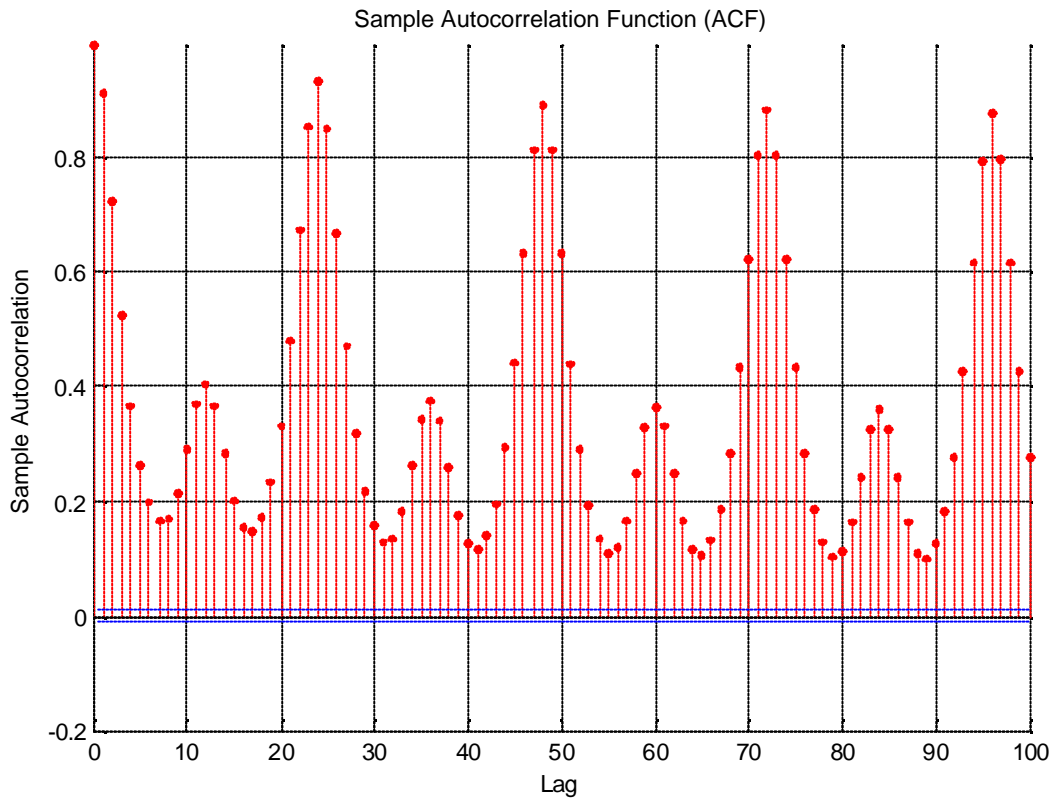


Figure 4.6 La fonction d'auto-corrélations simples de la charge électrique Algérienne

La charge électrique Algérienne est en croissance continue. Une transformation de type Logarithme est effectuée en premier lieu par l'équation (4.1). Ensuite plusieurs différentiations sont effectuées sur la charge électrique Algérienne.

$$Y_t = \log (Y_t) \quad (4.1)$$

En différenciant, le phénomène de sur-différentiation est souvent croisé. Pour cette raison, chaque étape de différenciation est contrôlée, pour déterminer la présence ou non de ce phénomène. Le calcul de l'écart type est le moyen utilisé pour déterminer le bon choix des différenciations. Le tableau 4.3 présente les écarts types calculés pour les différenciations effectuées.

**Tableau 4.3 les Ecart-types calculés en appliquant la méthode Box-Jenkins
Sur la charge électrique Algérienne**

Opération	Ecart-type
Initial	2328.4
Logarithme	0.181801
Différenciation d'ordre 24	0.069992
Différencier 01 fois	0.072511
Différencier 02 fois	0.064801
Différencier 03 fois	0.086010
Différenciation d'ordre 24 après une différenciation	0.029939
Différenciation d'ordre 24 après 02 différenciations	0.040018

L'observation des résultats dans le tableau 4.3 des écarts types, nous donne le meilleur scénario à suivre pour les différenciations appliquées sur la série représentant la charge électrique Algérienne. Les différenciations maintenues pour appliquer la méthode Box-Jenkins sont les suivantes :

- Appliquer le logarithme.
- Différencier 1 fois.
- Différenciation d'ordre 24 (Dessaisonalisation).

Avec les différenciations effectuées sur la charge électrique Algérienne, la première étape de la méthode Box-Jenkins est achevée. Une idée sur les paramètres et leurs ordres doit être faite afin de les estimer. La série étudiée est de type scalaire. Pour l'étude, on ne dispose pas d'autres valeurs externes concernant les variables qui influent sur les valeurs de la charge électrique Algérienne, à savoir les paramètres climatiques (Températures, etc.). Pour cette raison, on ne dispose que de 02 paramètres à estimer. Il s'agit des ordres des deux polynômes A et C de la forme générale du modèle Box-Jenkins définie par l'équation (2.17). Ce qui nous donne à modéliser la charge électrique Algérienne comme suit :

$$A(q) y(t) = C(q) e(t) \quad (4.2)$$

Les polynômes $A(q)$ et $C(q)$ sont données par les deux équations 4.3 et 4.4 respectivement. L'estimation se limite à calculer les coefficients de ces deux polynômes.

$$A(q) = 1 - a_1 q^{-1} \dots - a_{na} q^{-na} \quad (4.3)$$

$$C(q) = 1 + c_1 q^{-1} \dots + c_{nc} q^{-nc} \quad (4.4)$$

La fonction *pem* de la boîte à outils Matlab System Identification ToolBox est utilisée pour l'estimation du modèle Box-Jenkins. La fonction nécessite de préciser juste l'ordre des polynômes. Comme résultats, la fonction *pem* nous renvoi les polynômes estimés ainsi qu'une fonction *Loss* (*V*) et une erreur de prédiction *FPE* (Erreur de Prédiction Finale) donnée par l'équation (4.5).

$$FPE = V \frac{1 + d/N}{1 - d/N} \quad (4.5)$$

- Où
- V* La fonction *Loss* qui représente le déterminant de la matrice de variance des erreurs de prédiction,
 - d* Nombre de paramètres,
 - N* Nombre de données.

Le problème qui se pose durant l'estimation est le bon choix des degrés des polynômes. La fonction d'auto-corrélation simple et la fonction d'auto-corrélations partielles sont les deux moyens qui nous permettent de faire une pré-idée sur ces valeurs. Elles sont représentées respectivement par les deux figures 4.7 et 4.8.

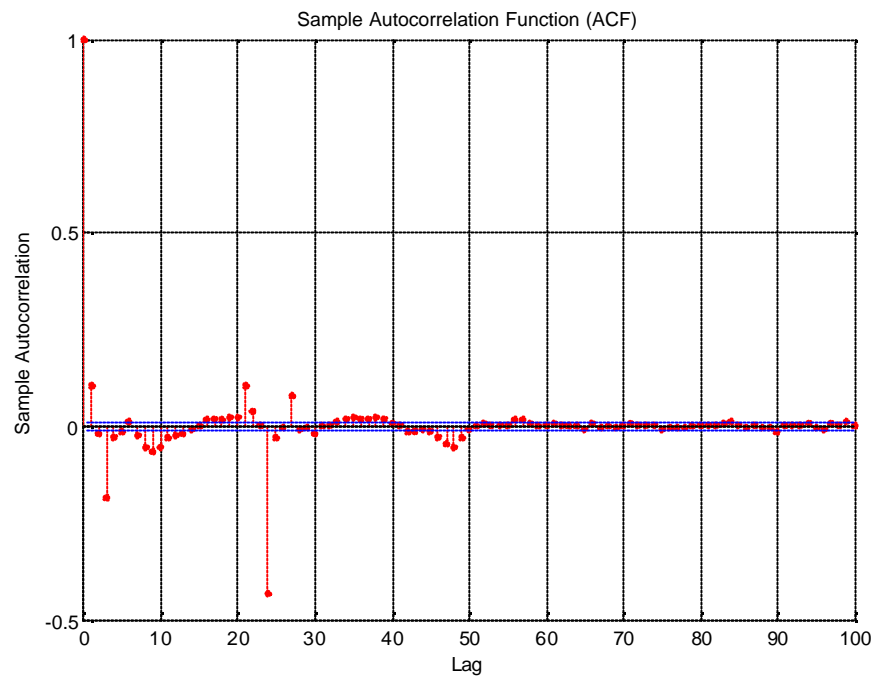


Figure 4.7 La fonction d’auto-corrélation simple da la série à étudier.




Figure 4.8 La fonction d’auto-corrélation partielle da la série à étudier.

Sur la figure 4.7, la corrélation sur le retard 24 est forte (Sous forme d'un pic). En plus, toutes les corrélations sont presque nulles après le pic. Ce qui nous donne le choix 24 comme ordre de la composante MA. Concernant la composante AR, la figure 4.8 présente des pics périodiques de 24. Dans ce cas, il est impossible de faire une hypothèse sur l'ordre du polynôme. 25 modèles sont utilisés pour chaque valeur de l'ordre du polynôme A (de 0 jusqu'à 24). Le tableau 4.4 résume les résultats trouvés. Le critère AIC est calculé Pour chaque modèle.

Tableau 4.4 L'erreur FPE et le critère AIC calculés durant l'estimation du modèle Box-Jenkins pour la charge électrique Algérienne

Modèle	FPE x 10 ⁻³	AIC
0 , 24	,	-7,3726
1 , 24	,	-7,3759
2 , 24	,	-7,3764
3 , 24	,	-7,3896
4 , 24	,	-7,3894
5 , 24	,	-7,3903
6 , 24	,	-7,3899
7 , 24	,	-7,3899
8 , 24	,	-7,3910
9 , 24	,	-7,3911
10 , 24	,	-7,3955
11 , 24	,	-7,3992
12 , 24	,	-7,4046
13 , 24	,	-7,4079
14 , 24	,	-7,4105
15 , 24	,	-7,4149
16 , 24	,	-7,4156
17 , 24	,	-7,4150
18 , 24	,	-7,4149
19 , 24	,	-7,4151
20 , 24	,	-7,4155
21 , 24	,	-7,4156
22 , 24	,	-7,4155
23 , 24	, 0	-7,4161
24 , 24	,	-7,4133

L'observation du tableau 4.4 nous montre que le modèle (23 , 24) est le mieux adapté pour modéliser la charge électrique Algérienne, car il minimise l'erreur FPE ainsi que le critère AIC. Le choix est validé par la courbe des auto-corrélations des résidus obtenus, présentée par la figure 4.9. La figure montre l'absence des corrélations entre les résidus sur tous les retards.

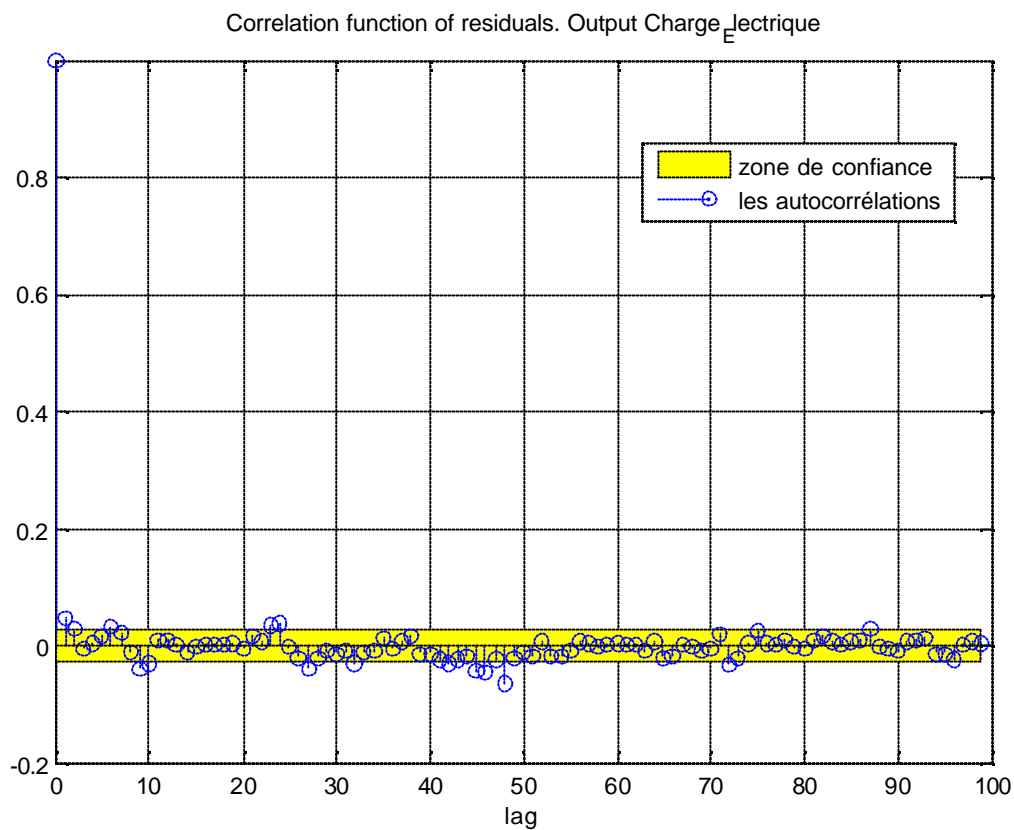


Figure 4.9 La fonction des corrélations des résidus.

Les figures 4.10 et 4.11 présentent la variation de la charge électrique estimée par le modèle maintenu (avec 23 paramètres AR et 24 paramètres MA) avec les valeurs réelles pour la semaine du 03 au 09 janvier 2004 et pour la semaine du 07 au 13 Août 2004 respectivement. On voit clairement que la prédiction suit les variations réelles de la charge électrique Algérienne.

Sur les figures 4.12 et 4.13, on a rétabli les changements qui ont été fait sur la charge électrique Algérienne. Ces figures présentent une comparaison entre les valeurs prédites et les valeurs réelles.




Figure 4.10 Les valeurs de la charge électrique Algérienne prédites et réelles pour la période du 03 au 09 Janvier 2004.

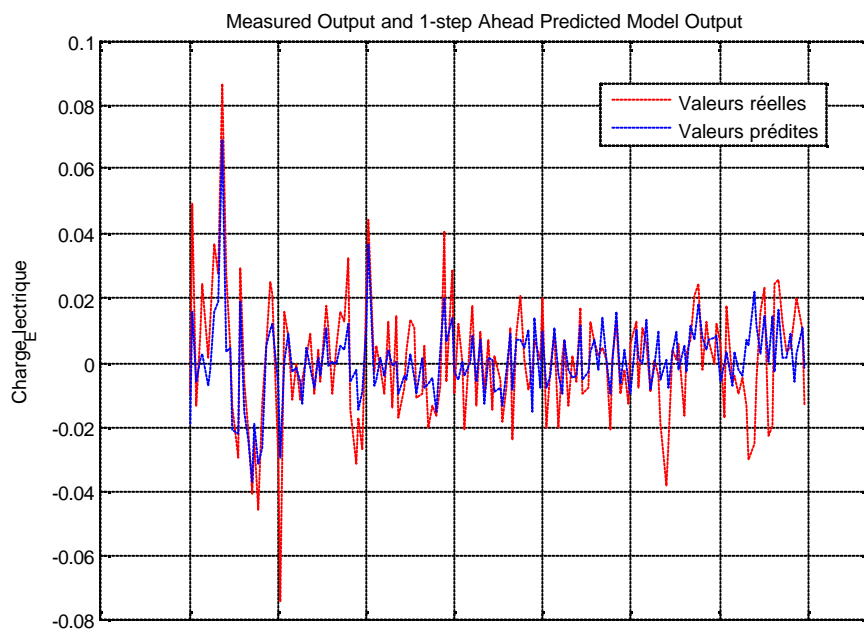


Figure 4.11 Les valeurs de la charge électrique Algérienne prédites et réelles pour la période du 07 au 13 Août 2004.




Figure 4.12 Les valeurs de la charge électrique Algérienne prédites et réelles
 Sur l'échelle réelle pour la période du 03 au 09 Janvier 2004.




Figure 4.13 Les valeurs de la charge électrique Algérienne prédites et réelles
 Sur l'échelle réelle pour la période du 07 au 13 Août 2004.

Le modèle final de Box-Jenkins est celui donné par l'équation (4.2) avec :

$$A(q) = 1 - 0.1123 q^{-1} + 0.005082 q^{-2} + 0.03951 q^{-3} + 0.008115 q^{-4} + 0.01623 q^{-5} - 0.01305 q^{-6} + 0.02892 q^{-7} + 0.06585 q^{-8} + 0.08972 q^{-9} + 0.06825 q^{-10} + 0.06424 q^{-11} + 0.07983 q^{-12} + 0.05717 q^{-13} + 0.04041 q^{-14} + 0.05151 q^{-15} + 0.02371 q^{-16} - 0.0005408 q^{-17} - 0.003692 q^{-18} + 0.01453 q^{-19} + 0.01267 q^{-20} + 0.0245 q^{-21} + 0.00828 q^{-22} - 0.04059 q^{-23}. \quad (4.6)$$

$$C(q) = 1 + 0.01552 q^{-1} - 0.04337 q^{-2} - 0.03856 q^{-3} - 0.03171 q^{-4} - 0.02308 q^{-5} - 0.02542 q^{-6} - 0.01752 q^{-7} - 0.009587 q^{-8} - 0.0008382 q^{-9} + 0.004574 q^{-10} + 0.01996 q^{-11} + 0.03351 q^{-12} + 0.02093 q^{-13} - 0.003247 q^{-14} - 0.004803 q^{-15} - 0.01515 q^{-16} - 0.02619 q^{-17} - 0.02459 q^{-18} - 0.01243 q^{-19} - 0.01455 q^{-20} - 0.01163 q^{-21} - 0.02806 q^{-22} - 0.0101 q^{-23} - 0.7354 q^{-24}. \quad (4.7)$$

3.2 Modélisation par les Réseaux de Neurones Artificiels

Les Réseaux de Neurones Artificiels sont des approximateurs de fonctions. Ils sont considérés comme des boîtes noires paramétrable, dans le but de trouver un lien entre les entrées et les sorties à travers un échantillon de données durant la phase d'apprentissage.

Dans ce projet, les Réseaux de Neurones Artificiels sont appliqués pour trois approches de modélisations. Pour les trois cas, on utilise des paramètres similaires. On parle du type de réseau, de la fonction d'activation et de la règle d'apprentissage.

Le type de réseau utilisé est un Perceptron Multi Couches (MLP), ce type de réseau est un outil fiable pour les problèmes d'approximation de fonctions. Le choix des entrées se fait à l'aide de la corrélation qui existe entre les données. La fonction d'activation utilisée pour activer les neurones des couches cachées est la fonction sigmoïdale. La fonction fournit des valeurs des sorties appartenant à l'intervalle $[0,1]$. Pour les neurones de la couche de sortie, la fonction d'activation est de type linéaire. La procédure utilisée pour la phase d'apprentissage est la procédure de correction de l'erreur (Rétro Propagation de l'erreur). Le principe est facile, on procède à la propagation de l'erreur calculée par le réseau de la couche de sortie vers la couche d'entrée. L'algorithme utilisé pour la mise à jour des poids est celui de

Levenberg-Marquardt. Son principe se base sur une minimisation de fonction. Il calcule une fonction de coût, sur laquelle il décide si la mise à jour sera acceptée ou non. Il continue le calcul jusqu'à la stabilité du réseau. Le calcul se fait à l'aide de la jacobéenne des poids et des biais. La méthode de Levenberg-Marquardt modifie les paramètres selon l'équation suivante:

$$\mathbf{q}_k = \mathbf{q}_{k-1} - [\mathbf{H}_{k-1} + \mathbf{I}_{k-1} \mathbf{I}]^{-1} \nabla J_{k-1} \quad (4.8)$$

Avec \mathbf{I} matrice identité

Les données utilisées pour la modélisation de la charge électrique sont normalisées. On a pris une des étapes de la méthode Box-Jenkins, celle où on élimine la tendance en terme de variance par le logarithme et celle de la moyenne par la soustraction de la moyenne de la série.

La validation des modèles est faite par le calcul de l'erreur quadratique moyenne donné par l'équation suivante :

$$e = \frac{1}{N} \sum (y_e - y_r)^2 \quad (4.9)$$

Avec N nombre de valeur.

y_e valeur estimée

y_r valeur réelle.

3.2.1. Prédiction à 1 pas en avant

On utilise ici un MLP avec une seule sortie qui présente la prédiction à 1 seul pas en avant. Pour ce réseau on a utilisé 08 entrées les plus dépendantes entre elles dans le passé des valeurs de la charge électrique Algérienne comme le montre le tableau 4.5 et la figure 4.14.

Tableau 4.5 Les entrées du Réseau de Neurones Artificiels appliqué pour la prédiction d'un seul pas en avant.

Entrée	Charge Electrique.
1	La charge à l'heure précédente.
2	La charge à l'heure avant la précédente.
3	La charge d'hier pour la même heure.
4	La charge d'hier pour l' heure précédente.
5	La charge d'hier pour l' heure avant la précédente.
6	La charge de la semaine passée du même jour et même heure.
7	La charge de la semaine passée du même jour et l'heure précédente.
8	La charge de la semaine passée du même jour et l'heure avant la précédente.

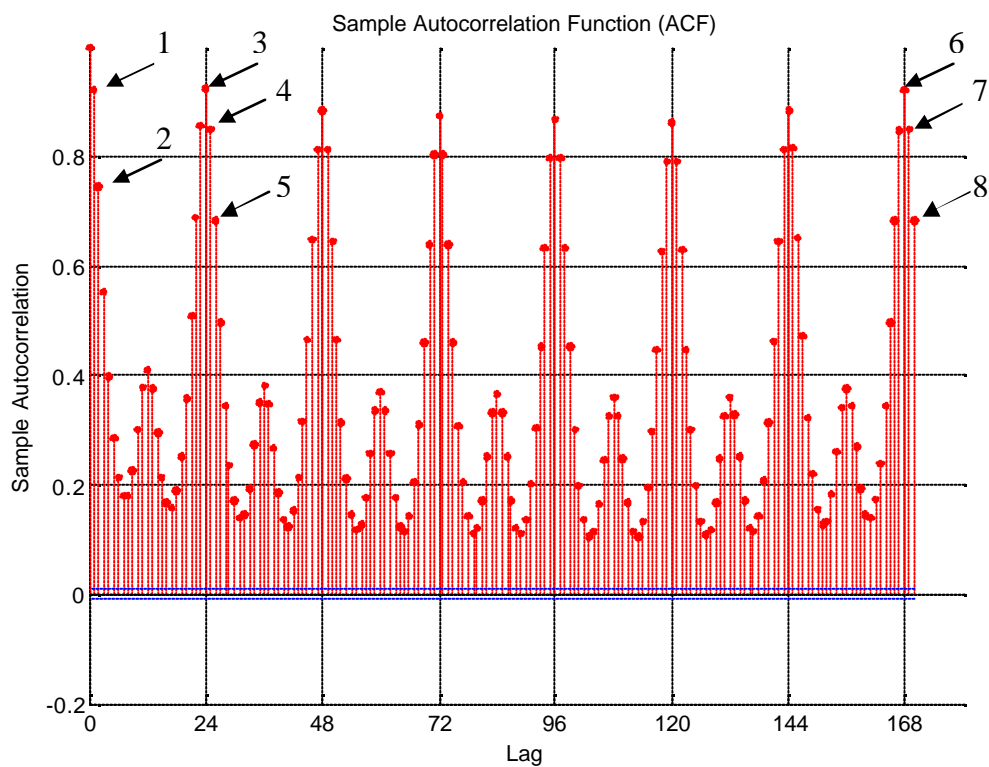


Figure 4.14 Les auto-corrélations des entrées du Réseau de Neurones Artificiels appliqué pour la prédiction d'un seul pas en avant.

Pour l'utilisation du réseau, on a pris, parmi l'échantillon d'apprentissage, les valeurs de l'année 2003 entière. 05 mois de données de l'année 2004 sont consacrés pour la validation. Afin de mieux valider le modèle, on n'a pas pris les mois consécutifs, dans le but d'avoir un échantillon englobant les 04 saisons de l'année. Les mois choisis sont : Janvier, Avril, Juin, Aout et Octobre.

Après plusieurs essais sur l'architecture en utilisant une seule couche cachée ensuite deux couches cachées, on a eu plusieurs architectures où l'erreur d'apprentissage et de validation converge vers une même valeur. Le tableau 4.6 présente les architectures jugées intéressantes avec leurs erreurs de validation.

Tableau 4.6 Les erreurs de prédiction d'un pas en avant.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur x 10⁻³
[8 8 1]	8	-	0,27423
[8 10 1]	10	-	0,27334
[8 11 1]	11	-	0,25393
[8 12 1]	12	-	0,26586
[8 16 1]	16	-	0,26139
[8 17 1]	17	-	0,25091
[8 8 10 1]	8	10	0,25865
[8 8 12 1]	8	12	0,27098
[8 8 14 1]	8	14	0,24993
[8 9 14 1]	9	14	0,27847

L'observation des résultats sur le tableau 4.6 montre que l'architecture [8 8 14 1] présente la plus basse erreur vis-à-vis des autres architectures. Pour ce réseau, la variation de l'erreur d'apprentissage et de validation est schématisée dans les figures 4.15 et 4.16.




Figure 4.15 Variation des erreurs d'apprentissage et de validation pour la prédiction d'un pas en avant de la charge électrique Algérienne .




Figure 4.16 Variation des erreurs d'apprentissage et de validation sur une échelle logarithmique pour la prédiction d'un pas en avant de la charge électrique Algérienne .




Figure 4.17 Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle normalisée pour la période du 03 au 09 Janvier 2004.




Figure 4.18 Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle normalisée pour la période du 07 au 13 Août 2004.

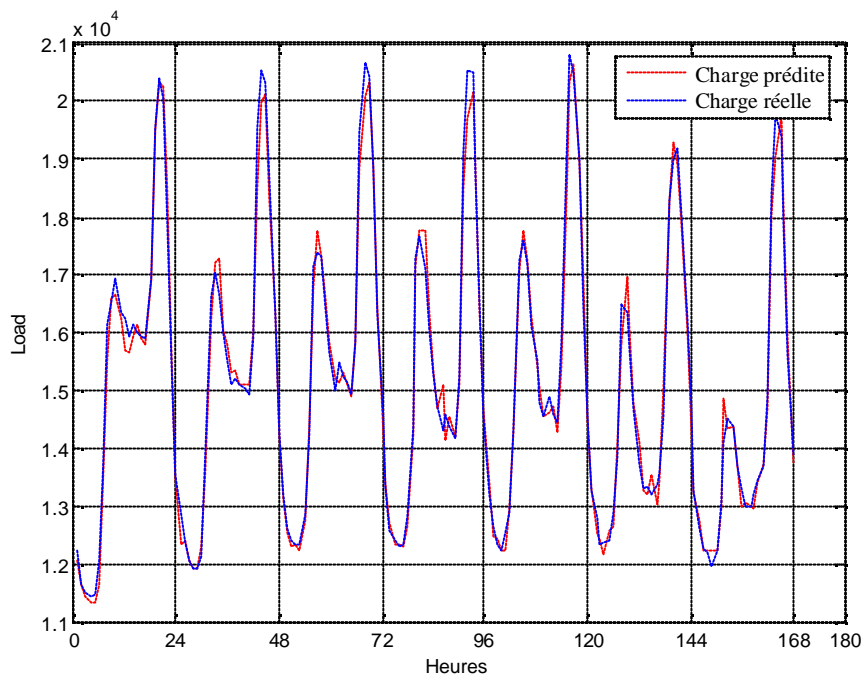


Figure 4.19 Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle réelle pour la période du 03 au 09 Janvier 2004.

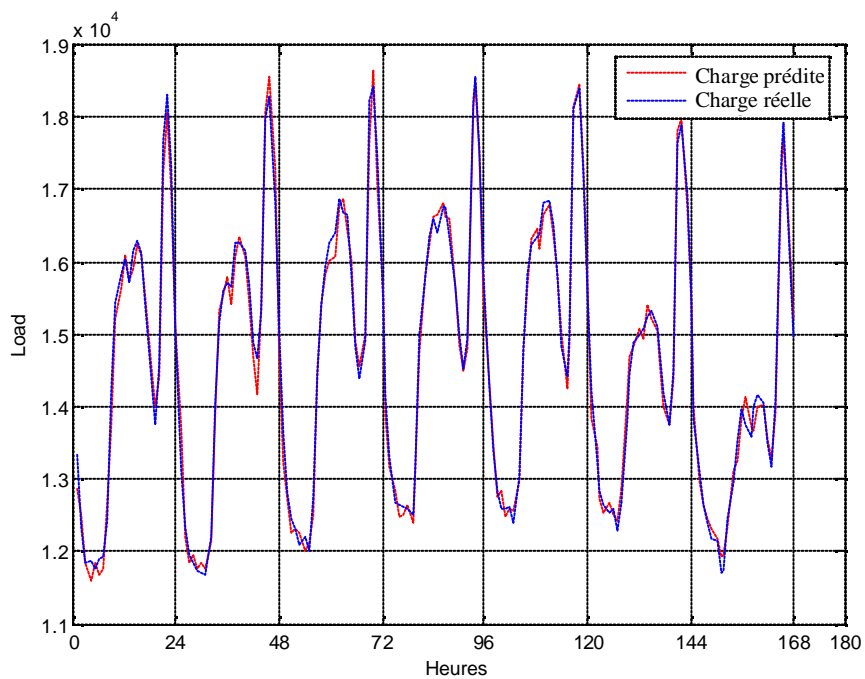


Figure 4.20 Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle réelle pour la période du 07 au 13 Août 2004.

Les variations de la charge électrique prédite et celle réelle sont mentionnées dans les figures 4.17, 4.18, 4.19 et 4.20. On voit clairement que les valeurs de la charge électrique Algérienne prédites par le modèle suivent la variation réelle, quelque soit la saison.

3.2.2. Prédiction à 24 pas en avant avec 24 sorties

On utilise ici un MLP avec 24 sorties qui présentent la prédiction des 24 pas en avant. Pour ce réseau on a utilisé les 08 entrées ainsi que les mêmes échantillons d'apprentissage et de validation que pour le réseau utilisé pour prédire 1 seul pas en avant. Comme on a 24 sorties, on calcule pour chaque sortie son erreur. Ensuite, on calculera la moyenne des erreurs.

Les essais sur l'architecture en utilisant une seule couche cachée ensuite deux couches cachées, sont résumés sur le tableau 4.7.

Tableau 4.7 Les erreurs moyennes de prédictions de 24 pas en avant.

architecture	Nombre de neurones dans la première couche cachée	Nombre de neurones dans la deuxième couche cachée	L'erreur
[8 8 24]	8	-	0,0123
[8 10 24]	10	-	0,0124
[8 11 24]	11	-	0,0117
[8 12 24]	12	-	0,0112
[8 16 24]	16	-	0,0110
[8 17 24]	17	-	0,0107
[8 8 10 24]	8	10	0,0107
[8 8 12 24]	8	12	0,0103
[8 8 14 24]	8	14	0,0103
[8 9 14 24]	9	14	0,0105

Les deux architectures [8 8 12 24] et [8 8 14 24] présentent la même erreur. Cette erreur est la plus basse par rapport aux autres architectures. Le tableau 4.8 montre les erreurs des deux architectures pour chaque pas. Le tableau démontre que le réseau [8 8 14 24] présente des basses erreurs sur la majorité des pas. Par conséquent, ce sera l'architecture choisie pour la prédiction en 24 pas en avant pour la charge électrique Algérienne.

Tableau 4.8 Comparaison des erreurs pour chaque pas obtenu par les deux architectures [8 8 12 24] et [8 8 14 24]

Les pas	L'architecture [8 8 12 24]	L'architecture [8 8 14 24]
1	0,0008	0,0006
2	0,0020	0,0019
3	0,0059	0,0058
4	0,0095	0,0093
5	0,0104	0,0103
6	0,0102	0,0102
7	0,0109	0,0108
8	0,0123	0,0124
9	0,0144	0,0146
10	0,0161	0,0163
11	0,0163	0,0159
12	0,0147	0,0142
13	0,0128	0,0126
14	0,0117	0,0121
15	0,0126	0,0131
16	0,0144	0,0147
17	0,0151	0,0152
18	0,0151	0,0150
19	0,0134	0,0133
20	0,0100	0,0098
21	0,0067	0,0065
22	0,0045	0,0044
23	0,0039	0,0037
24	0,0039	0,0035
Moyenne	0,0103	0,0103

Ce qui peut être aussi tiré du tableau 4.8 est que l'erreur augmente dès le deuxième pas. Cette erreur est considérée grande du 08^{ème} pas jusqu'au 19^{ème} pas. La variation de la charge électrique prédite et celle réelle sont mentionné dans les figures 4.21, 4.22, 4.23 et 4.24. Ces courbes démontrent la différence dans la période où l'erreur est grande.




Figure 4.21 Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle normalisée pour la journée du 03 Janvier 2004.




Figure 4.22 Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle normalisée pour la journée du 07 Août 2004.




Figure 4.23 Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle réelle pour la journée du 03 Janvier 2004.




Figure 4.24 Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle réelle pour la journée du 07 Août 2004.

3.2.3. Prédiction à 24 pas en avant avec 24 modèles

On utilise ici 24 réseaux MLP avec une seule sortie qui présente la prédiction à 1 seul pas en avant pour chaque heure de la journée. Les entrées de chaque réseau dépendent des corrélations entre les valeurs. Les courbes de corrélation montrent des variations de corrélation similaires pour quelques heures de la journée. Les fonctions d'auto-corrélations simples pour chaque heure sont regroupées en annexe 01. Le tableau 4.9 montre chaque heure et ses entrées.

Tableau 4.9 Les entrées pour les 24 modèles utilisés pour la prédiction

Les heures	Nombre d'entrées	Les entrées
1 - 6 , 22 - 24	05	1 - 4 , 7
8 - 17	04	1 - 3 , 7
7 , 18 - 21	08	1 - 8

Les données horaires de la charge électrique Algérienne sont divisées en 24 échantillons, un pour chaque heure. Comme résultat, on aura 24 classes de 1827 valeurs. Pour garder un bon rapport entre les données d'apprentissage et de validation, l'année 2004 est attribuée pour la validation. Les deux années 2002 et 2003 forment l'échantillon d'apprentissage.

Après plusieurs essais sur l'architecture en utilisant une seule couche cachée ensuite deux couches cachées, on a eu plusieurs architectures où l'erreur d'apprentissage et de validation converge vers une même valeur. Les architectures des essais avec leurs erreurs pour chaque heure sont résumées dans l'annexe 02. Le tableau 4.10 présente l'architecture maintenue et son erreur de validation pour chaque heure.

Tableau 4.10 Les erreurs de prédiction pour chaque heure de la journée

Heure	Architecture	Erreur x 10 ⁻³
1	[5 8 13 1]	1,1188
2	[5 8 11 1]	1,1896
3	[5 5 11 1]	0,8655
4	[5 9 11 1]	0,9726
5	[5 7 8 1]	1,1151
6	[5 5 11 1]	1,1319
7	[8 9 10 1]	1,5334
8	[4 5 1]	2,5348
9	[4 9 1]	2,2178
10	[4 5 1]	2,5352
11	[4 7 1]	2,7144
12	[4 5 10 1]	3,0419
13	[4 7 8 1]	3,7173
14	[4 5 1]	4,1420
15	[4 5 6 1]	4,3197
16	[4 5 1]	3,8861
17	[4 6 1]	3,5658
18	[8 11 13 1]	3,2920
19	[8 10 17 1]	2,0602
20	[8 12 18 1]	1,9285
21	[8 11 13 1]	1,5565
22	[5 9 10 1]	0,9915
23	[5 9 14 1]	1,1990
24	[5 8 11 1]	1,2604

La variation de la charge électrique prédite et celle réelle sont mentionnées dans les figures 4.25, 4.26, 4.27 et 4.28. Ce qui peut être repéré sur les figures est que les variations sont les mêmes sur l'échelle normalisé ou l'échelle réelle. Donc la normalisation n'a pas d'influence sur les valeurs de la charge électrique Algérienne. Le modèle a donné des résultats acceptables vu qu'on ne repère pas des différences majeures entre les valeurs prédites et réelles.




Figure 4.25 Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle normalisée pour la journée du 03 Janvier 2004.




Figure 4.26 Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle normalisée pour la journée du 07 Août 2004.




Figure 4.27 Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle réelle pour la journée du 03 Janvier 2004.




Figure 4.28 Les valeurs de la charge électrique Algérienne prédites et réelles sur une échelle réelle pour la journée du 07 Août 2004.

3.3. Comparaison entre les modèles de prédiction de la Charge Electrique Algérienne

Après avoir appliqué la méthode Box-Jenkins et les Réseaux de Neurones Artificiels sur la charge électrique Algérienne, les résultats obtenus sont jugés acceptables. On a eu 04 modèles au total.

Les figures 4.29 et 4.30 présentent les variations des valeurs des prédictions un pas en avant du modèle Box-Jenkins et du Réseau de Neurones Artificiels. Elles sont comparées avec les valeurs réelles. En observant les figures, on voit clairement que les Réseaux de Neurones Artificiels présentent des résultats meilleurs que ceux obtenus par la méthode Box-Jenkins.




Figure 4.29 Comparaison entre les valeurs réelles et prédites par Box-Jenkins et les Réseaux de Neurones Artificiels de la charge électrique Algérienne pour la journée du 03 Janvier 2004.




Figure 4.30 Comparaison entre les valeurs réelles et prédites par Box-Jenkins et les Réseaux de Neurones Artificiels de la charge électrique Algérienne pour la journée du 07 Août 2004.

On a mentionné dans les paragraphes précédents que l'intérêt premier est d'avoir une prédiction à plusieurs pas en avant. Dans ce projet, on a utilisé un réseau de Neurones Artificiels avec 24 sorties qui représentent les pas de prédiction. Dans un second lieu, on a utilisé pour chaque heure un modèle de prédiction pour avoir les 24 pas en parallèle. Sur les figures 4.31 et 4.32, une comparaison des deux modèles avec les valeurs réelles est schématisée. La technique qui utilise un modèle pour chaque heure a donné de bons résultats par rapport à celle qui utilise un seul modèle avec 24 sorties.




Figure 4.31 Comparaison entre les valeurs réelles et prédites en 24 pas en avance de la charge électrique Algérienne pour la journée du 03 Janvier 2004.




Figure 4.32 Comparaison entre les valeurs réelles et prédites en 24 pas en avance de la charge électrique Algérienne pour la journée du 07 Août 2004.

4. CONCLUSION

Dans ce chapitre, des modèles de prédiction sont appliqués sur la charge électrique Algérienne. La méthode Box-Jenkins est considérée comme une base de comparaison pour les autres méthodes. Dans ce contexte, elle a été appliquée pour prédire un seul pas en avant pour la charge électrique Algérienne. Les résultats sont comparés avec le modèle obtenu par l'application des Réseaux de Neurones Artificiels. Ce modèle a présenté des résultats acceptables, vu qu'il a donné les meilleures prédictions sur les données réelles.

Pour la prédiction de plusieurs pas en avant, deux méthodes sont utilisées dans ce projet. La première consiste à avoir les 24 pas en même temps sous forme d'un vecteur de sortie pour le Réseau de Neurones Artificiels. La seconde classe les données par heure et prédit chaque heure séparément. A la fin, 24 prédictions sont obtenues en parallèle. Cette dernière technique a présenté des résultats très intéressants.

Conclusion Générale

Conclusion générale

Au cours de ce travail, nous avons traité le problème de prédiction des séries temporelles. Nous avons commencé par introduire les séries temporelles avec leurs caractéristiques. Dans un second plan, nous avons présenté la charge électrique comme étant un exemple de séries temporelles. Nous avons aussi exposé quelques expériences de différent pays dans la prédiction de la charge électrique.

Les modèles de prédiction de la charge électrique se regroupent en général en deux classes ; Les méthodes statistiques et les méthodes de l'Intelligence Artificielle. Les modèles tirés de la méthode Box-Jenkins sont les plus utilisés dans le cas des modélisations statistiques. D'un autre côté, les Réseaux de Neurones Artificiels sont les plus répandus concernant la modélisation intelligente de la charge électrique.

Dans ce travail, ces deux techniques de modélisation sont appliquées pour la prédiction de la charge électrique Algérienne. La charge électrique dépend souvent du comportement des utilisateurs. Elle dépend aussi des changements climatiques de la région en

Conclusion générale

gestion. Pour cette raison, les chercheurs n'ont pas pu trouver un modèle général pour prédire la charge électrique. Chaque série dépend de l'étude faite sur ses valeurs, pour tirer les caractéristiques qui aident à mieux la modéliser.

Dans ce projet, une prédiction avec un seul pas en avant de la charge électrique Algérienne est réalisée ainsi qu'une prédiction en 24 pas en avant. Pour la prédiction en un pas en avant, les Réseaux de Neurones Artificiels ont donné de bons résultats par rapport au modèle basé sur la méthode Box-Jenkins.

Elargir le pas de la prédiction de la charge électrique est très important pour la bonne gestion de la ressource. Dans ce contexte, deux architectures sont appliquées sur les données. La première consiste à prédire directement un vecteur qui contient les 24 pas de prédiction. La seconde prédit chaque pas séparé des autres. C'est-à-dire modéliser chaque heure de la journée par un modèle différent. Cette dernière a donné des résultats très intéressants.

On a essayé d'appliquer des méthodes de prédiction pour la charge électrique Algérienne. Il reste encore du travail dans ce contexte afin d'améliorer les résultats obtenus. Cette amélioration peut être obtenue en développant les aspects suivants:

- Les données utilisées dans ce projet sont celles de la charge électrique uniquement. Il est plus intéressant d'ajouter à ces données d'autres facteurs comme par exemple les caractéristiques climatiques avec la température comme variable principale. On peut aussi faire une étude sur les facteurs qui influent sur la charge électrique et chercher les moyens pour les utiliser dans la modélisation.
- Pendant une année le climat change de l'été vers l'hiver et vice-versa. Une classification des données peut se faire pour que la modélisation se réalise par la suite selon les saisons.
- Une étude sur le type de journée est entrain de se finaliser. L'utilisation des résultats obtenus peut donner une amélioration dans les résultats de la modélisation.

Conclusion générale

- Etablir une étude sur la similitude des heures par une classification. Par la suite, utiliser les résultats pour prédire les heures similaires par le même modèle.

- Utiliser d'autres types de Réseaux de Neurones Artificiels comme les réseaux récurrents pour prédire plusieurs pas en avant en utilisant les prédictions des pas précédents.

- Utiliser d'autres techniques pour prédire la charge électrique à savoir les filtres de Kalman, les SVMs ou encore la logique floue.

Références Bibliographiques

Références Bibliographiques

- [1] D. Eilstein, H. Prouvost, P. Saviuc, C. Declercq, A Lefranc, S. Cassadou, A. Zeghnoun, A. Tertre, P. Quénel, M. D'Helf, C. Nunes, P. Fabre, L. Filleul, L. Pascal, J.F. Jusot, B Chardon et S. Médina, Séries temporelles et modèles de Regression Application à l'analyse des associations à court terme entre la pollution atmosphérique et la santé, Département santé-environnement, Institut de veille sanitaire, France, 2003.
- [2] S. Lechevalier, Une introduction à l'économétrie des séries temporelles, DEES 113, pp 45-51, Octobre 1998.
- [3] B.Rapacchi, Dur,dur!! Les séries chronologiques!! Centre Interuniversitaire de Calcul de Grenoble, Août 1993.
- [4] Y. Aragon, Introduction aux Séries temporelles, Centre Interuniversitaire de Calcul de Toulouse, Septembre 2004.
- [5] X. Luna, une approche non paramétrique et parcimonieuse de la prévision de séries temporelles, thèse de doctorat, Ecole Polytechnique Fédérale de Lausanne, 1996.

- [6] G. Chevillon, Pratique des séries temporelles. Centre de recherche en économie de Sciences Po, Janvier 2004.
- [7] T. Zheng, A.A. Girgis et E.B. Makram, A Hybrid Wavelet-Kalman Filter Method For Rorecasting, Electric Power Systems Research 54, pp 11-17, 2000.
- [8] A.S. Debs, Modern Power System Control and Operation, ISBN: 0-89838-265-3. Kluwer Academic, Boston, 1988.
- [9] A.D. Papalexopoulos et T.C. Hesterberg, A Regression-Based Approach to Short-Term System Load Forecasting, IEEE Transaction on power systems Vol 5, N° 4, pp 1535-1544, November 1990.
- [10] W. Bartkiewicz, Neuro-Fuzzy Approaches to Short-Term Electrical Load Forecasting, IEEE-INNS-ENNS International Joint Conference on Neural Network Vol 6, pp 6229-6234, 2000.
- [11] W. Dai et P. Wang, Application of Pattern Recognition and Artificial Neural Network to Load Forecasting in Electric Power System, IEEE Third International Conference on Natural Computation Vol 1, pp 381-385, 2007.
- [12] H. Yamina, S.M. Shahidehpour et Z. Li, Adaptive short-term electricity price forecasting using artificial neural networks in the restructured power markets, Electrical Power and Energy Systems 26, pp 571-581, 2004.
- [13] G. Li, C. Cheng, J. Lin et Y. Zeng, Short-Term Load Forecasting Using Support Vector Machine With SCE-UA Algorithm, IEEE Third International Conference on natural Computation Vol 1, pp 290-294, 2007.
- [14] N. Lertpalangsunti et C.W. Chan, An Architectural Framework For The Construction Of Hybrid Intelligent Forecasting Systems: Application For Electricity Demand Prediction, Engineering Applications of Artificial Intelligence 11, pp 549-556, 1998.
- [15] T. Senjyu, H. Takara et K. Uezato, Two-hour-ahead Load Forecasting Using A Neural Network, Bulletin of the Faculty of Engineering, University of the Ryukyus Vol 60, pp 61-68, 2000.

- [16] P.L. Lai, S.J. Chuang et C. Fyfe, Power Load Forecasting Using Neural Canonical Correlates, IEEE 15th International Conference on Pattern Recognition Vol 2, pp 2455-2458, 2000.
- [17] S.J. Chuang, C. Fyfe and R.C. Hwang, Power load forecasting by neural network with weights-limited training algorithm, European Simulation Symposium and Exhibition, ESS98, 1998.
- [18] S. Haykin, Neural Networks – A Comprehensive Foundation, Macmillan, 1994.
- [19] J.W. Taylor et R. Buizza, Neural Network load forecasting with weather ensemble predictions, IEEE Transactions on power systems Vol 17, N° 3, pp 626-632, Août 2002.
- [20] D. Fay, A strategy for short-term load forecasting in Ireland. These PhD Dublin City University, July 2004.
- [21] M.T. Yousef, Neural networks as a tool for load forecasting, proceedings, International Conference on Engineering Applications of Neural Networks, Cagliari, Italy, pp 144-148, July 2000.
- [22] V.S. Kodogiannis et E.M. Anagnostakis, A Study of Advanced Learning Algorithms for Short-term Load Forecasting, Engineering Applications of Artificial Intelligence 12, pp 159-173, 1999.
- [23] J. Xie, Y. Zhang et C. Wang, A Study and Implementation of an Intelligent Load Forecast Support System, IEEE Power system technology Vol 2, pp 858-862, 2002.
- [24] F.C. Joseph, Forecasting and Planning Today Plus or Minus Twenty Years, Technological Forecasting and Social change, pp 15-20, 1989.
- [25] S.E. Papadakis, J.B. Theocharis et A.G. Bakirtzis, A Load Curve Based Fuzzy Modeling technique For Short-Term Load Forecasting, Fuzzy Sets and Systems 135, pp 279-303, 2003.
- [26] Y. Rui et A.A. El-Keib, A Review of ANN-based Short-term Load Forecasting Models, IEEE 27th Southeastern Symposium on System Theory, pp 78-82, 1995.

- [27] M.Y. Cho, J.C. Hwang et C.S. Chen, Customer Short Term Load Forecasting By Using ARIMA Transfer Function Model, IEEE Energy Management and Power Delivery Vol 1, pp 317-322, 1995.
- [28] D. Srtnivasan, A.C. Liew et J.S.P. Chen, A Novel Approach To Electrical Load Forecasting Based On A Neural Network, IEEE Neural Networks Vol 2, pp 1172-1177, 1991.
- [29] H.T. Yang, C.M. Huang et C.L. Hung, Identification of ARMAX Model for Short Term System Load Forecasting : An Evolutionary Programming Approach, IEEE Power Industry Computer Application Conference, pp 325-330, 1995.
- [30] O.A.S. Carpinteiro, A.P.A. Dasilva et C.H.L. Feichas, A Hierarchical Neural Model in Short-Term Load Forecasting, IEEE-INNS-ENNS International Joint Conference on Neural Networks Vol 6, pp 6241-6246, 2000.
- [31] A. Khotanzad, A. R.H. Abaye et D. Maratukulam, IEEE Power System Vol 10, pp 1716-1722, Août 1995
- [32] K. Jabour, J.F.V. Riveros et D. Landsbergen, ALFA : Automated load forecasting assistant, IEEE Transactions PWS 3, pp 908-914, 1988.
- [33] O.A.S. Carpinteiro et A.P.A. Dasilva, A Hierarchical Neural Model in Short-Term Load Forecasting, the VI Brazilian Symposium on Neural Networks, pp 120-124, 2000.
- [34] H. Mori, State of the art overview on artificial neural networks in power systems El-Sharkawi et Niebur edition, pp 51-70, 1996.
- [35] P.K. Dash, A.C. Liew, S. Rahman et S. Dash, Fuzzy and Neuro-fuzzy Computing Models for Electric Load Forecasting, Engineering Applications of Artificial Intelligence Vol. 8, N° 4, pp 423-433, Août 1995.
- [36] D.K. Ranaweera, N.F. Hubele et G.G. Karady, Fuzzy Logic Term Load Forecasting, Electrical Power & Energy Systems Vol. 18, No. 4, pp 215-222, 1996.
- [37] Y. Zhu et Y. He, Short-Term Load Forecasting Model Using Fuzzy C Means Based Radial Basis Function Network, IEEE 6th International Conference on intelligent Systems Design and Applications Vol 1, pp 579-582, 2006.

- [38] W. Charytoniuk et M.S. Chen, Neural Network design for Short-Term Load Forecasting, Proceeding of International Conference on Electric Utility Deregulation and restructuring and Power Technologies, London, pp 554-561, 2000.
- [39] Z.Y. Dong, B.L. Zhang et Q. Huang, Adaptive neural network short term load forecasting with wavelet decompositions, IEEE Porto Power Tech Conference Vol 2, pp 1-6, 2001.
- [40] A.A. El-Keib, X. Ma et H. Ma, Advancement of statistical based Modeling Techniques For Short-Term Load Forecasting, Electric power systems Research 35, pp 51-58, 1995.
- [41] D.C. Hill et D.G. Infield, Modelled Operation of The Shetland Islands Power System Comparing Computational and Human Operators Load Forecasts, IEE Generation, transmission and distribution Vol 142, N° 6, pp 555-679, November 1995.
- [42] S.J. Huang et K.R. Shih, Short-Term Load Forecasting Via Machine ARMA Model Identification Including Non-Gaussian Process Considerations, IEEE Transactions on Power Systems Vol 18, N° 2, Mai 2003.
- [43] S.J. Kiartzis, A.G. Bakirtzis et V. Petridis, Short-Term Load Forecasting Using Neural Networks, Electric power systems Research 33, pp 1-6, 1995.
- [44] T.W.S. Chow et C.T. Leung, Nonlinear Autoregressive Integrated Neural Networks Model for Short-Term Load Forecasting, IEEE Generation, Transmission and Distribution Vol. 143, N° 5, pp 500-506, September 1996.
- [45] E.A. Mohamed, M.M. Mansour, S. El-Debeiky et K.G. Mohamed, Egyptian Unified Grid Hourly Load Forecasting Artificial Using Neural Networks, Electric Power & Energy Systems Vol 20, N° 7, pp 495-500, 1998.
- [46] A.G. Darbellay et M. Slama, Forecasting The Short-Term Demand For Electricity, International Journal of Forecasting 16, pp 71-83, 2000.
- [47] E.A. Mohamed, M.M. Mansour, S. El-Debeiky, K.G. Mohamed et N.D. Rao, Results of Egyptian Unified Grid Hourly Load Forecasting Using An Artificial Using Neural Networks With Expert System Interface, Electric power systems Research 39, pp 171-177, 1996.

- [48] C.C. Chiu et L.J. Kao, Combining a Neural Networks With Rule-Based Expert System Approach for Short-Term Load Forecasting in, Expert systems with Applications Vol. 13, N° 4, pp 299-305, 1997.
- [49] S.J. Huang et C.L Huang, Genetic-based Multilayered for Taiwan power system Short-Term Load Forecasting, Electric power systems Research 38, pp 69-74, 1996.
- [50] D. Srinivasan, Evolving Artificial Neural Networks for Short Term Load Forecasting, Neurocomputing 23, pp 265-276, 1998.
- [51] F. Liu, Q. Song et R.D. Findlay, Accurate 24-hour-ahead Load Forecasting Using Similar Hourly Loads, IEEE Computational Intelligence for Modelling, Control and Automation, pp 249-254, Novembre 2006.
- [52] A. Oonsivilai et M.E El-Hawary, , Wavelet Neural Network Based Short Term Load Forecasting of Electric Power System Commercial Load, IEEE Canadian Conference On Electrical and computer Engineering Shaw Conference Center, pp 1223-1228, 1999.
- [53] S.J. Yao, Y.H. Song, L.Z. Zhang et X.Y. Cheng, Wavelet Transform and Neural Network for Short-Term Electrical Load Forecasting, Energy Conversion & Management 41, pp 1975-1989, 2000.
- [54] D. Tao, W. Xiuli et W. Xifan, A Combined Model Of Wavelet And Neural Network for Short-Term Load Forecasting, IEEE Power System Technology Vol 4, pp 2331-2335, 2002.
- [55] M. Tamimi et R. Egbert, Short Term Electric Load Forecasting Via Fuzzy Neural Collaboration, Electric power systems Research 56, pp 243-248, 2000.
- [56] S. Kiartzis, A. Kehagias, A. Bakirtzis et V. Petridis, Short Term Load Forecasting Using a Bayesian Combination Method, Electric Power & Energy Systems Vol 19, N° 3, pp 171-177, 1997.
- [57] C. Yin, L. Kang et W. Sun, Hybrid Neural Network Model for Short-Term Load Forecasting, IEEE 3rd International conference on natural computation Vol 1, pp 408-412, 2007.

- [58] M. Zhou, Z. Yan et Y. Ni, An ARIMA approach to forecasting electricity price with accuracy improvement by predicted errors, IEEE Power Engineering Society General Meeting Vol 1, pp 233-238, 2004.
- [59] E. César et B. Richard, Les Séries Temporelles, Université de Versailles Saint-Quentin-en-Yvelines, Mars 2006.
- [60] D. delignières, Séries temporelles-Modèles ARIMA, Séminaire EA "Sport-Performance-Santé", pp 1-19, Mars 2000.
- [61] A. Papoulis., Probability, Random Variables, and Stochastic Processes, 3rd edition. Singapore: McGraw Hill International, 1991.
- [62] G.E.P. Box et G.M. Jenkins, Time Series Analysis: Forecasting and Control, San Francisco: Holden Day, 1970.
- [63] J. Contreras, R. Espinola, F.J. Nogale et A.J. Conejo, ARIMA models to predict next day electricity prices, IEEE Transactions on Power Systems Vol 18, N° 3, Août 2003.
- [64] Gourieroux et Monfort, Séries temporelles et modèles dynamiques, Economica Paris, 1995.
- [65] B. Bowerman et R.T. O'Connell, Time series forecasting unified concepts and computer implementations, Duxbury press, 1987.
- [66] A.C. Harvey, Time Series Analysis, Hertfordshire UK: Philip Allan, 1981.
- [67] A. Zenide, Un modèle factoriel dynamique pour série temporelles, these doctorat, Ecole polytechnique fédérale de Lausanne, 2004.
- [68] S. Avouyi-Dovi et D. Guegan, Valeurs extrêmes et séries temporelles : application à la finance, Centre d'étude des politiques économiques de l'université d'Evry, 2001.
- [69] P.J. Brockwell et R.A. Davis, Time Series: Theory and Methods, New York USA: Springer Verlag Inc, 1987.
- [70] S. Ng et P. Perron, A note on the selection of time series models, technical report Boston College Department of Economics, Juin 2001.
- [71] H. Akaike, A new look at the statistical model identification, IEEE transaction on automatic control, AC19, pp716-723, 1974.

- [72] H. Abdi et D. Valentin, Modèles Neuronaux Connexionnistes et Numériques pour la Mémoire des Visages, *It Psychologie Française* 39(4), pp 357-392, 1994.
- [73] S. Yessaadi, Un modèle basé Template Matching/ Réseau de Neurones pour la Reconnaissance des visages, thèse de magistère, 2006.
- [74] C. Touzet, *Les Réseaux de Neurones Artificiels*, 1992.
- [75] M.A. Arbib, *The Hand Book of Brain Theory and Neural Networks*, 2nd edition, 2002.
- [76] Y.H. Hu et J.N. Hwang, *Introduction to neural Networks for Signal Processing, Handbook of Neural Network Signal Processing*, CRC Press LLC, 2002.
- [77] A.K. Jain, J. Mao et K.M Muhiuddin, *Artificial Neural Networks: A tutorial*, IEEE, pp.31-44, March 1996.
- [78] M.T. Khadir, *Les Réseaux de Neurones Artificiels*, 2005.
- [79] D.S. Neelakanta et D. Degroff, *Neural Network Modeling: Statical Mechanics and Cybernetic Perspectives*, CRC Press, CRC Press LLC, 1994.
- [80] J.C. Principe, *Artificial Neural Networks*, *The Electrical Engineering Handbook* Eds. Richard C. Dorf Boca Raton: CRC Press LLC, 2000.
- [81] R.P. Wurtz, *Neural Theories and Technical Systems for Face Recognition*, European symposium on artificial neural networks ESANN'97 N°5, Belgique, pp 73-78, April 1997.
- [82] L.P.J. Vealenturf, *Analysis and Applications of Artificial Neural Networks*, Book Prntice Hall Edition, 1995.
- [83] V. ANDRONOVA, *Utilisation de données météo et des réseaux de neurones pour la prédiction de vitesses de vent*, thèse de master, Juillet 2006.
- [84] H. Abdi, *Neural Network*, M. Lewis-Beck, A. Bryman et T. Futing (Eds.), *Encyclopedia of Social Sciences Research Methods*, Thousand Oaks (CA): Sage , 2003.
- [85] H. Abdi, *Précis de Connexionnisme, Intelligence Artificielle et Intelligence Naturelle*, Paris : Presse Universitaires de France in J. P Rossi, J. F Le Ny, J. F (Eds.), 1993.
- [86] G. Dreyfus, *Les Réseaux de Neurones, Mécanique Industrielle et Matériaux*, No.51, septembre 1998.

- [87] P. Dayan et L.F0 Abbott, Theoretical Neuroscience, 2000.
- [88] L. Fausett, fundamentals of Neural Networks Architectures, Algorithms and Applications, Addison Wesley, Publishing Company, Inc, 1991.
- [89] G. Dreyfus, J-M. Martinez, M. Samuelides et M.B. Gordon, Réseaux de Neurones Méthodologies et Application, S. Thiria, L Herault (Eds.), Groupe Eyrolles, 2004.
- [90] J.A. Freeman et D.M. Shapriua, Neural Networks: algorithms, Application and Programing Techniques, Book, Addison Wesley Publishing Company, INC, 1991.
- [91] Z. Szlávik, T. Szirányi, Face Identification with CNN-UM, 2003.
- [92] F. Rosenblatt, The Perceptron : probabilistic model for information storage and organization in the brain. Psychological Review 65, pp 386-408, 1958.
- [93] M.I. Jordan, Serial OPrder: A Parallel Distributed Processing Approach, San Diego, la Jolla, CA: Institute for Cognitive Science, University of California, 1986.
- [94] J.L. Elman, Finding structure in time. Cognitive Science 14, pp 179-211, 1990.
- [95] J-F. Jodouin, Les réseaux neuromimétriques, Editions Hermès, Paris, 1994.
- [96] W.S. Sarle, Neural Networks and Statical Models, Proceedings of The Nineteenth Annual SAS Users Group International conference, April 1994.
- [97] C. Touzet, Les Réseaux de Neurones Artificiels, 1992.
- [98] R. Magali, G. Meireles, E. Paulo, M. Almeida et M.G. Simeoes, A Comprehensive Review for industrial Applicability of Artificial Neural Networks, IEEE Transactions on Industrial Electronics Vol 50 N° 3, pp 585-601, 2003.

Annexe 01

Les fonctions d'auto-corrélations simples de toutes les heures de la charge électrique Algérienne.

Annexe 01




Figure 4.33 La fonction d'auto-corrélations simples de l'heure 1 de la charge électrique Algérienne




Figure 4.34 La fonction d'auto-corrélations simples de l'heure 2 de la charge électrique Algérienne




Figure 4.35 La fonction d'auto-corrélations simples de l'heure 3 de la charge électrique Algérienne




Figure 4.36 La fonction d'auto-corrélations simples de l'heure 4 de la charge électrique Algérienne




Figure 4.37 La fonction d'auto-corrélations simples de l'heure 5 de la charge électrique Algérienne




Figure 4.38 La fonction d'auto-corrélations simples de l'heure 6 de la charge électrique Algérienne




Figure 4.39 La fonction d'auto-corrélations simples de l'heure 7 de la charge électrique Algérienne




Figure 4.40 La fonction d'auto-corrélations simples de l'heure 8 de la charge électrique Algérienne




Figure 4.41 La fonction d'auto-corrélations simples de l'heure 9 de la charge électrique Algérienne




Figure 4.42 La fonction d'auto-corrélations simples de l'heure 10 de la charge électrique Algérienne




Figure 4.43 La fonction d'auto-corrélations simples de l'heure 11 de la charge électrique Algérienne




Figure 4.44 La fonction d'auto-corrélations simples de l'heure 12 de la charge électrique Algérienne




Figure 4.45 La fonction d'auto-corrélations simples de l'heure 13 de la charge électrique Algérienne




Figure 4.46 La fonction d'auto-corrélations simples de l'heure 14 de la charge électrique Algérienne




Figure 4.47 La fonction d'auto-corrélations simples de l'heure 15 de la charge électrique Algérienne




Figure 4.48 La fonction d'auto-corrélations simples de l'heure 16 de la charge électrique Algérienne




Figure 4.49 La fonction d'auto-corrélations simples de l'heure 17 de la charge électrique Algérienne




Figure 4.50 La fonction d'auto-corrélations simples de l'heure 18 de la charge électrique Algérienne




Figure 4.51 La fonction d'auto-corrélations simples de l'heure 19 de la charge électrique Algérienne




Figure 4.52 La fonction d'auto-corrélations simples de l'heure 20 de la charge électrique Algérienne




Figure 4.53 La fonction d'auto-corrélations simples de l'heure 21 de la charge électrique Algérienne




Figure 4.54 La fonction d'auto-corrélations simples de l'heure 22 de la charge électrique Algérienne




Figure 4.55 La fonction d'auto-corrélations simples de l'heure 23 de la charge électrique Algérienne




Figure 4.56 La fonction d'auto-corrélations simples de l'heure 24 de la charge électrique Algérienne

Annexe 02

Les erreurs de prédiction obtenues pour chaque heure de la charge électrique Algérienne.

Annexe 02

Tableau 4.11 Les erreurs de prédictions pour l'heure 1.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[5]	5	-	0,0011468
[8]	8	-	0,0011434
[9]	9	-	0,0012558
[10]	10	-	0,0012225
[11]	11	-	0,0011365
[12]	12	-	0,0011575
[7 9]	7	9	0,0011599
[8 11]	8	11	0,0012619
[8 13]	8	13	0,0011188

Tableau 4.12 Les erreurs de prédictions pour l'heure 2.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[11]	11	-	0,001202
[14]	14	-	0,0012012
[8 11]	8	11	0,0011896
[6 9]	6	9	0,001285

Tableau 4.13 Les erreurs de prédictions pour l'heure 3.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[13]	13	-	0,0011196
[5 20]	5	20	0,00088887
[5 17]	5	17	0,0011667
[5 11]	5	11	0,00086557
[7 11]	7	11	0,00091577

Tableau 4.14 Les erreurs de prédictions pour l'heure 4.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[9 11]	9	11	0,0009726
[9 12]	9	12	0,0010105
[9 17]	5	17	0,00097755

Tableau 4.15 Les erreurs de prédictions pour l'heure 5.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[7 8]	7	8	0,0011151
[11 20]	11	20	0,0018058

Tableau 4.16 Les erreurs de prédictions pour l'heure 6.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[5 7]	5	7	0,0011582
[8 4]	8	4	0,0011319
[6 8]	6	8	0,0013902
[8 18]	8	18	0,001161

Tableau 4.17 Les erreurs de prédictions pour l'heure 7.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[9 10]	9	10	0,0015334
[10 17]	10	17	0,001584
[13 16]	13	16	0,001584

Tableau 4.18 Les erreurs de prédictions pour l'heure 8.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[5]	5	-	0,0025348
[6]	6	-	0,0032891
[5 7]	5	7	0,0028361
[6 12]	6	12	0,00298
[7 10]	7	10	0,0031168
[7 11]	7	11	0,003104
[7 12]	7	12	0,0029202

Tableau 4.19 Les erreurs de prédictions pour l'heure 9.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[5]	5	-	0,0024222
[7]	7	-	0,0024276
[5 7]	5	7	0,0024088
[6 8]	6	8	0,0026023
[7 14]	7	14	0,023914

Tableau 4.20 Les erreurs de prédictions pour l'heure 10.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[5]	5	-	0,0025352
[9]	9	-	0,0025704
[7 14]	7	14	0,0025954
[8 11]	8	11	0,0027675

Tableau 4.21 Les erreurs de prédictions pour l'heure 11.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[5]	5	-	0,0028743
[7]	7	-	0,0027144
[5 7]	5	7	0,0030974
[5 10]	5	10	0,0031766
[6 8]	6	8	0,0028043
[6 12]	6	12	0,0030398
[7 10]	7	10	0,0028443
[7 12]	7	12	0,0030883
[8 14]	8	14	0,0028927

Tableau 4.22 Les erreurs de prédictions pour l'heure 12.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[5 6]	5	6	0,0032338
[5 10]	5	10	0,0030419
[6 8]	6	8	0,0032747
[6 10]	6	10	0,0034827
[7 12]	7	12	0,0033505
[7 13]	7	13	0,0038983
[8 16]	8	16	0,0036995

Tableau 4.23 Les erreurs de prédictions pour l'heure 13.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[5 6]	5	6	0,0038109
[6 4]	6	4	0,004363
[7 8]	7	8	0,0037173
[8 9]	8	9	0,0042354

Tableau 4.24 Les erreurs de prédictions pour l'heure 14.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[5]	5	-	0,004142
[5 6]	5	6	0,0042648
[6 9]	6	9	0,0043635
[7 9]	7	9	0,0045745
[7 11]	7	11	0,0042741
[7 14]	7	14	0,0046549

Tableau 4.25 Les erreurs de prédictions pour l'heure 15.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[4]	4	-	0,004382
[5 6]	5	6	0,0043197
[7 9]	7	8	0,0050787
[7 13]	7	13	0,0078315

Tableau 4.26 Les erreurs de prédictions pour l'heure 16.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[4]	4	-	0,0040348
[5]	6	-	0,0038861
[6]	6	-	0,0039052
[9]	9	-	0,0039854
[5 7]	5	7	0,0040426
[5 8]	5	8	0,0043074
[6 10]	6	10	0,0041025

Tableau 4.27 Les erreurs de prédictions pour l'heure 17.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[4]	4	-	0,0036261
[6]	6	-	0,0035658
[5 6]	5	6	0,0037785
[5 7]	5	7	0,0037114
[5 9]	5	9	0,0038028
[6 8]	6	8	0,0037633
[7 9]	7	9	0,0045428

Tableau 4.28 Les erreurs de prédictions pour l'heure 18.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[11 13]	11	13	0,003292

Tableau 4.29 Les erreurs de prédictions pour l'heure 19.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[10]	10	-	0,0023501
[10 17]	10	17	0,0020602
[10 18]	10	18	0,0034519
[12 20]	12	20	0,0028611

Tableau 4.30 Les erreurs de prédictions pour l'heure 20.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[9 10]	9	10	0,0031598
[9 17]	9	17	0,0034713
[9 18]	9	18	0,0042739
[10 14]	10	14	0,0037385
[10 16]	10	16	0,011814
[11 16]	11	16	0,0027524
[12 18]	12	18	0,0019285
[12 19]	12	19	0,0033246
[14 15]	14	15	0,0024318
[15 20]	15	20	0,0060971
[16 20]	16	20	0,0024521

Tableau 4.31 Les erreurs de prédictions pour l'heure 21.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[9 15]	9	15	0,0025605
[10 12]	10	12	0,0052601
[11 13]	11	13	0,0015565
[11 16]	11	16	0,0018653
[11 19]	11	19	0,0021142
[12 14]	12	14	0,0025487

Tableau 4.32 Les erreurs de prédictions pour l'heure 22.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[7 13]	7	13	0,0011158
[9 10]	9	10	0,0099156
[10 20]	10	20	0,001115
[10 18]	10	18	0,0010752
[10 17]	10	17	0,0010774

Tableau 4.33 Les erreurs de prédictions pour l'heure 23.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[9 14]	9	14	0,001199
[9 11]	9	11	0,0012133
[6 8]	6	8	0,0014383

Tableau 4.34 Les erreurs de prédictions pour l'heure 24.

Architecture	Nombre de neurone dans la première couche cachée	Nombre de neurone dans la deuxième couche cachée	L'erreur
[8]	8	-	0,0013502
[6 12]	6	12	0,001471
[8 9]	8	9	0,0014671
[8 11]	8	11	0,0012604
[9 10]	9	10	0,0014029
[9 11]	9	11	0,0014171
[9 18]	9	18	0,0013268
[10 12]	10	12	0,0017245
[10 14]	10	14	0,0013791
[10 15]	10	25	0,0013962
[10 20]	10	20	0,001362

Résumé

Les compagnies de gestion électrique ont besoin d'une prédiction à court terme de la demande de la charge électrique afin de programmer les installations de sa production. Les erreurs de prédiction peuvent mener à des risques et insuffisances dans la génération et distribution de la quantité de la charge électrique vers les utilisateurs.

Les recherches dans cet axe sont nombreuses. Plusieurs pays ont abouti à modéliser la série représentant la variation de leur charge électrique. Ces recherches se basent sur plusieurs approches telles que les modèles Box-Jenkins, les Réseaux de Neurones Artificiels, le filtre de Kalman, etc. Mais la méthode Box-Jenkins et les Réseaux de Neurones Artificiels restent les plus répandues.

Ce travail s'inscrit dans le cadre de la prédiction des séries temporelles, Plus particulièrement, la prédiction de la charge électrique. Des techniques sont appliquées pour prédire la charge électrique Algérienne.

Quatre modèles sont proposés dans le cadre de ce travail. Les deux premiers se focalisent sur la prédiction d'un seul pas en avant. Un modèle se base sur la méthode Box-Jenkins qui représente dans la littérature la base de comparaison de toutes autres techniques. Les résultats obtenus par cette méthode sont comparés avec ceux obtenus par un modèle Réseau de Neurones Artificiels de type Perceptron Multi Couches.

Généralement, un seul pas est insuffisant pour bien fonder la gestion de la ressource. Sur cette base, il est plus intéressant de chercher une prédiction à plusieurs pas en avant. Dans ce contexte, deux modèles sont proposés. Le premier modèle fournit un vecteur de 24 valeurs comme sortie du Réseau de Neurones Artificiels représentant les 24 pas de prédiction. Les résultats sont comparés avec les résultats du deuxième modèle qui consiste à classer les données en 24 classes selon l'heure. Par la suite, on prédit chaque heure séparément pour obtenir 24 prédictions reflétant les 24 pas.

Mots clés : Série Temporelle – Charge Electrique – Box-Jenkins – Réseau de Neurones Artificiels – Perceptron Multi Couches – Prédiction.