



République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la
Recherche Scientifique



Université 20 août 1955 -Skikda -

Faculté des sciences

Département informatique

Mémoire de projet fin d'étude en vue de
l'obtention d'un diplôme de master en
informatique

Spécialité : Réseaux et systèmes distribuées

Thème :

**La prédiction de la consommation de l'Energie
électrique cas d'étude : sociétés nationale Sonelgaz.**

Réalisé par :

- **DJIDJA RANYA**
- **HILA HADIL**

Encadré par :

DR.Benoudina Lazhar

2024-2025

Remerciment

Nous remercions avant tout **ALLAH**, qui nous a donné la force, la patience et la détermination nécessaires pour mener à bien ce travail.

Nous exprimons notre profonde gratitude à notre encadrant, **Mr. BenoudinaLazhar**, pour son accompagnement, sa disponibilité et ses conseils précieux tout au long de cette année. Son soutien a été essentiel à la réussite de ce projet.

Nos sincères remerciements vont également à l'ensemble des enseignants du département d'informatique, dont les enseignements et l'encadrement ont largement contribué à notre formation.

Nous adressons aussi notre reconnaissance aux membres du jury pour avoir accepté d'évaluer notre travail et pour leurs remarques constructives.

Enfin, nous remercions chaleureusement toutes les personnes qui, de près ou de loin, nous ont apporté leur aide et leur soutien tout au long de ce travail.



Dédicace

Je dédie ce travail :

*À mes chers parents, qui ont toujours été
mon soutien et mon*

*Appui tout au long de mes années
d'études.*

*A mes Très chers frères : Housseem et
Mohamed.*

*A ma très chère sœur Ferial
Et toute la famille Djidja.*

*Je dédie aussi ce travail ... Aux
Personnes qui m'ont encouragé, qui
Etaient toujours à mes côtés.*

A mon cher binôme

Ranya



Dédicace

Je dédie ce travail :

A mes chers parents,

*Pour tous leurs sacrifices, leur amour,
leur tendresse et leur soutien tout au
long de mes études,*

A mes frères Raouf Yahya Akram

*, A tous ma famille Hila pour leur
appui et leur encouragement*

*A tous ceux qui j'aimes qui m'ont
encouragé, qui étaient toujours à mes
côtés.*

A mon cher binôme.

*Merci atouts d'être toujours là pour
moi.*

Hadil

Résumé :

La production et la consommation d'énergie électrique jouent un rôle crucial sur les plans économique et environnemental. Assurer un équilibre entre l'offre et la demande est essentiel pour optimiser la gestion de l'électricité. La prévision mensuelle de la consommation d'énergie devient ainsi un enjeu majeur pour la planification de la production et de la distribution.

Divers outils de prédiction ont été développés pour anticiper la quantité d'énergie nécessaire. Parmi eux, les approches basées sur les séries temporelles sont largement utilisées. Dans ce travail, nous proposons une méthode reposant sur l'apprentissage automatique, en particulier les réseaux de neurones artificiels, afin d'améliorer la précision des prévisions de la consommation mensuelle d'électricité.

Mots clés : Énergie électrique, séries temporelles, réseaux de neurones artificiels.

Abstract :

The production and consumption of electrical energy play a crucial role in both economic and environmental aspects. Ensuring a balance between supply and demand is essential for optimizing electricity management. Monthly energy consumption forecasting thus becomes a major challenge for planning production and distribution.

Various prediction tools have been developed to anticipate the required amount of energy. Among them, time series-based approaches are widely used. In this work, we propose a method based on machine learning, specifically artificial neural networks, to improve the accuracy of monthly electricity consumption forecasts.

Keywords: Electrical energy, time series, artificial neural networks.

ملخص

تلعب إنتاج واستهلاك الطاقة الكهربائية دورًا حاسمًا من الناحيتين الاقتصادية والبيئية. لذلك، يُعد تحقيق التوازن بين العرض والطلب أمرًا ضروريًا لتحسين إدارة الكهرباء. ومن هنا تبرز أهمية التنبؤ بالاستهلاك الشهري للطاقة الكهربائية لضمان تخطيط فعال لإنتاج الكهرباء وتوزيعها.

تم تطوير العديد من أدوات التنبؤ للتوقع المسبق لكمية الطاقة المطلوبة، ومن بين هذه الأدوات، تحظى الأساليب القائمة على السلاسل الزمنية باهتمام كبير. في هذا العمل، نقترح منهجية تعتمد على التعلم الآلي، وتحديدًا الشبكات العصبية الاصطناعية، بهدف تحسين دقة التنبؤ باستهلاك الكهرباء الشهري.

الكلمات المفتاحية: الطاقة الكهربائية، السلاسل الزمنية، الشبكات العصبية الاصطناعية.

SOMMAIRE :

Introduction Général	1
Chapitre 1 : L'énergie Electrique	
1.1 Introduction :.....	5
1.2 Définition de l'énergie électrique :	5
1.3 Les sources et les types d'énergie :	5
1.3.1 Les sources d'énergie renouvelable :	5
1.3.2. Les sources d'énergie non renouvelable:	7
1.3.3 Les énergies dérivées de sources non renouvelables :	8
1.4 Le fonctionnement du réseau électrique :	8
1.5 Méthodes de Production de l'Énergie Électrique :.....	9
1.5.1 Méthodes Traditionnelles :.....	9
1.5.2 Méthodes Renouvelables :	9
1.6 Définition consommation d'énergie électrique :.....	10
1.6.1 La consommation d'énergie mondial	11
1.6.2 La consommation d'énergie électrique national :.....	12
1.7 les Secteurs de la consommation d'énergie électrique :.....	12
1.8 Facteurs de la consommation d'énergie électrique :	13
1.9 L'importance de la rationalisation de la consommation d'énergie:.....	14
1.10 la société nationale d'électricité et de gaz (SONELGAZ-SKIKDA) :.....	15
1.10.1 Description SONELGAZ :.....	15
1.10.2 Filiales et participation du groupe Sonelgaz:.....	16
1.11 Les étapes de la production, du transport de l'énergie électrique :	17
1.11.1 La production d'énergie électrique :.....	17
1.11.2 Le transport de l'énergie électrique :.....	17
1.11.2.1. Les lignes électriques	17
1.11.2.2. Les lignes aériennes	18
1.11.3. La distribution de l'énergie électrique :.....	18
1.12 Conclusion :	18
Chapitre 2 : L'intelligence artificielle et la prédiction	
2.1. Introduction :.....	20
2.2 Concepts sur la prédiction :	20
2.2. 1 Définition d'une prévision :	20
2.2.2 Horizon de la prévision :	20
2.3 les méthodes de prévision :.....	21

2.3.1 Les Méthodes déterministes de prévision :.....	21
2.3.2 Méthodes probabilistes de prévision :	22
2.3.3 Méthodes d'intelligence artificielle pour la Prédiction de la Consommation Électrique :	22
2.4 les modèles de la prévision :.....	23
2.5. Neurone :.....	25
2.5.1. Neurone biologique :.....	25
2.5.2 Neurones formels :.....	26
2.6 Les fonctions d'activation :	28
2.7 Les réseaux de neurones artificiels (Artificiel Neural Networks ANN) :	29
2.9 Différents types de réseaux de neurones artificiels :	31
2.9.1 Réseaux non bouclés (Feed-Forward) :.....	31
2.9.1.1 Perceptron Monocouche ELM (Single-Layer Perceptron - SLP):	32
2.9.1.2 Perceptron Multi Couche (PMC) :	33
2.9.1.3 Le réseau de neurones à fonctions radiales de base (RBF) :.....	34
2.9.2 Réseau bouclés (Feed-Back) :.....	35
2.9.2.1 Les Cartes Auto-Organisatrices de Kohonen (Réseaux Kohonen) :.....	36
2.9.2.2 Les Réseaux de HopField :.....	36
2.9.2.3 Les Réseaux ART (Adaptive Résonance Theory) :.....	37
2.9.2.4 Le modèle Adaline :.....	37
2.10 Avantages et inconvénients des réseaux de neurones :[32].....	38
2.11 Conclusion :	39

Chapitre 3 : Analyse et conception

3.1 Introduction :.....	41
3.2. Étude comparative entre les deux techniques de prédiction de la Consommation d'énergie électrique :.....	41
3.2.1 Méthodes d'Apprentissage Automatique :	41
3.2.2 Méthodes Traditionnelles (Modèles Statistiques) :.....	42
3.4 Algorithme d'apprentissage :.....	44
3.4.1 Algorithme du gradient :.....	44
3.4.2 L'algorithme de rétro-propagation du gradient :	46
3.5 Avantages et inconvénients des techniques de prédiction:.....	51
3.5.1 La Régression :.....	51
3.5.2 Perceptron Multi Couche (PMC) :	51
3.6 Les étapes de développement de modèle de prédiction :.....	52
3.7 Dataset :.....	53

3.8 Métriques d'évaluation pour les modèles de prédiction :.....	53
3.9 Conclusion :	55

Chapitre 4 : Implémentation et discussion des résultats

4.1. Introduction :.....	57
4.2. Environnement de travail et langage de programmation :.....	57
4.2.1 python :.....	57
4.2.2 Anaconda :	58
4.2.3 Les bibliothèques Python utilisées :.....	61
4.3 Programme Python pour les techniques de prédiction de la consommation :.....	63
Exemple de fichier CSV :.....	66
Explication du programme :	66
4.4 Les différentes courbes obtenus :.....	67
4.5 Discussion des résultats :.....	68
4.6 Conclusion :	69
Conclusion générale :.....	70
Bibliographie.....	71

Liste des figures :

Figure1.1 Sources de production d'électricité d'énergie	10
Figure1.2 Sources de central nucléaire.....	10
Figure1.3 les chiffres au-dessus des histogrammes sont en milliers de TWh de 1979 à 2019.....	11
Figure1.4 : Représentation graphique de l'évolution de la consommation Annuelle de l'énergie électrique en Algérie.....	12
Figure1.5 : Représentation graphique du groupe Sonelgaz.....	16
Figure2.1 : Types de prédiction	21
Figure 2.2 Les modèles de prévisions.....	23
Figure2.3 : Représentation graphique du Neurone biologique.....	26
Figure2.4 : Représentation graphique du Neurones formels.....	27
Figure2.5 : les courbes des fonctions d'activation.....	29
Figure2.6 : Architecture de base de ANN.....	30
Figure2.7 : Un réseau de neurone non bouclé.....	31
Figure2.8 : Structure d'un ELM(SLP).....	32
Figure2.9 : Exemple Structure d'un PMC.....	34
Figure2.10 : Architecteur du réseau RBF.....	35
Figure2.11 : un réseau de neurone boucle.....	35
Figure3.1 : Modèle de régression linéaire.....	43
Figure3.2 : Modèle de régression non linéaire.....	44
Figure3.3 : organigramme de l'algorithme du gardien.....	46
Figure 3.4 : Exemple de réseau MLP à une couche cachée avec 4 entrées, 3 neurones.....	47
Figure 3.5 : Organigramme de l'algorithme de rétro-propagation du gradient.	50
Figure3.6 : étapes de la prévision a laide de modelés d'apprentissage automatique.....	52
Figure 4.1 : Logo de Python.....	58
Figure 4.2 : La fenêtre d'accueil de l'environnement anaconda.....	59
Figure 4.3 : Logo du langage Jupyter.....	59
Figure 4.4 : Fenêtre d'accueil de l'application jupyter.....	60

Figure 4.5:Fenêtre d'exécution des programmes python.....60

Liste des tableaux:

Tableau 2.1 : Les caractéristiques du réseau de neurones artificiels30

Tableau 2.2 : Avantages et inconvénients des réseaux de neurones.....38

Introduction Général

L'électricité est l'une des découvertes les plus marquantes de l'histoire de l'humanité. Elle a joué un rôle essentiel dans le développement de tous les domaines de la vie, en stimulant la créativité et en améliorant la qualité de vie. Son utilisation s'est répandue dans les usines, les entreprises, les foyers et les établissements d'enseignement, apportant des avancées majeures. En réduisant le temps et les efforts nécessaires à de nombreuses tâches, elle a considérablement facilité le quotidien. Cette importance croissante a entraîné une forte augmentation de la demande en électricité.

Les entreprises de production d'électricité rencontrent des difficultés à estimer la demande des consommateurs afin d'éviter le gaspillage, car l'électricité est une énergie difficile à stocker et se dissipe avec le temps. De plus, étant une énergie secondaire, sa production dépend d'autres sources comme l'énergie thermique, hydraulique et éolienne.

La consommation d'énergie constitue un enjeu majeur ayant un impact significatif sur l'économie, l'environnement et la société. L'augmentation constante de la demande énergétique impose l'adoption de stratégies plus efficaces et durables pour sa gestion. Dans cette optique, l'intelligence artificielle (IA) et l'apprentissage automatique (ML) se sont révélés être des outils prometteurs en proposant des approches innovantes pour l'analyse et la prévision de la consommation énergétique.

Dans ce contexte, notre mémoire vise à proposer un système de prédiction de la consommation d'énergie électrique dans la Wilaya de Skikda (Collo). Ce système repose sur l'utilisation des réseaux de neurones artificiels, une branche essentielle de l'intelligence artificielle.

Il convient de souligner que la prévision de la consommation électrique joue un rôle clé et efficace dans l'élaboration des plans futurs de la Société Algérienne de Distribution de l'Électricité et du Gaz, « Sonelgaz ». Elle permet également de développer des stratégies adaptées et d'assurer une prise de décision opportune et éclairée.


Dans le premier chapitre, nous avons pu voir les principaux concepts concernant l'énergie, ses utilisations, ses types et son importance dans les divers secteurs et sa consommation en Algérie, ainsi que sa rationalisation, cette énergie étant l'une des principales ressources nécessaires pour notre vie quotidienne. Enfin, nous avons terminé notre travail par une conclusion.

Le deuxième chapitre est dédié à une présentation des réseaux de neurones artificiels et la prédiction.

Le troisième chapitre est consacré à l'analyse et à la conception de notre future application. Nous présentons ainsi les détails de l'architecture proposée et les techniques utilisées.

Le quatrième chapitre est dédié à l'implémentation et la réalisation de la proposition de notre système.

Enfin, le mémoire se termine par une conclusion générale et perspectives.



Chapitre 1:

L'énergie électrique

1.1 Introduction :

L'énergie, et en particulier l'énergie électrique, constitue l'un des fondements essentiels du développement de chaque nation, étant un moteur clé de l'économie mondiale. Elle joue également un rôle central dans la détermination du niveau de progrès ou de retard d'un pays. En conséquence, la demande en énergie électrique ne cesse d'augmenter, aussi bien de la part des ménages que des secteurs économiques. Ce chapitre propose d'abord une introduction aux concepts de base de l'énergie électrique et à ses diverses méthodes de production. Puis, nous analyserons les principaux secteurs consommateurs d'électricité afin de mieux comprendre l'évolution de cette consommation, tout en mettant en lumière les facteurs qui en expliquent les variations.

1.2 Définition de l'énergie électrique :

L'énergie électrique est une forme d'énergie qui résulte de la circulation des charges électriques, généralement sous forme de courant électrique, à travers un conducteur. Elle peut être utilisée pour alimenter des appareils ou pour être transformée en d'autres formes d'énergie, comme la lumière, la chaleur ou le mouvement. Une source d'énergie désigne toute matière ou phénomène naturel qui permet de produire de l'énergie. Cela peut être des ressources comme le soleil, le vent, l'eau, le pétrole, le charbon, ou encore des déchets organiques. Ces sources sont utilisées pour générer de l'électricité, de la chaleur, ou pour alimenter des machines.[1]

1.3 Les sources et les types d'énergie :

L'énergie peut être classée en différentes catégories en fonction de sa provenance et de la manière dont elle est produite. Les sources d'énergie sont généralement divisées en deux grands groupes : les énergies renouvelables et les énergies non renouvelables.

1.3.1 Les sources d'énergie renouvelable :

Les énergies renouvelables proviennent de ressources naturelles qui se renouvellent constamment, ce qui en fait des sources d'énergie durables et respectueuses de l'environnement. Les principales sources d'énergie renouvelable sont :

1.L'énergie solaire :

- **Source :** L'énergie solaire provient du rayonnement du soleil.
- **Technologies utilisées :** Les panneaux solaires photovoltaïques (qui convertissent la lumière en électricité) et les chauffe-eaux solaires (pour la production de chaleur).

- **Avantages** : Inépuisable, écologique et largement disponible.
- **Inconvénient** : Dépendante des conditions météorologiques et de l'heure du jour.

2.L'énergie éolienne :

- **Source** : L'énergie éolienne est générée par le vent qui fait tourner les pales des éoliennes.
- **Technologies utilisées** : Les éoliennes terrestres et offshore (en mer).
- **Avantages** : Source d'énergie propre et renouvelable.
- **Inconvénient** : Dépendante des conditions climatiques et géographiques.

3.L'énergie hydraulique :

- **Source** : L'énergie hydraulique provient de l'eau en mouvement, principalement des rivières et des barrages.
- **Technologies utilisées** : Les centrales hydroélectriques et les turbines sous-marines.
- **Avantages** : Source stable, prévisible et largement utilisée dans le monde entier.
- **Inconvénient** : Impact environnemental sur les écosystèmes aquatiques et la biodiversité.

4.La biomasse :

- **Source** : La biomasse provient de matières organiques comme les déchets agricoles, les résidus forestiers ou même les algues.
- **Technologies utilisées** : Les centrales de biomasse, les biocarburants et la méthanisation (production de biogaz).
- **Avantages** : Réduit les déchets, et peut être utilisée dans de nombreuses applications (chauffage, production d'électricité).
- **Inconvénient** : Peut entraîner une compétition avec les terres agricoles et avoir des effets sur la biodiversité.

5.La géothermie :

- **Source** : La géothermie utilise la chaleur interne de la Terre, provenant des profondeurs géologiques.
- **Technologies utilisées** : Les centrales géothermiques et les pompes à chaleur géothermiques.

- **Avantages** : Énergie fiable, stable, disponible 24h/24.
- **Inconvénient** : Géographiquement limitée à certaines régions où l'activité géothermique est intense.

6.L'hydrogène (dans certaines applications) :

- **Source** : L'hydrogène est une source d'énergie potentielle qui peut être produite à partir de l'eau (via l'électrolyse) ou de la biomasse.
- **Technologies utilisées** : Piles à hydrogène (pour les véhicules) et stockage d'hydrogène.
- **Avantages** : Zéro émission à l'utilisation, peut être produit de manière propre.
- **Inconvénient** : Coût de production élevé, infrastructures de stockage et de transport encore limitées.

1.3.2. Les sources d'énergie non renouvelable:

Les énergies non renouvelables proviennent de ressources naturelles limitées qui, une fois épuisées, ne peuvent pas être remplacées dans un délai humainement significatif. Les principales sources d'énergie non renouvelable sont :

1. L'énergie fossile :

- **Sources** : Pétrole, charbon et gaz naturel.
- **Technologies utilisées** : Centrales thermiques, moteurs à combustion interne, raffinage du pétrole, etc.
- **Avantages** : Fournit une grande quantité d'énergie de manière fiable et continue.
- **Inconvénient** : Contribue au changement climatique (émissions de CO₂), ressources limitées, pollution de l'air et de l'eau.

Sous-catégories :

- **Pétrole** : Utilisé pour la production d'électricité, les carburants (essence, diesel), et la pétrochimie.
- **Charbon** : Principalement utilisé pour la production d'électricité et dans certaines industries (acier).
- **Gaz naturel** : Utilisé pour la production d'électricité, le chauffage et comme carburant.

2.L'énergie nucléaire :

Source : L'énergie nucléaire provient de la fission des atomes d'uranium dans des réacteurs nucléaires.

Technologies utilisées : Centrales nucléaires et réacteurs à fission.

Avantages : Très grande production d'énergie à partir de petites quantités de combustible, faible émission de CO₂ pendant la production.

Inconvénient : Risques liés à la sécurité (accidents nucléaires), gestion des déchets radioactifs, coûts de démantèlement des centrales.

1.3.3 Les énergies dérivées de sources non renouvelables :

✚ **L'énergie géothermique d'origine fossile :** Dans certains cas, des ressources géothermiques sont exploitées pour leur chaleur sous forme de vapeur provenant de sources non renouvelables.

✚ **Les carburants synthétiques et les biocarburants :** Ces sources, souvent produites à partir de ressources fossiles ou de terres agricoles, peuvent être utilisées dans les transports, mais posent des défis en termes de durabilité et d'impact environnemental.

1.4 Le fonctionnement du réseau électrique :

Le réseau électrique est un système complexe permettant de transporter l'électricité depuis les sites de production jusqu'aux consommateurs. Il comprend plusieurs composants :

- ❖ **Les centrales de production :** Ce sont les sites où l'électricité est générée. Elles peuvent être thermiques, nucléaires ou renouvelables.
- ❖ **Les lignes de transmission :** Ces lignes haute tension transportent l'électricité à de grandes distances. L'électricité est transportée sous haute tension pour minimiser les pertes énergétiques durant le transport.
- ❖ **Les transformateurs :** Ils abaissent la tension pour adapter l'électricité aux besoins des consommateurs (résidentiels, industriels).[2]
- ❖ **Les lignes de distribution :** Ces lignes basse tension amènent l'électricité jusque dans les foyers et les entreprises.
- ❖ **Les compteurs :** Ils mesurent la quantité d'électricité utilisée par chaque consommateur.

1.5 Méthodes de Production de l'Énergie Électrique :

L'électricité peut être produite de différentes manières, en utilisant des sources d'énergie comme le charbon, le soleil, le vent ou l'eau. Voici un aperçu des principales méthodes utilisées pour produire de l'électricité.

1.5.1 Méthodes Traditionnelles :

- **Centrale à Charbon** : Brûle du charbon pour produire de la vapeur qui fait tourner une turbine. Polluante, mais produit de l'électricité en continu.
- **Centrale au Gaz Naturel** : Utilise le gaz pour produire de la vapeur. Moins polluante que le charbon, mais reste une source fossile.
- **Centrale Nucléaire** : Utilise la chaleur générée par la fission d'atomes d'uranium pour produire de la vapeur. Faible émission de CO₂, mais risque lié aux déchets radioactifs.

1.5.2 Méthodes Renouvelables :

- **Énergie Solaire** : Convertit la lumière du soleil en électricité via des panneaux solaires. Propre, mais dépend du soleil.[3]
- **Énergie Éolienne** : Utilise le vent pour faire tourner des turbines et produire de l'électricité. Propre, mais dépend du vent.[4]
- **Énergie Hydraulique** : Utilise la force de l'eau (barrages) pour produire de l'électricité. Stable et renouvelable, mais peut affecter l'environnement.



Figure1.1 Sources de production d'électricité d'énergie.[5]

Centrale nucléaire




Figure1.2 Sources de central nucléaire.[6]

1.6 Définition consommation d'énergie électrique :

Désigne l'ensemble des processus et des équipements qui utilisent l'électricité pour fonctionner, qu'il s'agisse de machines industrielles, de systèmes résidentiels (comme

les appareils électroménagers) ou d'infrastructures publiques (éclairage, transports, etc.). Cette consommation varie en fonction de divers facteurs comme :

- ✚ **La puissance des appareils** : Des équipements plus puissants consomment plus d'énergie.
- ✚ **La durée d'utilisation** : Plus un appareil fonctionne longtemps, plus il consomme d'énergie.
- ✚ **Le type de réseau** : L'efficacité des réseaux de distribution peut influencer la quantité d'énergie réellement consommé.[7]

1.6.1 La consommation d'énergie mondiale :

En % et en milliers de TWh

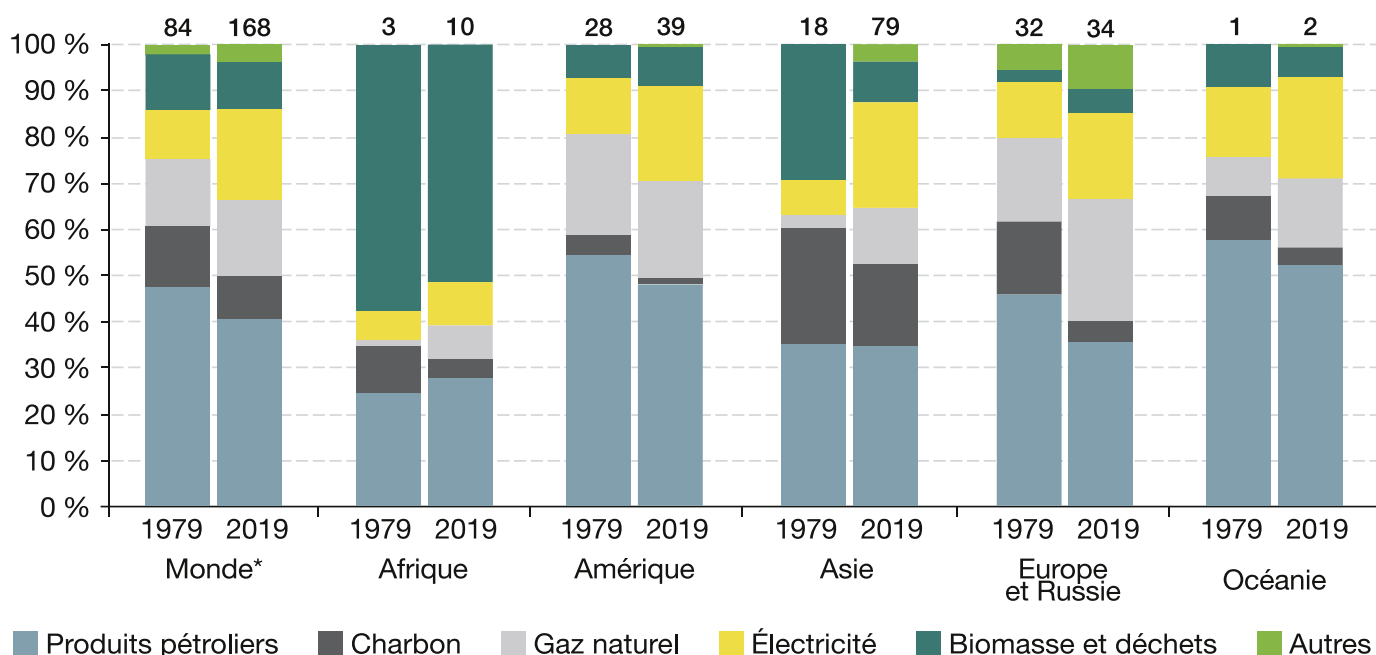


Figure 1.3 les chiffres au-dessus des histogrammes sont en milliers de TWh de 1979 à 2019.[8]

La part des produits pétroliers domine dans la consommation finale mondiale (40 %), en recul de 7 points par rapport à 1979. Celles du charbon et de la biomasse se sont aussi réduites, respectivement de 3 et 2 points **en 40 ans**, atteignant toutes les deux 10 % en 2019, alors que la part du gaz naturel est relativement stable (16 % en 2019). La part de l'électricité (dont 60 % est produite à partir de charbon et de gaz naturel en 2019) dans la consommation finale mondiale a fortement progressé en 40 ans, passant de 11 % à 20 %.

L'évolution du mix mondial dépend de la répartition géographique de la consommation, le poids de l'Asie passant notamment de 21 % à 47 % du total entre 1979 et 2019, ainsi que des disparités entre les mix continentaux. Les énergies fossiles représentent en 2019

environ deux tiers de la consommation finale sur tous les continents, à l'exception de l'Afrique où la biomasse est majoritaire (51 %). Le pétrole est partout la première énergie fossile. Tandis que l'Asie utilise beaucoup le charbon (18 %), l'Amérique et l'Europe ont davantage recours au gaz naturel (respectivement 21 % et 26 %). La part de l'électricité dans la consommation finale **en 2019** est similaire sur tous les continents (autour de 20 %), à l'exception de l'Afrique (10 %).

1.6.2 La consommation d'énergie électrique national :

La représentation graphique ci-dessus schématise l'évolution de la consommation Annule de l'énergie électrique en Algérie :




Figure1.4 : Représentation graphique de l'évolution de la consommation Annuelle de l'énergie électrique en Algérie.[9]

Le graphique met en évidence une hausse marquée de la consommation d'électricité à l'échelle nationale. Cette progression résulte de plusieurs facteurs, tels que l'amélioration des conditions de vie et la montée de la demande en électricité dans différents secteurs.

1.7 les Secteurs de la consommation d'énergie électrique :

L'énergie électrique est utilisée dans divers domaines en raison de la diversité de ses applications. Parmi les principaux secteurs de consommation, on distingue :

1. Le secteur résidentiel : L'électricité est fournie aux particuliers pour couvrir leurs besoins en éclairage, chauffage et alimentation des appareils électroménagers, contribuant ainsi au confort quotidien des foyers.

2. Le secteur des services publics : L'électricité est consommée dans divers Établissements tels que les bâtiments commerciaux, les hôpitaux et les Écoles, où elle est essentielle pour assurer le bon fonctionnement des Infrastructures et des services.

3. Le secteur agricole : L'énergie électrique est employée pour alimenter Divers équipements et machines agricoles, comme les pompes à eau et les Faucheuses, facilitant ainsi les activités agricoles.

4. Le secteur industriel : Ce secteur utilise l'électricité pour alimenter les Machines, équipements et systèmes nécessaires aux processus de Production dans les entreprises et les installations manufacturières.[10]

1.8 Facteurs de la consommation d'énergie électrique :

Les facteurs de consommation désignent les éléments ou conditions qui influencent la quantité d'énergie consommée, que ce soit pour l'électricité, le pétrole, le gaz ou d'autres sources d'énergie. Ces facteurs peuvent être :

1. **Croissance démographique :** L'augmentation de la population entraîne une hausse de la demande en énergie électrique, surtout dans les zones urbaines où les besoins énergétiques sont plus élevés.
2. **Développement économique :** La croissance économique génère une demande accrue en électricité, notamment dans les secteurs industriels, commerciaux et des services.
3. **Climat :** Les conditions climatiques affectent la consommation d'électricité, en particulier pour le chauffage en hiver et la climatisation en été.
4. **Technologies et équipements :** L'utilisation de nouveaux appareils électriques (électroménagers, véhicules électriques, etc.) augmente la demande d'électricité. Plus les technologies sont développées, plus la consommation peut être élevée.
5. **Efficacité énergétique :** Les progrès dans l'efficacité énergétique des équipements (par exemple, éclairage LED, appareils à faible consommation) peuvent réduire la consommation d'électricité.
6. **Prix de l'électricité :** Des prix plus bas peuvent encourager une consommation plus élevée, tandis que des prix élevés peuvent inciter les consommateurs à réduire leur utilisation ou à adopter des technologies plus efficaces.

7. **Politiques énergétiques** : Les incitations gouvernementales, telles que les subventions pour les énergies renouvelables ou les normes d'efficacité énergétique, peuvent influencer les niveaux de consommation.

8. **Infrastructures et réseau électrique** : L'efficacité du réseau de distribution et de production d'électricité (centrales, lignes de transmission, etc.) peut affecter l'offre disponible, influençant la consommation.

9. **Comportements et habitudes des consommateurs** : Les habitudes individuelles et collectives, comme l'utilisation d'appareils électriques ou la gestion de l'énergie domestique, ont un impact direct sur la consommation.

10. **Urbanisation** : Le développement des villes, avec une plus grande concentration d'activités humaines et de services, entraîne une demande plus élevée en électricité.[10]

1.9 L'importance de la rationalisation de la consommation d'énergie:

La gestion efficace de l'énergie est essentielle pour plusieurs raisons :

✚ **Améliorer la stabilité politique et sociale** : En limitant notre dépendance aux énergies fossiles importées et en investissant dans des solutions durables, nous renforçons notre autonomie énergétique, favorisons la création d'emplois et stimulons l'économie.[11]

✚ **Protéger l'environnement** : Une consommation énergétique excessive contribue aux Émissions de gaz à effet de serre, à la pollution et à la dégradation des écosystèmes. Une utilisation plus rationnelle de l'énergie permet de limiter ces impacts et de Préserver la biodiversité.[12]

✚ **Optimiser les coûts économiques** : L'énergie représente une part significative des dépenses des ménages et des entreprises. En adoptant des pratiques Écoénergétiques, nous réduisons nos factures et favorisons une gestion plus durable Des ressources financières.[13]

1.10 la société nationale d'électricité et de gaz (SONELGAZ-SKIKDA) :



1.10.1 Description SONELGAZ :

Sonelgaz, l'entreprise historique en Algérie, est responsable de la production, du transport et de la distribution de l'électricité et du gaz. Son champ d'action s'est élargi pour inclure la commercialisation de ces énergies à l'international. Suite à la loi régissant l'électricité et le gaz, Sonelgaz a été restructurée et est désormais un groupe industriel comportant 31 filiales et 9 sociétés partenaires, avec un effectif de plus de 56 500 employés. Son rôle essentiel dans le développement économique et social de l'Algérie se reflète à travers ses programmes d'électrification rurale et de distribution de gaz, qui ont permis d'atteindre une couverture électrique de près de 98 % et une pénétration du gaz de 40 %. L'entreprise vise à renforcer sa compétitivité et à rivaliser avec les meilleurs opérateurs du bassin méditerranéen. La Société de Distribution d'Électricité et du Gaz de l'Est (SDE) se charge de l'exploitation, de la maintenance et du développement des réseaux électriques et gaziers dans cette région, en veillant à une commercialisation optimale de ces services.[14]

Quelques dates importantes de Sonelgaz :

- **1947** : Création de l'entreprise **Électricité et Gaz d'Algérie (EGA)**.
- **1969** : Création de la **Société Nationale de l'Électricité et du Gaz (Sonelgaz)**.

1.10.2 Filiales et participation du groupe Sonelgaz:

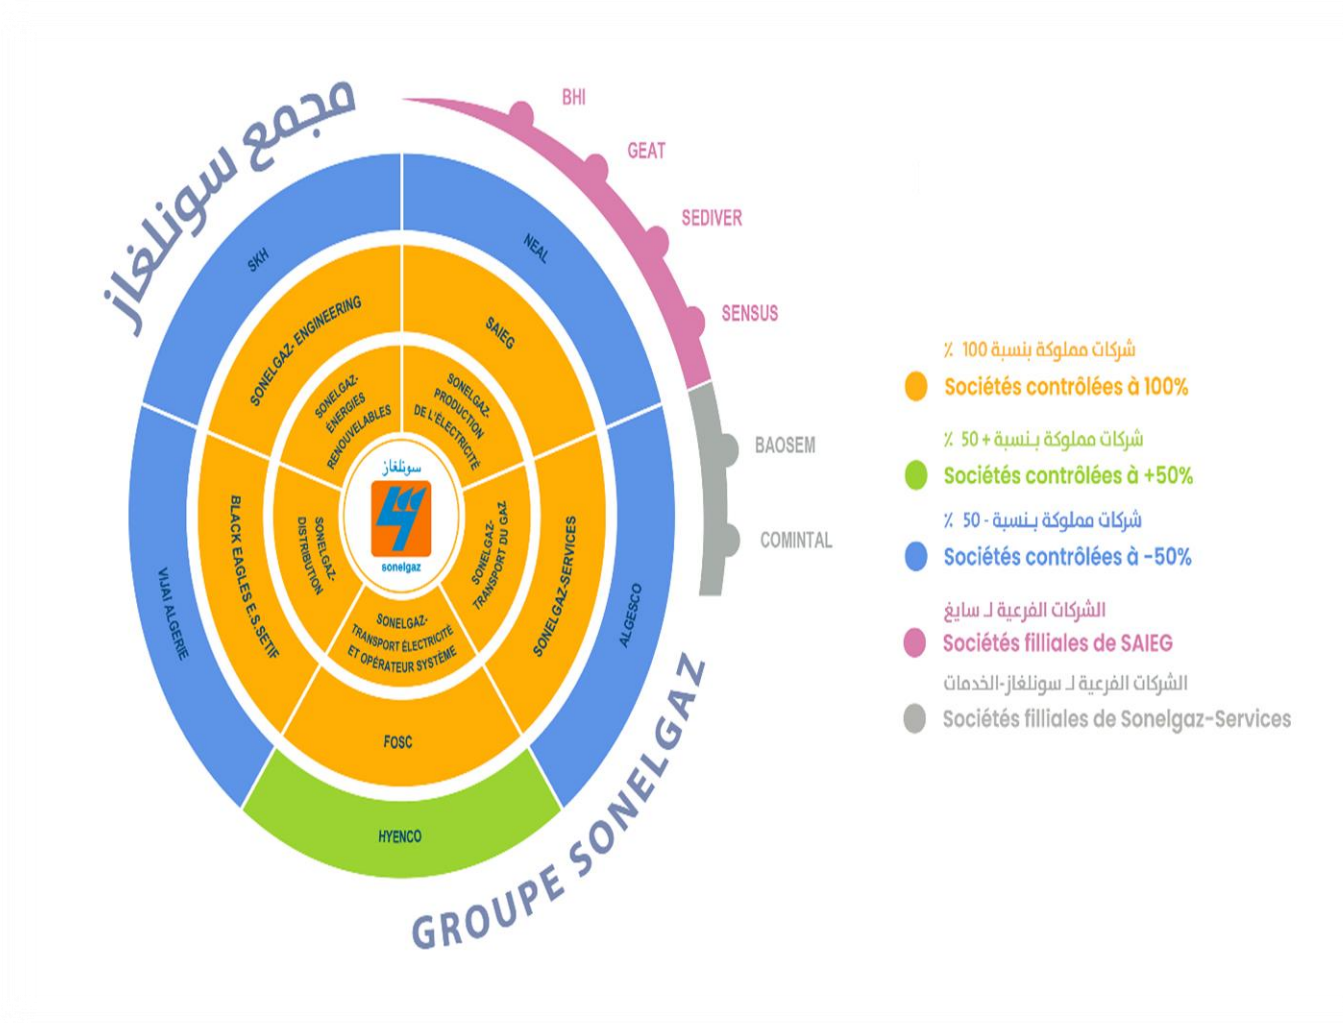


Figure1.5 : Représentation graphique du groupe Sonelgaz[15]

1.11 Les étapes de la production, du transport de l'énergie électrique :

1.11.1 La production d'énergie électrique :

L'électricité industrielle est principalement produite par la conversion de l'énergie mécanique en énergie électrique, selon le principe de l'alternateur. Ce dernier fonctionne grâce au mouvement d'un aimant dans un bobinage de fil conducteur. Les sources d'énergie mécanique utilisées pour faire tourner l'alternateur incluent l'eau (barrages hydroélectriques), le vent (éoliennes), et la vapeur d'eau produite dans les centrales thermiques et nucléaires.

Bien que les énergies renouvelables, telles que l'énergie solaire, éolienne et marémotrice, connaissent un essor, elles ne couvriront qu'une part limitée des besoins énergétiques mondiaux. Par conséquent, les ressources fossiles, telles que le charbon, le gaz naturel et l'énergie nucléaire, continueront probablement à jouer un rôle majeur dans la production d'électricité à l'échelle mondiale.

Le stockage de l'électricité reste un défi technologique majeur, nécessitant un équilibre constant entre la production et la consommation. En Algérie, la société «SONALGAZ» veille à maintenir cet équilibre en temps réel, en ajustant la production en fonction des prévisions des besoins énergétiques, qui varient selon la saison, les conditions météorologiques et l'heure de la journée. [16]

1.11.2 Le transport de l'énergie électrique :

Une fois produite, l'électricité doit être acheminée des sites de production vers les centres de consommation à travers un réseau de lignes électriques, constitué de pylônes ainsi que de câbles aériens ou souterrains.

1.11.2.1. Les lignes électriques

Une ligne électrique est un ensemble de conducteurs (en aluminium, cuivre, bronze ou autres alliages), d'isolants et d'éléments accessoires, conçus pour assurer le transport de l'énergie électrique.

Les lignes électriques se classent selon trois critères principaux :

- Position dans l'espace : Lignes aériennes, Lignes souterraines (câbles).
- Classe de tension : lignes Basse tension (BT) et Haute tension (HT).
- Type de courant : Continu, Alternatif monophasé ou triphasé.

1.11.2.2. Les lignes aériennes

Les lignes aériennes sont composées de conducteurs de phase maintenus par des isolateurs, fixés sur des structures telles que des pylônes métalliques ou des poteaux en béton ou en bois.

Elles sont principalement utilisées pour :

- Le transport sur longues distances.
- Les lignes haute tension (HT) et très haute tension (THT).
- L'alimentation en zones rurales, notamment pour la basse tension (BT).

L'énergie est générée à 15 kV, élevée à 220 kV pour le transport, abaissée à 110 kV pour la répartition, puis réduite à 30 kV pour la distribution finale.

1.11.3. La distribution de l'énergie électrique :

La distribution électrique est l'étape finale qui permet d'acheminer l'électricité depuis le réseau de transport jusqu'aux utilisateurs (maisons, entreprises, usines).

L'électricité y passe de la moyenne tension (environ 15 kV) à la basse tension (380/220V) grâce à des postes de transformation. Le réseau peut être aérien ou souterrain selon la zone. Cette étape vise à garantir une fourniture sûre, fiable et adaptée aux besoins des consommateurs.[16]

1.12 Conclusion :

À travers ce que nous avons abordé dans ce chapitre, il est clair que l'énergie joue un rôle essentiel dans l'économie et revêt une grande importance pour tous les pays. Ses usages sont variés et s'adaptent aux besoins des consommateurs. Parmi les différentes formes d'énergie, l'énergie électrique occupe une place primordiale, car elle est indispensable pour améliorer le niveau de vie des individus et favoriser le développement économique et industriel. Ainsi, la consommation d'électricité ne cesse d'augmenter, poussant de nombreux pays, comme l'Algérie, à réfléchir à des solutions pour rationaliser son utilisation, en particulier dans les secteurs industriel et domestique, qui ont enregistré une forte hausse ces dernières années. Face à cette situation, il devient impératif d'adopter les meilleures techniques permettant de prévoir la consommation énergétique, afin d'élaborer des stratégies adaptées à la demande croissante. L'une de ces techniques repose sur les réseaux de neurones artificiels (RNA), que nous présentons dans le deuxième chapitre, que nous allons présenter dans ce chapitre.

Chapitre2:

L'intelligence artificielle et la prédiction

2.1. Introduction :

L'être humain est capable de raisonner, de parler, de calculer, et d'apprendre grâce à la complexité de son cerveau et à ses nombreux mécanismes cognitifs. Mais comment parvient-il à accomplir toutes ces tâches ? L'intelligence artificielle (IA) s'efforce de comprendre et de reproduire ces capacités humaines, notamment grâce aux réseaux de neurones, une avancée majeure dans ce domaine. Ces modèles d'apprentissage automatique imitent, dans une certaine mesure, la manière dont le cerveau humain fonctionne pour traiter des informations complexes et effectuer des prédictions.

2.2 Concepts sur la prédiction :

2.2. 1 Définition d'une prévision :

La prévision repose sur l'analyse des tendances passées et des facteurs influents pour estimer des valeurs futures. Dans le domaine de la consommation électrique, elle consiste à anticiper l'évolution des besoins en énergie, que ce soit en termes de quantité totale consommée (exprimée en kWh) ou de puissance requise à un instant donné (en kW). D'un point de vue mathématique, si $P(t)$ représente la puissance électrique moyenne à un instant t , la prévision vise à estimer $P(t+\Delta t)$, où Δt correspond à l'horizon temporel de projection, défini en fonction des exigences du contexte.

2.2.2 Horizon de la prévision :

La prédiction de la consommation d'énergie peut être classée en trois catégories en fonction de l'horizon temporel.

1. **Prévisions à court terme (de quelques heures à quelques semaines) :** Elles sont utilisées pour optimiser l'exploitation des unités de production, la distribution de l'énergie et la gestion des charges, tout en tenant compte du contrôle en temps réel et de la sécurité du réseau.
2. **Prévisions à moyen terme (de quelques semaines à quelques mois) :** Elles servent principalement à la planification des ressources et à la fixation des tarifs de production. L'objectif est d'assurer un équilibre entre l'offre et la demande, d'optimiser les achats d'énergie et d'ajuster les prix en fonction des besoins du marché.

3. **Prévisions à long terme (de plusieurs mois à plusieurs années)** : Elles sont essentielles pour la gestion des ressources et les décisions d'investissement. Elles permettent de planifier l'expansion du réseau, le développement des infrastructures de production, de transport et de distribution d'énergie, ainsi que l'acquisition de nouvelles unités de génération. Ce découpage permet d'adapter les stratégies de gestion et d'anticipation en fonction des besoins et des enjeux à court, moyen et long.

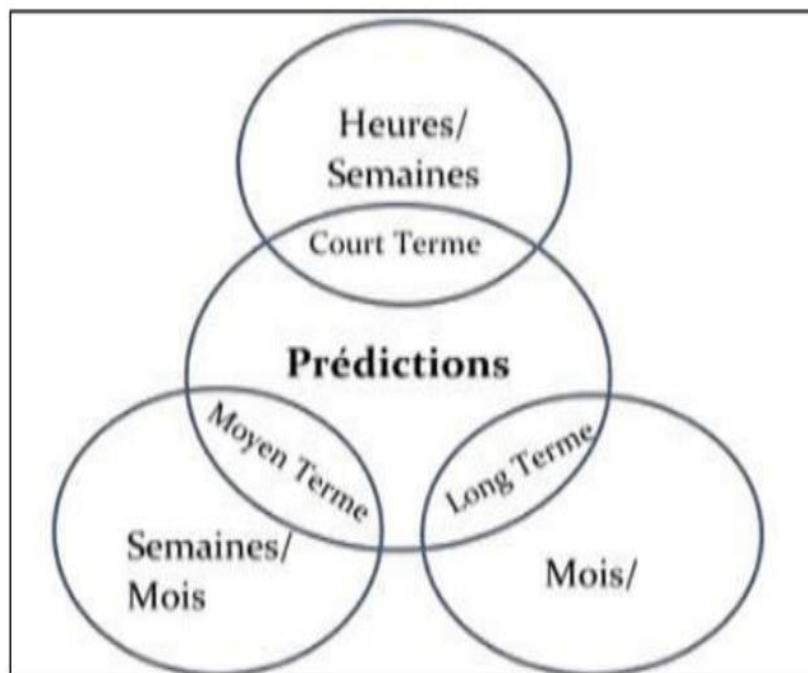


Figure2.1 : Types de prédiction [17]

2.3 les méthodes de prévision :

2.3.1 Les Méthodes déterministes de prévision :

- **Jour similaire** : Cette méthode identifie des jours passés aux caractéristiques comparables (jour de la semaine, météo, etc.) pour estimer la consommation électrique future.
- **Usage final (Bottom-up)** : Elle reconstruit la courbe de charge en analysant les habitudes de consommation (nombre d'appareils, puissance consommée, durée d'utilisation, etc.).
- **Lissage exponentiel** : Technique basée sur une moyenne pondérée des consommations passées, mettant plus l'accent sur les données récentes pour des prévisions à court terme.

2.3.2 Méthodes probabilistes de prévision :

- **Séries temporelles** : Basées sur l'analyse des données historiques, elles modélisent les tendances, saisons et variations aléatoires pour anticiper la consommation future.
- **Chaîne de Markov** : Modélise la consommation sous forme d'états et de probabilités de transition, en supposant que l'évolution future dépend uniquement de l'état actuel.

2.3.3 Méthodes d'intelligence artificielle pour la Prédiction de la Consommation Électrique :

L'intelligence artificielle propose plusieurs approches, dont les réseaux de neurones et la logique floue, largement utilisées pour prévoir la consommation électrique.

- **Réseaux de Neurones Artificiels (RNA)** : Inspirés du cerveau humain, ils analysent les données à travers des couches de neurones interconnectés. En s'entraînant sur des données historiques, ils identifient des tendances complexes pour des prévisions précises.
- **Logique Floue** : Elle modélise des concepts incertains avec des valeurs graduelles (ex. « faible », « élevé »). Basée sur des règles linguistiques, elle est idéale pour traiter l'imprécision et intégrer des connaissances expertes.

2.4 les modèles de la prévision :

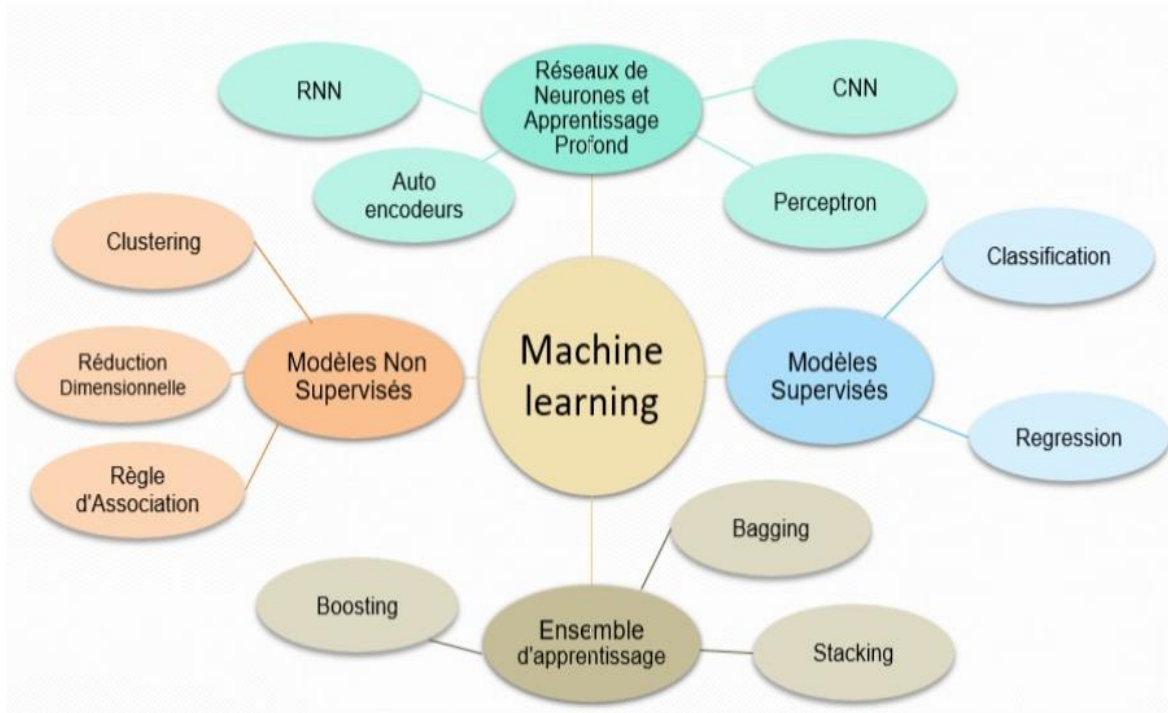


Figure 2.2 Les modèles de prévisions.

1. Modèles Supervisés :

L'apprentissage supervisé utilise des données étiquetées pour entraîner un modèle à prédire un résultat.

Les principaux sous-types sont :

- ✓ Classification : Le modèle apprend à classer des données en catégories (exemple : détection de spam, reconnaissance d'image).
- ✓ Régression : Le modèle prédit des valeurs continues.

Elle se divise en deux types principaux :

1. **Régression linéaire** : modèle simple , relation droite entre les variables.

Type:

1.1 Régression linéaire simple : Un seul facteur explicatif (X) est utilisé pour prédire une variable (Y). La relation entre les deux est une droite.

1.2 Régression linéaire multiple :Plusieurs variables indépendantes (X_1, X_2, \dots) sont utilisées pour estimer la valeur de Y . La relation reste linéaire, mais prend en compte plusieurs dimensions.

2. **Régression non linéaire** : relation courbe ou plus complexe.

Type:

2.1 Régression polynomiale :On ajoute des puissances de X (comme X^2, X^3 , etc.) pour modéliser une relation en courbe entre X et Y .

2.2 Régression exponentielle :La variable Y évolue très rapidement (à la hausse ou à la baisse) selon une fonction exponentielle de X .

2.3 Régression logarithmique : Y augmente fortement au début quand X augmente, puis sa croissance ralentit.

2.4 Régression puissance : Y est proportionnelle à X élevé à une certaine puissance ($Y = a * X^b$). On l'utilise quand la relation suit une loi de puissance.

2.5 Régression logistique :Elle sert à prédire la probabilité qu'un événement binaire se produise . Le résultat est compris entre 0 et 1.

- ✓ Perceptron : Un algorithme de base des réseaux de neurones artificiels pour la classification binaire.
- ✓ CNN (Convolution Neural Networks) : Un type de réseau de neurones avancé, principalement utilisé pour la reconnaissance d'images et le traitement de données visuelles.

2. Modèles Non Supervisés :

- ✓ L'apprentissage non supervisé est utilisé lorsque les données ne sont pas étiquetées. L'algorithme essaie de trouver des structures et des relations cachées.
- ✓ Clustering : Regroupe des données similaires.
- ✓ Réduction Dimensionnelle : Technique pour réduire la quantité de variables tout en conservant l'essentiel de l'information (exemple : PCA – Analyse en Composantes Principales).
- ✓ Règle d'Association : Recherche des relations entre les variables.
- ✓ Auto-encodeurs : Réseaux de neurones utilisés pour la compression et la détection d'anomalies.

3. Réseaux de Neurones et Apprentissage Profond :

L'apprentissage profond (Deep Learning) est un sous-domaine du Machine Learning utilisant des réseaux de neurones multicouches.

- ✓ RNN (Recurrent Neural Networks) : Réseaux de neurones spécialisés dans le traitement des données séquentielles (exemple : traduction automatique, analyse de texte, prévision de séries temporelles).

4. Ensembles d'Apprentissage :

Les méthodes d'ensemble combinent plusieurs modèles pour améliorer la précision.

- ✓ Boosting : Améliore les performances en entraînant des modèles faibles successivement pour corriger les erreurs (exemple : AdaBoost, Gradient Boosting).
- ✓ Bagging : Combine plusieurs modèles entraînés indépendamment et agrège leurs résultats (exemple : Random Forest).
- ✓ Stacking : Utilise plusieurs modèles et un métamodèle pour faire la prédiction finale.

2.5. Neurone :

2.5 Qu'est-ce qu'un « neurone » ?

Un neurone est une cellule vivante spécialisée dans la transmission des signaux électriques et chimiques. Il peut prendre différentes formes, comme pyramidale, sphérique ou étoilée, et sa structure est délimitée par une membrane qui sépare son intérieur de l'extérieur.

Les neurones sont considérés comme les éléments de base du traitement de l'information dans le cerveau, permettant de recevoir, de traiter et de transmettre des signaux. Ce processus de communication est au cœur de toutes les fonctions cognitives humaines, de la pensée à l'apprentissage.

Il existe principalement deux types de neurones : les neurones biologiques et les neurones formels.[18]

2.5.1. Neurone biologique :

Un neurone biologique est une cellule spécialisée du système nerveux, dont le rôle principal est de transmettre des signaux électriques et chimiques entre différentes régions du cerveau et du corps. Ces neurones sont responsables de la communication interne du cerveau, ce qui permet au système nerveux de traiter l'information.

Un neurone biologique se compose de plusieurs parties :

- **Le corps cellulaire** : Il contient le noyau, qui contrôle les fonctions de la cellule et lui permet de survivre.
- **Les dendrites** : Ce sont des prolongements ramifiés qui reçoivent des signaux provenant d'autres neurones.
- **L'axone** : Il s'agit d'un long prolongement qui transmet les signaux électriques du neurone vers d'autres neurones ou cellules.
- **Les synapses** : Ce sont les zones de connexion entre les neurones. Lorsque l'influx nerveux arrive à la fin de l'axone, il est converti en signal chimique, permettant à l'information de se transmettre d'un neurone à l'autre.

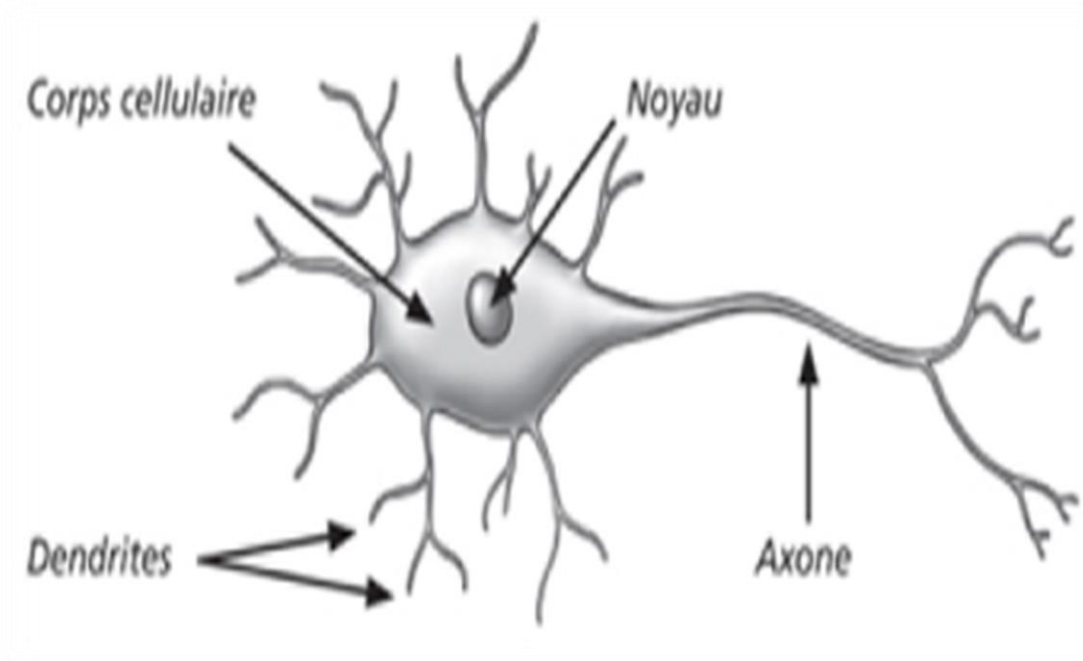


Figure2.3 : Représentation graphique du Neurone biologique. [19]

2.5.2 Neurones formels :

Un neurone formel est une représentation mathématique simplifiée du neurone biologique, utilisée principalement dans les réseaux de neurones artificiels.

Contrairement aux neurones biologiques, qui sont des cellules vivantes complexes, les neurones formels sont des unités de calcul conçues pour modéliser certaines fonctions cognitives du cerveau humain dans un cadre informatique.[20]

Un neurone formel est composé de plusieurs éléments :

1. **Entrées** : Ce sont les données d'entrée reçues par le neurone. Chaque entrée représente une caractéristique ou un aspect de l'information à traiter.
2. **Poids** : Les poids sont des valeurs associées à chaque entrée, qui déterminent l'importance de cette entrée dans le calcul du neurone. Ces poids sont ajustés lors de l'apprentissage afin d'optimiser la performance du réseau.
3. **Somme pondérée** : Le neurone calcule la somme de ses entrées, chacune étant multipliée par son poids respectif.
4. **Fonction d'activation (Activation fonction)** : La somme pondérée est ensuite passée à travers une fonction d'activation, qui détermine si le neurone doit "s'activer" ou non. La fonction d'activation permet d'introduire des non-linéarités dans le modèle, ce qui est crucial pour résoudre des problèmes complexes. Des exemples de fonctions d'activation sont la fonction sigmoïde, RLU (Rectifie Linear Unit).
5. **Sortie** : La sortie du neurone est le résultat de l'application de la fonction d'activation à la somme pondérée. C'est ce signal qui sera transmis à d'autres neurones dans un réseau de neurones.

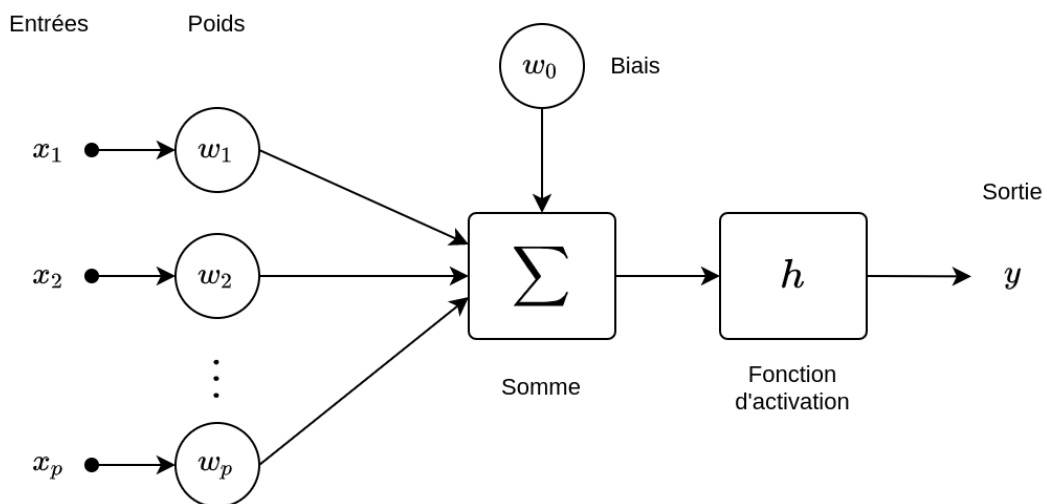


Figure2.4 : Représentation graphique du Neurones formels [21]

Avec :

- ❖ Les X_i sont les entrées du réseau.
- ❖ S le potentiel d'activation.

- ❖ W_i les poids synaptiques associés aux entrées.
- ❖ y la sortie du réseau tels que :

$$S = \sum_{i=1}^N W_i \cdot X_i + W_0 \quad (2.1)$$

2.6 Les fonctions d'activation :

Les fonctions d'activation introduisent des non-linéarités dans les réseaux neuronaux, leur permettant d'apprendre des relations complexes entre entrées et sorties. Sans elles, les réseaux seraient limités aux relations linéaires. Le choix d'une fonction adaptée est essentiel pour assurer une bonne généralisation et des prédictions précises.

- ✓ **La fonction Sigmoid** : transforme une entrée réelle en une valeur entre 0 et 1, avec une courbe en forme de S, convergeant vers 0 pour les grandes valeurs négatives et vers 1 pour les grandes valeurs positives. Sa formule est :

$$F(x) = \frac{1}{1+e^{-x}} \quad (2.2)$$

- ✓ **La fonction Tangente hyperbolique (Tanh)** : est similaire à la Sigmoid, mais ses sorties varient entre -1 et 1. Elle est exprimée par :

$$F(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.3)$$

La fonction ReLU (Rectified Linear Unit) : Relu est une fonction d'activation non linéaire couramment utilisée dans les réseaux Neuronaux, car elle fonctionne comme une fonction d'activation à apprentissage rapide qui fournit des performances croissantes et aussi donne de meilleurs résultats Si l'on compare avec les fonctions sigmoïde et Tangent hyperbolique en termes de performance et de Généralisation Elle donne 0 pour toutes les valeurs négatives et l'entrée elle-même pour toutes les Valeurs positives

Représenter par :

$$F(x) = \max(0, x) \quad (2.4)$$




Figure2.5 : les courbes des fonctions d'activation.

2.7 Les réseaux de neurones artificiels (Artificial Neural Networks ANN) :

Un réseau de neurones artificiels (RNA) est un système d'unités appelées neurones, interconnectées de manière complexe. Il reçoit des signaux d'entrée, les traite à travers ces neurones, puis produit des signaux de sortie. Le réseau fonctionne de manière parallèle et distribue l'information à travers tous ses neurones, avec des connexions pondérées qui modulent les signaux.

Le RNA apprend par entraînement plutôt que par programmation explicite. Les poids des connexions sont ajustés pendant l'apprentissage afin d'optimiser la performance du réseau pour accomplir une tâche spécifique.

2.7.1 Les composants des réseaux de neurones artificiels :

Les réseaux de neurones artificiels se composent de trois types de couches :

1. **Couche d'entrée** : reçoit les données d'entrée et les transmet aux neurones suivants sans traitement.
2. **Couches cachées** : traitent les informations en appliquant des poids et des fonctions d'activation, puis transmettent les résultats aux couches suivantes.

3. **Couche de sortie** : génère le résultat final du réseau, sans connexions supplémentaires après elle.




Figure2.6 : Architecture de base de ANN [22]

2.8 Les caractéristiques du réseau de neurones artificiels :

Caractéristique	Description
Architecture du réseau	Détermine la structure du réseau, les connexions entre les neurones et la direction de propagation de l'information.
Fonction d'activation des neurone	Définit le comportement des neurones en transformant la somme des entrées pondérées en une sortie, souvent de manière non linéaire.
Algorithme d'apprentissage	Permet d'ajuster les poids du réseau en fonction des données d'entrée et des résultats souhaités pour améliorer les prédictions ou classifications.

Tableau 2.1 : Les caractéristiques du réseau de neurones artificiels [23]

2.9 Différents types de réseaux de neurones artificiels :

Selon la topologie de connexion des neurones, on peut les classer en deux grandes catégories : réseaux non bouclés (statique ou feed-forward) et réseaux bouclés (dynamique, feed-back ou récurrent).

2.9.1 Réseaux non bouclés (Feed-Forward) :

Un réseau de neurones non bouclé (également appelé réseau feed-forward, réseau statique ou réseau proactif) est un type de réseau dans lequel l'information circule uniquement dans un sens, de l'entrée vers la sortie, sans rétroaction ni boucle. Autrement dit, chaque neurone reçoit des entrées, effectue des calculs (sommation et activation) et transmet son résultat à la couche suivante. Il n'y a pas de connexion entre les neurones d'une même couche ni de connexion qui ferait revenir l'information en arrière. [24]




Figure2.7 : Un réseau de neurone non bouclé.[21]

Le Perceptron :

Le perceptron est le tout premier modèle de réseau de neurones, inventé en 1957 par Frank Rosenblatt. C'est un réseau simple composé uniquement d'une couche d'entrée et d'une couche de sortie. Le perceptron peut apprendre des fonctions booléennes telles que les fonctions AND et OR. Ce modèle est capable de résoudre

des problèmes où la sortie peut être classée en deux catégories, comme dans le cas des fonctions logiques de base.[25]

2.9.1.1 Perceptron Monocouche ELM (Single-Layer Perceptron - SLP):

Dans un perceptron mono couche, il existe une seule couche cachée qui relie la couche d'entrée à la couche de sortie. Seule cette couche cachée est modifiable durant l'entraînement du réseau.

- Limitations : Les applications de ce modèle sont assez limitées. Chaque neurone de la couche cachée fonctionne indépendamment des autres neurones et ne reçoit aucune connexion provenant d'autres neurones dans la même couche. De plus, il ne peut résoudre que des problèmes où la sortie attendue est un vecteur scalaire plutôt qu'une seule valeur scalaire.

L'exemple de réseau a une seule couche est donné par la (figure 2.8)[26]

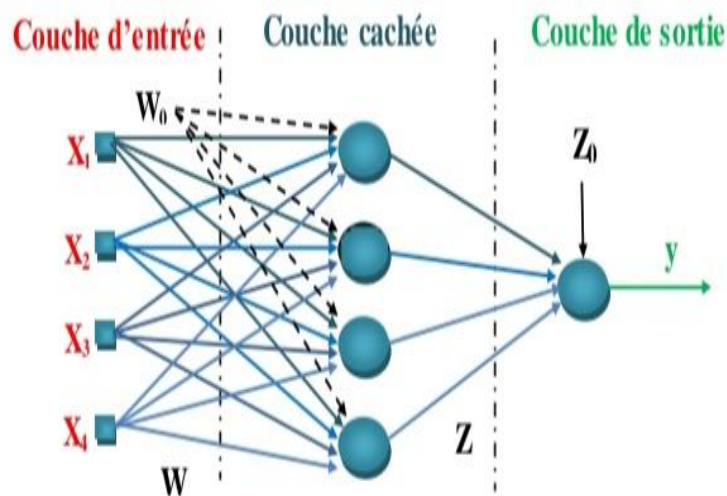


Figure2.8 : Structure d'un ELM (SLP)[21]

La sortie du réseau a pour expression :[21]

$$Y = \left[g \left[z \left[f \left(Wx + W0 \right) \right] \right] \right] + Z0 \quad (2.5)$$

Avec :

F et g et les fonctions de transfert, des couches cachées et de sorties respectivement.

Y : La sortie du réseau.

X : Le vecteur des entrées.

W : La matrice des poids de connexions liant la couche d'entrée à la couche cachée.

W0 : Le vecteur des biais des cellules de la couche cachée.

Z : La matrice des poids des connexions liant la couche cachée à la couche de sortie.

Z0 : Le vecteur des biais des cellules de la couche de sortie.

2.9.1.2 Perceptron Multi Couche (PMC) :

Le Perceptron Multicouche (PMC) (ou Multi _layer perceptron) est un type de réseau neuronal artificiel qui se compose de plusieurs couches de neurones interconnectés. Contrairement au perceptron simple (qui ne comporte qu'une seule couche de neurones), le PMC permet de traiter des problèmes plus complexes grâce à l'ajout de couches cachées. Ces couches permettent au réseau de créer des représentations de plus en plus abstraites des données d'entrée, ce qui améliore ses capacités de modélisation.

Composants du PMC :

- ❖ Couche d'entrée : C'est la couche initiale du réseau où les données brutes sont injectées. Elle contient autant de neurones qu'il y a d'entrées dans le système, mais elle ne modifie pas les informations, elle se contente de les transmettre.
- ❖ Couches cachées : Ce sont des couches intermédiaires qui transforment les données. Chaque neurone dans ces couches applique des transformations non linéaires aux données qu'il reçoit des couches précédentes. Ces couches sont dites "cachées" car leurs sorties ne sont pas directement accessibles à l'extérieur du réseau. Le nombre et la taille de ces couches influencent considérablement la capacité du réseau à apprendre des relations complexes.
- ❖ Couche de sortie : C'est la couche finale du réseau, qui produit la sortie, que ce soit une classe dans un problème de classification ou une valeur continue dans un problème de régression. Le nombre de neurones dans cette couche dépend
- ❖ du type de tâche que le réseau doit accomplir.[27]




Figure2.9 : Exemple Structure d'un PMC[21]

2.9.1.3 Le réseau de neurones à fonctions radiales de base (RBF) :

Est un modèle populaire dans le domaine de l'intelligence artificielle et de l'apprentissage automatique, particulièrement adapté pour des tâches de classification et régression.

Structure du Réseau RBF:

Le Réseau RBF se compose de trois couches distinctes :

- ❖ **Couche d'entrée** : La couche d'entrée reçoit directement les données d'entrée, sans aucune transformation ou modification. Elle sert de passerelle pour transmettre les données vers la couche cachée.
- ❖ **Couche cachée** : La couche cachée est l'élément clé du réseau RBF. Chaque neurone dans cette couche est associé à une fonction radiale de base, souvent une fonction gaussienne. Le rôle de chaque neurone est de mesurer la proximité de l'entrée par rapport à un centre spécifique, et la sortie du neurone est généralement fonction de cette distance.
- ❖ **Couche de sortie** : La couche de sortie combine les sorties des neurones de la couche cachée. Les neurones de cette couche utilisent une fonction d'activation linéaire pour produire la sortie finale. L'équation pour la sortie du réseau est donc une somme pondérée des activations de la couche cachée.[28]




Figure2.10 : Architecteur du réseau RBF[21]

2.9.2 Réseau bouclés (Feed-Back) :

Les réseaux bouclés (également appelés réseaux dynamiques ou réseaux récurrents) sont une classe de modèles de réseaux neuronaux qui se distinguent des réseaux traditionnels par leur capacité à avoir des boucles ou des connexions de rétroaction (feed-back) entre les neurones. Ces réseaux ont la particularité de pouvoir mémoriser et utiliser l'information des états passés pour influencer leurs décisions futures.[29]




Figure2.11 : un réseau de neurone boucle.[21]

1. Principe de Fonctionnement des Réseaux Bouclés (Récurents) :

Dans un réseau récurrent, les sorties des neurones peuvent être envoyées en retour vers l'entrée du réseau, créant ainsi des boucles de rétroaction. Cela permet aux réseaux récurrents de traiter non seulement les informations actuelles, mais aussi de prendre en compte l'historique des informations passées. Quelques points clés à propos des réseaux récurrents :

- **Boucles de rétroaction :** La sortie d'un neurone peut être utilisée comme entrée pour le même neurone ou pour d'autres neurones du réseau. Cette architecture de rétroaction permet au réseau d'exploiter des informations passées (mémoire) et d'adapter ses réponses en fonction des états précédents.
- **Comportement dynamique :** Contrairement aux réseaux statiques (comme les perceptrons multi couches), les réseaux récurrents ne donnent pas nécessairement la même sortie pour une même entrée à différents instants de temps. La sortie peut dépendre de l'entrée et de l'état interne du réseau à un moment donné, ce qui rend ces réseaux capables de traiter des séquences d'informations et de conserver des états internes qui influencent les sorties futures.[29]

2.9.2.1 Les Cartes Auto-Organisatrices de Kohonen (Réseaux Kohonen) :

Les cartes auto-organisatrices de Kohonen (ou réseaux Kohonen) sont un type de réseau de neurones non supervisé qui utilise un processus d'apprentissage non dirigé pour organiser les neurones en une structure spécifique. L'objectif principal de ces réseaux est de permettre aux neurones de s'auto organiser en fonction des propriétés ou caractéristiques des données d'entrée.[30]

2.9.2.2 Les Réseaux de HopField :

Les réseaux de HopField sont des réseaux récurrents qui peuvent être vus comme une mémoire associative non linéaire. Ce modèle a été proposé en 1982 par John HopField. Les réseaux de HopField sont entièrement connectés, chaque neurone étant connecté à tous les autres neurones du réseau. Ce type de réseau est récurrent, ce qui signifie que les sorties des neurones peuvent influencer leurs propres entrées ou celles des autres neurones.[31]

2.9.2.3 Les Réseaux ART (Adaptive Résonance Theory) :

Les réseaux ART ont été développés par Carpenter et Gross berg en 1987. Ils sont conçus pour résoudre le dilemme stabilité/plasticité dans l'apprentissage des réseaux de neurones. Ce dilemme réside dans la difficulté à maintenir une stabilité des catégories apprises tout en permettant au réseau de s'adapter à de nouvelles données. Les réseaux ART permettent de gérer ce compromis en ajustant dynamiquement leur structure.[31]

2.9.2.4 Le modèle Adaline :

C'est un réseau présenté par Windrow et Hoff, ce réseau contient trois couches, une d'entrée, une couche cachée et une couche de sortie. Ce modèle est similaire au modèle de perceptron seulement la fonction d'activation change, mais reste toujours linéaire. Ce réseau est utilisé généralement pour la classification c'est à dire la séparation linéaire entre les données qui seront présentés par classe.

2.10 Avantages et inconvénients des réseaux de neurones :[32]

Avantages	Inconvénients
<p>Capacité à modéliser des fonctions complexes Les réseaux de neurones peuvent modéliser des relations linéaires ou non linéaires, simples ou complexes, ce qui les rend très flexibles.</p>	<p>Besoin de grandes quantités de données Les réseaux de neurones nécessitent souvent beaucoup de données pour un apprentissage efficace, en particulier pour des modèles profonds (deep learning).</p>
<p>Apprentissage automatique : L'apprentissage se fait automatiquement à partir des données, sans avoir besoin d'une supervision manuelle complexe.</p>	<p>Besoin de puissance de calcul importante : L'entraînement des réseaux de neurones, surtout avec de grandes quantités de données, demande une puissance de calcul élevée et peut nécessiter des ressources matérielles importantes</p>
<p>Résistance au bruit et aux données incomplètes : Les réseaux sont robustes face au bruit, et peuvent fonctionner même lorsque les données sont incomplètes ou imparfaites.</p>	<p>Difficulté à interpréter les modèles : Les réseaux de neurones sont souvent considérés comme des boîtes noires, ce qui les rend difficiles à interpréter ou à expliquer de manière transparente.</p>
<p>Adaptabilité et flexibilité : Ils peuvent s'adapter à des problèmes de classification, de régression, de reconnaissance de formes, etc. et sont capables d'apprendre des modèles à partir de données variées.</p>	<p>Risque de surapprentissage (overfitting Si le modèle est trop complexe par rapport à la quantité de données, il peut facilement surapprendre les données d'entraînement et ne pas bien généraliser aux nouvelles données.)</p>

Tableau 2.2 : Avantages et inconvénients des réseaux de neurones.

2.11 Conclusion :

Ce chapitre a exploré l'utilisation des réseaux de neurones artificiels, en mettant l'accent sur leur capacité à généraliser et à résister au bruit, ce qui les rend efficaces dans de nombreuses applications. Nous avons principalement abordé deux types d'architectures neuronales : le Perceptron Multicouche (PMC) et les réseaux à fonctions radiales de base (RBF), utilisés pour des tâches comme la classification, la prédiction et l'approximation.

Les réseaux de neurones se sont avérés particulièrement adaptés à la prévision de la consommation d'électricité, en raison de leur capacité à modéliser des phénomènes complexes et influencés par plusieurs facteurs. Toutefois, ces réseaux nécessitent de grandes quantités de données, des ressources informatiques importantes et peuvent être difficiles à interpréter. Malgré ces défis, les réseaux de neurones restent une méthode privilégiée pour résoudre des problèmes complexes, notamment dans la gestion de l'énergie.

Chapitre3 :

Analyse et conception

3.1 Introduction :

La prévision de la consommation d'énergie électrique joue un rôle essentiel dans la planification et la gestion efficaces des réseaux électriques, en particulier dans un contexte marqué par la montée en puissance des énergies renouvelables et l'émergence des réseaux intelligents. La qualité de cette planification dépend largement des méthodes de prédiction utilisées, chacune présentant des forces et des limites qui la rendent plus ou moins adaptée à différents scénarios. Cette étude propose une comparaison des principales approches afin de mieux comprendre leurs spécificités et d'orienter le choix de la méthode la plus appropriée selon les besoins ciblés.

3.2. Étude comparative entre les deux techniques de prédiction de la Consommation d'énergie électrique :

3.2.1 Méthodes d'Apprentissage Automatique :

✚ Perceptron Multi Couche (PMC) :

Le Perceptron Multi-Couche (PMC), ou Multi-Layer Perceptron (MLP) en anglais, est un type de réseau de neurones artificiels utilisé principalement pour l'apprentissage supervisé. Il est composé de plusieurs couches de neurones organisées en trois types :

- **La couche d'entrée** : Reçoit les données en entrée (les caractéristiques du problème), Une ou plusieurs couches cachées : Traitent l'information en appliquant des transformations non linéaires grâce aux fonctions d'activation (comme ReLU, sigmoid).
- **La couche de sortie** : Fournit la prédiction ou la classification du modèle.

✚ Principe de fonctionnement :

1. Propagation avant (Feedforward) :

- Les données sont introduites dans la couche d'entrée.
- Les signaux sont transmis aux couches cachées, où chaque neurone calcule sa sortie en appliquant une somme pondérée des entrées suivie d'une fonction d'activation non linéaire comme Sigmoid ou ReLU.
- Les informations traversent les différentes couches jusqu'à la couche de sortie, où la prédiction est générée.

2. Apprentissage par rétropropagation (Back propagation) :

L'erreur entre la sortie prédite et la sortie attendue est calculée. Cette erreur est propagée en sens inverse à travers le réseau afin d'ajuster les poids des connexions à

l'aide d'un algorithme d'optimisation comme la descente de gradient (Gradient Descent). Ce processus est répété plusieurs fois durant l'entraînement du réseau.

3. Généralisation et prédiction :

Une fois entraîné, le modèle est capable de généraliser les connaissances acquises pour effectuer des prédictions sur de nouvelles données jamais vues auparavant.

3.2.2 Méthodes Traditionnelles (Modèles Statistiques) :

Régression Linéaire :

La régression linéaire est une méthode statistique utilisée pour analyser la relation entre une variable dépendante et une ou plusieurs variables indépendantes. Elle consiste à déterminer une ligne droite (ou un plan dans le cas de plusieurs variables) qui représente au mieux les données en minimisant l'écart entre les valeurs prévues et les valeurs réelles.

Principe de fonctionnement :

La régression linéaire repose sur l'élaboration d'une équation permettant de prédire la valeur d'une variable dépendante (y) à partir d'une ou plusieurs variables explicatives (x). Elle suppose que ces dernières influencent la variable dépendante. L'estimation des paramètres se fait généralement par la méthode des moindres carrés, qui minimise l'écart entre les valeurs observées et celles prédites par le modèle. Les variables explicatives sont représentées sur l'axe horizontal et la variable dépendante sur l'axe vertical. Cette méthode permet d'analyser l'impact des variables explicatives, de modéliser les relations entre elles et de réaliser des prévisions précises.




Figure3.1 : Modèle de régression linéaire[34].

➤ **Régression non Linéaire :**

La régression non linéaire est une méthode statistique utilisée pour modéliser la relation entre une variable dépendante et une ou plusieurs variables indépendantes lorsque cette relation ne suit pas une forme linéaire. Contrairement à la régression linéaire, elle permet d'ajuster des courbes plus complexes aux données.

➤ **Principe de fonctionnement :**

La régression non linéaire repose sur l'élaboration d'une équation mathématique non linéaire reliant la variable dépendante (y) à une ou plusieurs variables explicatives (x). Ce type de modèle suppose que la relation entre les variables ne peut pas être représentée par une droite mais plutôt par une courbe (ex. : exponentielle, logarithmique, puissance, sigmoïde, etc.).

L'estimation des paramètres se fait souvent par des méthodes d'optimisation numérique, comme la méthode des moindres carrés non linéaires. Elle est particulièrement utile lorsque les données montrent une variation qui ne peut pas être expliquée par un modèle linéaire, permettant ainsi d'améliorer la précision des

prédictions et de mieux comprendre les relations complexes entre les variables.




Figure3.2 : Modèle de régression non linéaire[34].

3.4 Algorithme d'apprentissage :

3.4.1 Algorithme du gradient :

L'algorithme du gradient est une méthode essentielle en apprentissage automatique, notamment en régression linéaire. Il permet d'ajuster les poids d'une fonction linéaire en minimisant la fonction du coût. Cet algorithme itératif met à jour les poids à chaque itération afin d'atteindre un minimum global ou local.

Étapes de l'algorithme :

1. Initialiser les poids θ_j à 0. Fixer un pas α pour mettre à jour les poids. Aussi, Fixer un seuil de tolérance $\varepsilon > 0$.
2. Calculer les gradients de la fonction du coût en θ_j .
3. Mettre à jours les poids θ_j en utilisant leurs anciennes valeurs, leurs gradients et Le pas α .
4. Si la fonction du coût $J < \varepsilon$ on s'arrête ; sinon, on revient à l'étape (2).

Choix du pas :

Le pas α est une valeur connue entre 0 et 1. $\alpha \in]0, 1]$.

- ❖ Si le pas est grand, on risque de manquer la solution optimale.
- ❖ S'il est petit, l'algorithme prend du temps à converger.

Une approche adaptative consiste à ajuster dynamiquement

- ❖ Si la fonction du coût diminue, augmenter.
- ❖ Si la fonction du coût augmente, réduire.

Cela nécessite d'introduire des paramètres de contrôle comme un taux d'augmentation et un taux de réduction.

Critères d'arrêt :

Le seuil de tolérance ϵ est la valeur minimale acceptable du coût, entraînant l'arrêt de l'algorithme.

Si le pas est trop grand, on s'arrête en l'absence d'amélioration.

Une autre méthode consiste à fixer un nombre maximal d'itérations.

Calcul des gradients :

Le gradient de chaque poids θ_j est calculé en utilisant le dérivé partiel de la fonction Du coût par rapport à ce poids. Donc, le gradient d'un poids θ_j est calculé comme suit, Où (i) représente un échantillon :

$$\frac{\partial j}{\partial \theta} = \frac{1}{N} \sum_{i=1}^N \frac{\partial y(x^{(i)})}{\partial y} * \frac{\partial y(x^{(i)} - y^{(i)})}{\partial y} \quad (3.1)$$

Pour les θ_j avec $j > 0$:

$$\frac{\partial J}{\partial \theta} = \frac{2}{N} \sum_{i=1}^N x^{(i)} (y(x^{(i)}) - y^{(i)}) \quad (3.2)$$

Pour θ_0 :

$$\frac{\partial j}{\partial \theta} = \frac{2}{N} \sum_{i=1}^N [Y(x^{(i)}) - y^{(i)}] \quad (3.3)$$

Mise à jour des poids : Les poids sont mis à jour en se basant sur les gradients et le

pas comme suit : [33]
$$\theta = \theta_j - \alpha * \frac{\partial j}{\partial \theta_i} \quad (3.4)$$

L'organigramme :

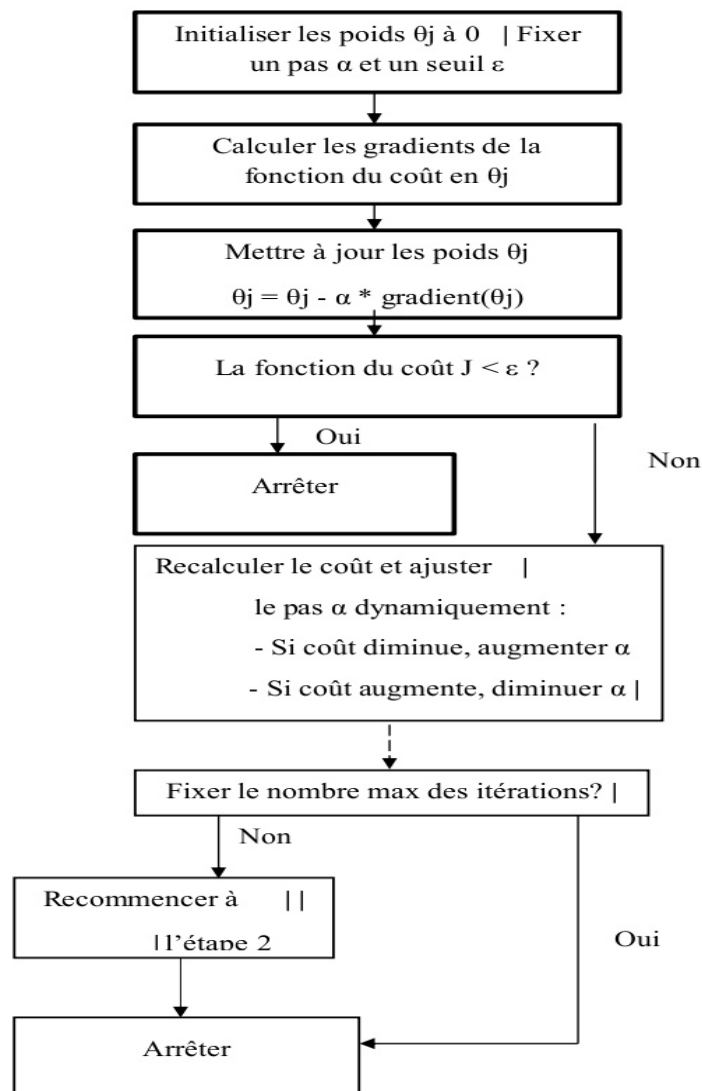


Figure3.3 : organigramme de l'algorithme du gardien.

3.4.2 L'algorithme de rétro-propagation du gradient :

Principe :

La rétropropagation du gradient est une méthode utilisée pour entraîner les réseaux de neurones. Elle consiste à faire circuler l'erreur à l'envers, c'est-à-dire depuis la couche de sortie vers la couche d'entrée, pour ajuster les poids du réseau.

L'idée est de comparer les résultats produits par le réseau avec les résultats attendus, en utilisant l'erreur quadratique, qui est le carré de la différence entre la sortie obtenue et la sortie désirée.

En calculant la dérivée partielle de cette erreur par rapport à chaque poids, on mesure l'influence de chaque poids sur l'erreur finale. Grâce à cela, on peut ajuster progressivement les poids pour réduire l'erreur, en suivant la direction indiquée par le gradient.

Chaque mise à jour des poids est modulée par un coefficient d'apprentissage, noté η , qui contrôle l'ampleur de la correction.[35]

Algorithme :

I. Définition du réseau:

Un réseau de neurones multicouche se compose de trois couches principales :[36]

-Couche d'entrée : Elle contient m unités qui servent juste à transmettre les données au réseau. Ce ne sont pas des neurones, mais simplement des valeurs d'entrée notées .

-Couche cachée : Elle est composée de n neurones. Chaque neurone transforme les données reçues à l'aide d'une fonction d'activation, y_j .

-Couche de sortie : Cette couche contient p neurones, chacun appliquant aussi une fonction d'activation, notée Z_k , pour produire le résultat final du réseau.

✓ Les connexions entre les couches :

- $n \times m$ Entre la couche d'entrée et la couche cachée, il y a connexions, chaque lien ayant un poids .

- $n \times p$ Entre la couche cachée et la couche de sortie, on trouve connexions, avec des poids .

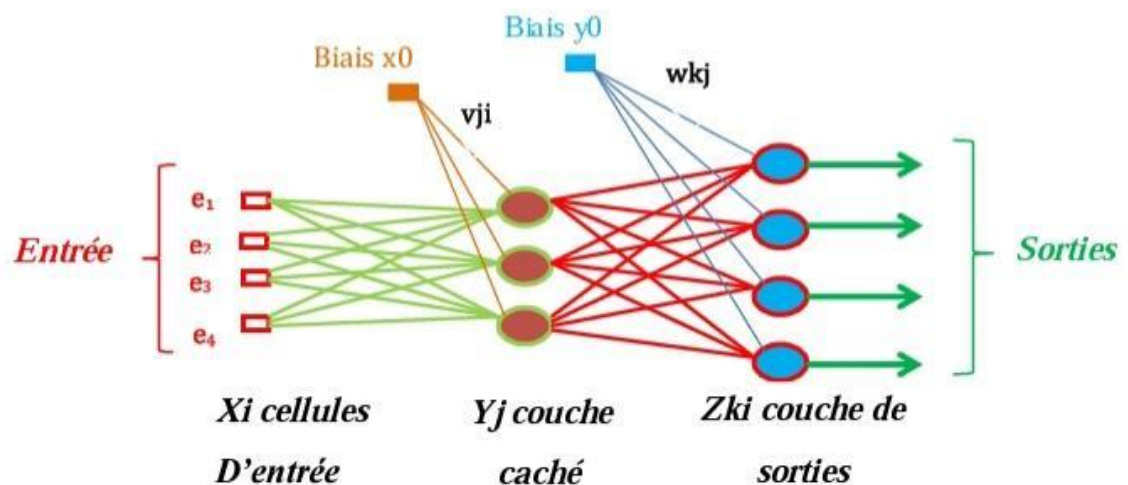


Figure 3.4: Exemple de réseau MLP à une couche cachée avec 4 entrées, 3 neurones dans la couche cachée, et 4 sorties. [37]

L'algorithme de rétro-propagation permet d'entraîner un réseau de neurones en ajustant les poids des connexions. Il se déroule en 3 grandes étapes :[38]

1. Initialisation

On initialise aléatoirement : Les poids des connexions entre les neurones : V_{ji} et W_{kj} .

Les biais (valeurs constantes ajoutées) : x_0 , y_0 .

2. Propagation avant (Forward) $x_i = e_i$

a) Vers la couche cachée :

Chaque neurone de la couche cachée reçoit une combinaison des entrées .

$$y_j = f\left(\sum_{i=1}^m x_i v_{ji} + x_0\right) \quad (3.5)$$

➤ Où f est la fonction d'activation, souvent sigmoïde : $f(s) = \frac{1}{1+e^{-s}}$ (3.6)

b) Vers la couche de sortie :

$$z_k = f\left(\sum_{j=1}^n y_j w_{kj} + y_0\right) \quad (3.7)$$

3. Calcul de l'erreur

L'erreur pour un exemple est mesurée par :

$$E = \frac{1}{2} \sum_{p=1}^p (s_k - z_k)^2 \quad (3.8)$$

S_k : sortie attendue.

$-Z_k$: sortie réelle du réseau.

L'étape de rétro-propagation passe par quatre étapes :

1. Calculez le taux de changement de l'erreur lorsque la sortie réelle change, c'est-à-dire la différence entre la sortie réelle du réseau et la sortie attendue.
2. Calculez le taux d'erreur dans la somme des entrées reçues par l'unité de sortie. Cela revient à multiplier l'erreur trouvée par la dérivée de la fonction d'activation de cette unité.
3. Calculez la vitesse de changement de l'erreur lors de la modification des poids des connexions entre les neurones. Pour cela, on multiplie le taux d'erreur par l'activité du neurone précédent et par la dérivée par rapport au poids.

4. Calculez le taux de changement de l'erreur au niveau de l'activité d'unité dans la couche précédente. Ce processus est essentiel pour permettre l'application de la rétro- propagation dans les réseaux neuronaux à plusieurs couche.

En utilisant les étapes 2 et 4, cette procédure peut être appliquée au reste des couches du réseau neuronal.

Donc:

La Rétro propagation de l'erreur:

- a) Erreur pour la sortie :

$$E_k = (s_k - z_k) (1 - z_k) z_k \quad (3.9)$$

- b) Erreur pour la couche cachée :

$$F_j = y_j(1 - y_j) \sum_{k=1}^p w_{kj} E_k \quad (3.10)$$

Mise à jour des poids:

- c) Entre entrée et cachée :

$$\Delta V_{ji} = \eta y_j F_j$$

$$\Delta x_0 = \eta F_j$$

- d) Entre cachée et sortie :

$$\Delta W_{kj} = \eta z_k E_k$$

$$\Delta y_0 = \eta E_k$$

η Est le taux d'apprentissage

L'organigramme :

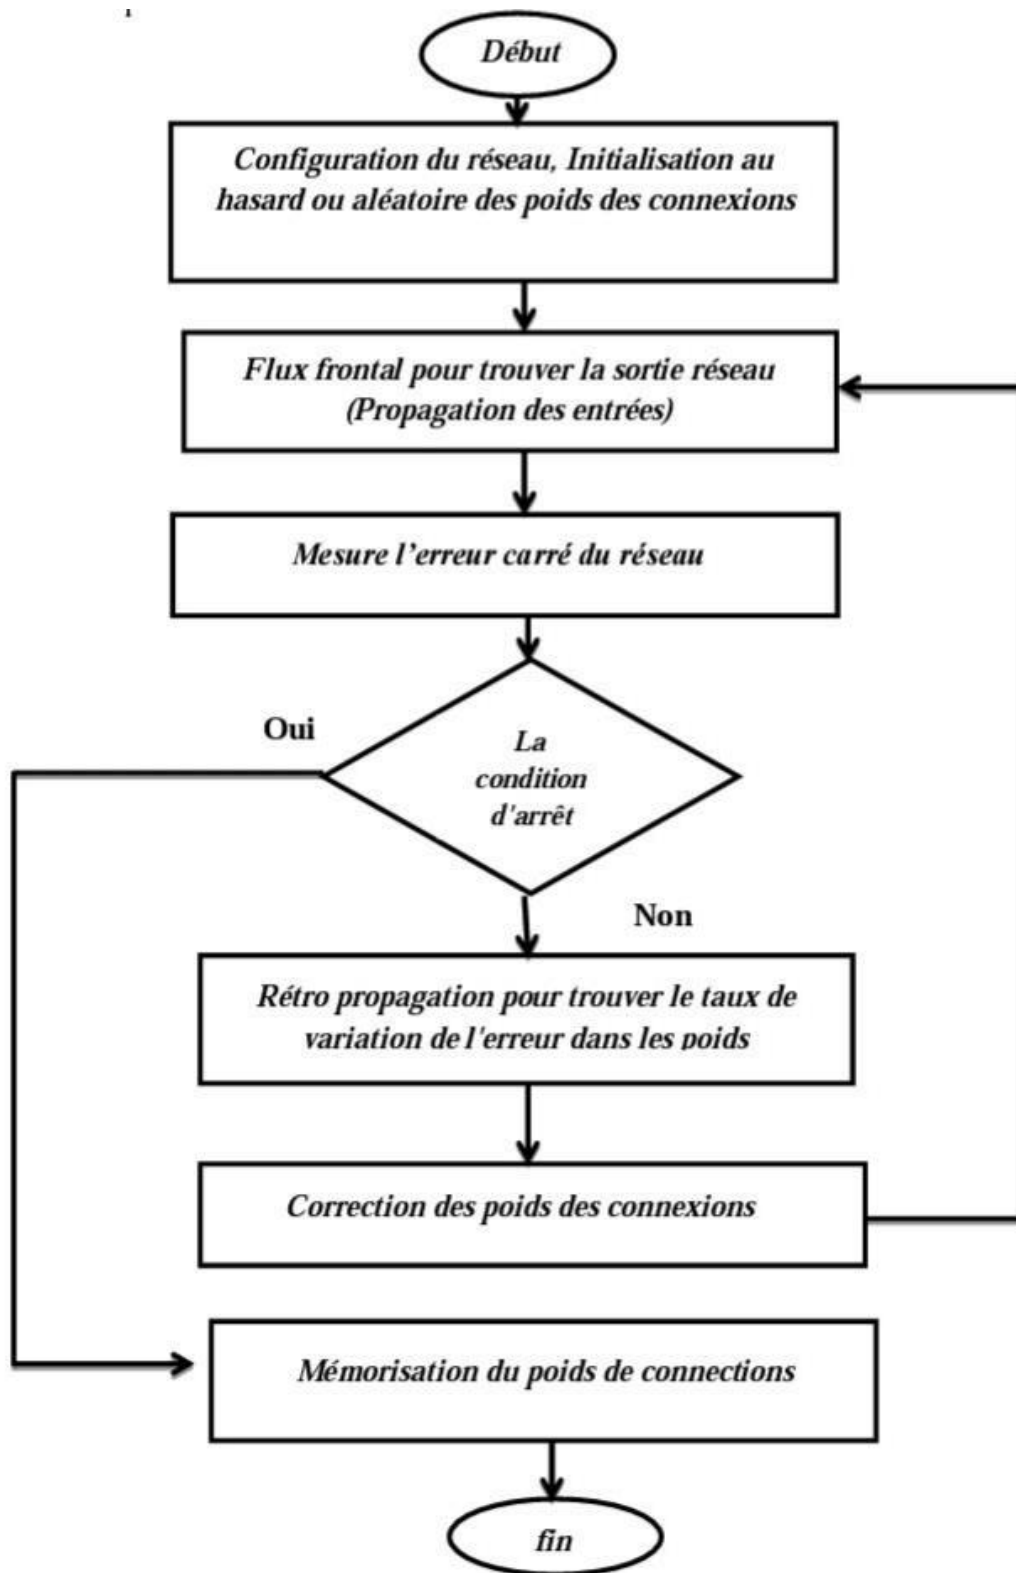


Figure 3.5 : Organigramme de l'algorithme de rétro-propagation du gradient. [21]

3.5 Avantages et inconvénients des techniques de prédiction:

3.5.1 La Régression :

Les avantages :

- Facile à mettre en œuvre et à interpréter
- Utile pour l'analyse des données.
- Flexible et adaptable.

Les inconvénients :

- Donne des mauvaises performances s'il n'y a pas une relation linéaire.
- La plupart des phénomènes réels ne correspondent pas à la supposition du modèle Linéaire.
- Sensible aux valeurs aberrantes et au bruit.
- Sujet au sur ajustement et au sous-ajustement.

3.5.2 Perceptron Multi Couche (PMC) :

Les avantages :

- Classifieur très précis lorsqu'il est bien paramétré.
- Capacité d'apprentissage incrémentale.
- Scalabilité permettant une mise en œuvre sur de vastes bases de données.

Les inconvénients :

- Modèle en boîte noire, rendant difficile l'interprétation de la causalité entre Descripteurs et variable à prédire.
- Complexité dans le paramétrage, notamment pour déterminer le nombre optimal de neurones dans la couche cachée.
- Risque de convergence vers un optimum local.

3.6 Les étapes de développement de modèle de prédiction :

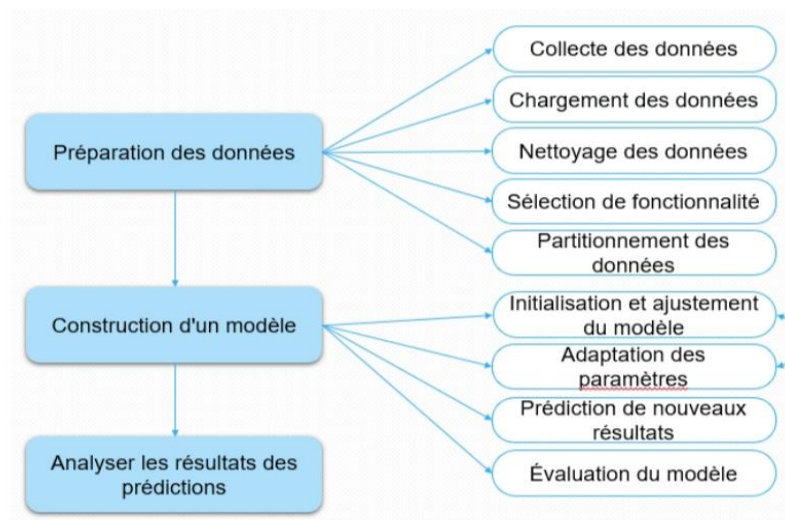


Figure3.6 : étapes de la prévision à l'aide de modèles d'apprentissage automatique .

Pour développer un modèle de prédiction de la consommation d'énergie électrique à l'aide de réseaux de neurones, vous pouvez suivre ces étapes générales :

1. **Collecte des données** : Rassemblez les données historiques sur la consommation d'électricité, en intégrant des variables influentes telles que la météo, l'heure, les jours fériés, et d'autres facteurs pertinents.
2. **Prétraitement des données** : Nettoyez et transformez les données en gérant les valeurs manquantes, en normalisant les variables et en structurant les caractéristiques pour les rendre exploitables par le modèle.
3. **Choix du modèle** : Sélectionnez une architecture de réseau de neurones appropriée, comme un perceptron multicouche (MLP), adapté aux tâches de prédiction.
4. **Construction du modèle** : Définissez la structure du réseau (nombre de couches, neurones par couche, fonctions d'activation) en tenant compte de la complexité du problème.
5. **Entraînement du modèle** : Séparez les données en ensembles d'apprentissage et de validation, puis entraînez le modèle à l'aide d'algorithmes d'optimisation (comme Adam ou SGD) pour ajuster les poids et les biais.

6. **Évaluation du modèle :** Mesurez la performance du modèle sur un ensemble de test en utilisant des indicateurs comme l'erreur quadratique moyenne (RMSE), l'erreur absolue moyenne (MAE) ou le coefficient de détermination (R^2).
7. **Optimisation et ajustement :** Affinez les performances du modèle en ajustant les hyperparamètres (taux d'apprentissage, nombre d'itérations, régularisation) et en explorant d'autres architectures si nécessaire.

3.7 Dataset :

Les données utilisées dans cette étude proviennent d'un dataset contenant des informations sur la consommation d'énergie mensuelle de « Sonelgaz Skikda », l'une des entreprises spécialisées dans le transport et la distribution d'électricité en Algérie. Ces données couvrent une longue période et fournissent des informations précieuses sur les tendances de consommation d'énergie.

Ce dataset contient des informations sur la consommation d'énergie mensuelle en unités de mégawatts (MW). Il a été retenu dans le cadre de notre travail pour les raisons suivantes :

Pertinence : le dataset est pertinent pour nos recherches, car il constitue une source importante pouvant être utilisée pour les prévisions ainsi que pour les techniques de prétraitement et d'analyse des données.

Taille : dataset est suffisamment grand pour représenter un défi intéressant à traiter, et pour être utilisé dans l'entraînement et le test de notre modèle.

Disponibilité : dataset est accessible au public, ce qui permet son utilisation académique, offrant ainsi une référence utile ; il est également reconnu pour sa grande qualité.

3.8 Métriques d'évaluation pour les modèles de prédiction :

Les métriques d'évaluation des modèles en apprentissage automatique sont des mesures quantitatives utilisées pour évaluer les performances des modèles de Prédiction. Ces mesures permettent de faire une comparaison entre les performances de différents modèles et aussi à l'optimisation des paramètres du modèle pour obtenir de meilleures prédictions.

• **Erreur moyenne absolue (Mean Absolute Error – MAE) :**

L'erreur moyenne absolue est la mesure de la différence entre les valeurs prédites et Les valeurs réelles. Elle est calculée en prenant la moyenne de la valeur absolue de ces Différences.[39]

Formule :

$$\text{MAE} = \frac{\sum_{i=1}^n |y_i - x_i|}{n}$$

Y_i = prédiction, x_i = valeur réelle, n = nombre total de points de données.

• **Erreur quadratique moyenne (Mean Squared Error – MSE) :**

L'erreur quadratique moyenne est la mesure de la différence entre les valeurs prédites Et les valeurs réelles. Elle est calculée en prenant la moyenne des carrés de ces Différences.[39]

Formule :

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{Y}_i)^2$$

N = nombre de points de données, y_i = valeurs observées, \hat{y}_i = valeurs prédites

• **Erreur quadratique moyenne racine (Root Mean Squared Error – RMSE) :**

L'erreur quadratique moyenne racine est la racine carrée de l'erreur quadratique Moyenne. Elle est une mesure plus intuitive de l'erreur que le MSE[40].

Formule :

$$\text{RMSE} = \sqrt{\text{MSE}}$$

• **Coefficient de détermination (R-squared) :**

Le coefficient de détermination est une mesure de la proportion de variance dans les Données expliquées par le modèle. Il est calculé en divisant la variance expliquée par La variance totale.[41]

Formule :

$$R^2 = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2}$$

• **Erreur absolue moyenne pondérée (Mean Absolute Percentage Error –**

MAPE) :

L'erreur absolue moyenne pondérée est une mesure de l'erreur moyenne en Pourcentage entre les valeurs prédites et les valeurs réelles. Elle est calculée en Prenant la moyenne de la valeur absolue de ces différences pondérées par les valeurs Réelles.[42]

Formule :

$$M = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_t - F_t}{A_t} \right|$$

M= MAPE, n = nombre de fois que l'itération de sommation se produit, A_t = valeur Réelle, F_t = valeur prévue.

3.9 Conclusion :

La sélection d'une méthode de prévision ne peut se faire sans une analyse rigoureuse du contexte d'application. Elle doit prendre en compte la nature des données, les objectifs du projet, ainsi que les contraintes techniques et humaines. Une bonne adéquation entre la méthode choisie et les spécificités du problème à traiter est essentielle pour garantir la fiabilité des prévisions et optimiser la prise de décision.

Chapitre4:

Realisation et implementation

4.1. Introduction :

Après avoir réalisé une étude comparative entre les deux techniques de prédiction, à savoir les réseaux de neurones et la régression linéaire, nous passons à leur implémentation pratique. L'objectif est d'analyser les performances de chaque méthode afin de déterminer laquelle s'avère la plus efficace dans le contexte de notre problématique.

4.2. Environnement de travail et langage de programmation :

L'implémentation de notre projet a été effectuée en utilisant le langage de programmation Python, reconnu pour sa richesse en bibliothèques scientifiques et sa simplicité de syntaxe. Pour le développement, nous avons opté pour l'environnement Anaconda, qui facilite la gestion des packages et propose une interface conviviale grâce à des outils tels que Jupyter Notebook.

4.2.1python :

Python est un langage de programmation de haut niveau, interprété et interactif. Il est orienté objet, ce qui permet de concevoir des programmes capables de simuler des comportements du monde réel. C'est un langage polyvalent, adapté à de nombreux domaines d'application.

Développé par Guido van Rossum entre 1985 et 1990, Python est reconnu pour sa simplicité aussi bien dans son apprentissage que dans son utilisation. Cette facilité en fait un choix privilégié pour une vaste communauté de développeurs.

Le langage s'appuie sur un large éventail de bibliothèques (ou packages), qui favorisent la modularité et la réutilisation du code. Ces bibliothèques sont généralement disponibles gratuitement sur la plupart des plateformes.

Grâce à cette simplicité et à sa flexibilité, de nombreux développeurs ont créé des bibliothèques spécialisées dans des domaines comme l'apprentissage automatique (machine learning), ce qui a renforcé sa popularité auprès des experts du domaine.



Figure 4.1 : Logo de python[43]

4.2.2 Anaconda :

Anaconda est une plateforme open source qui facilite la gestion des packages ainsi que la distribution d'environnements de développement pour des langages tels que Python, très utilisé dans les domaines de la science des données et de l'apprentissage automatique. Son principal objectif est de mettre à disposition des outils puissants destinés aux scientifiques des données, développeurs et analystes œuvrant dans des secteurs comme le traitement de données massives, l'analyse prédictive ou encore le calcul scientifique.

Anaconda se décline en deux versions : une version gratuite, appelée la distribution, et une version payante, Anaconda Enterprise, offrant des fonctionnalités supplémentaires pour les entreprises. Elle inclut par défaut des bibliothèques essentielles telles que Python, NumPy, Pandas et Jupyter, et repose sur Conda, un gestionnaire de packages et d'environnements, qui permet d'installer, de mettre à jour et de gérer facilement les dépendances nécessaires aux projets.

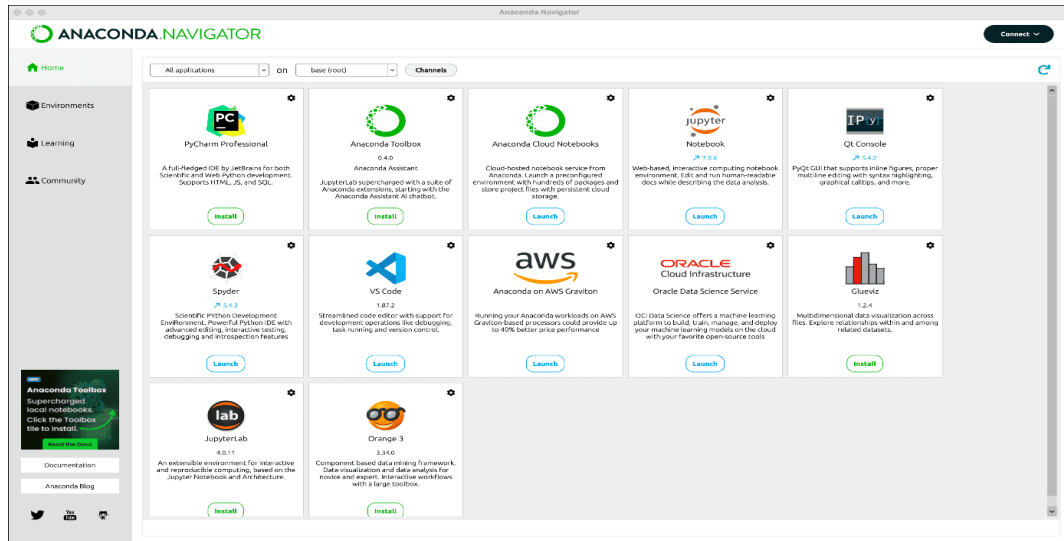


Figure 4.2 : le fenêtre d'accueil de l'environnement Anaconda[44]

Parmi les outils proposés, Jupyter Notebook est particulièrement apprécié. Cette application Web interactive permet de créer, exécuter et partager des documents mêlant code, texte, visualisations et équations, dans une interface conviviale. Elle est idéale pour l'analyse de données, la modélisation et le travail collaboratif.



Figure 4.3 :Logo de langage Jupyter[45]

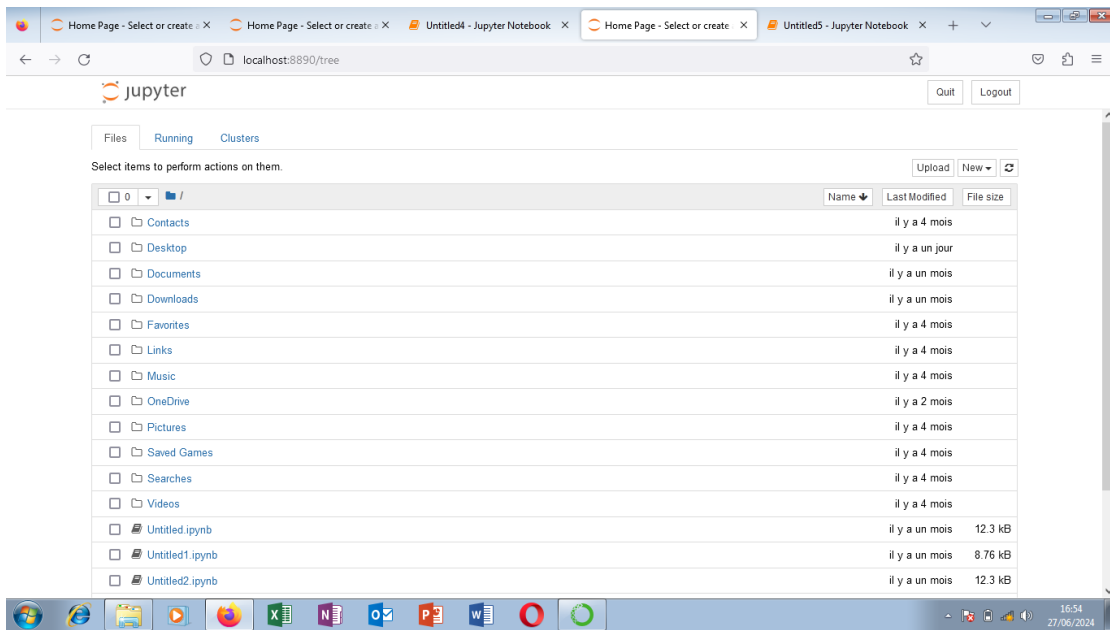


Figure 4.4: Fenetre d'accueil de l'application jupyter

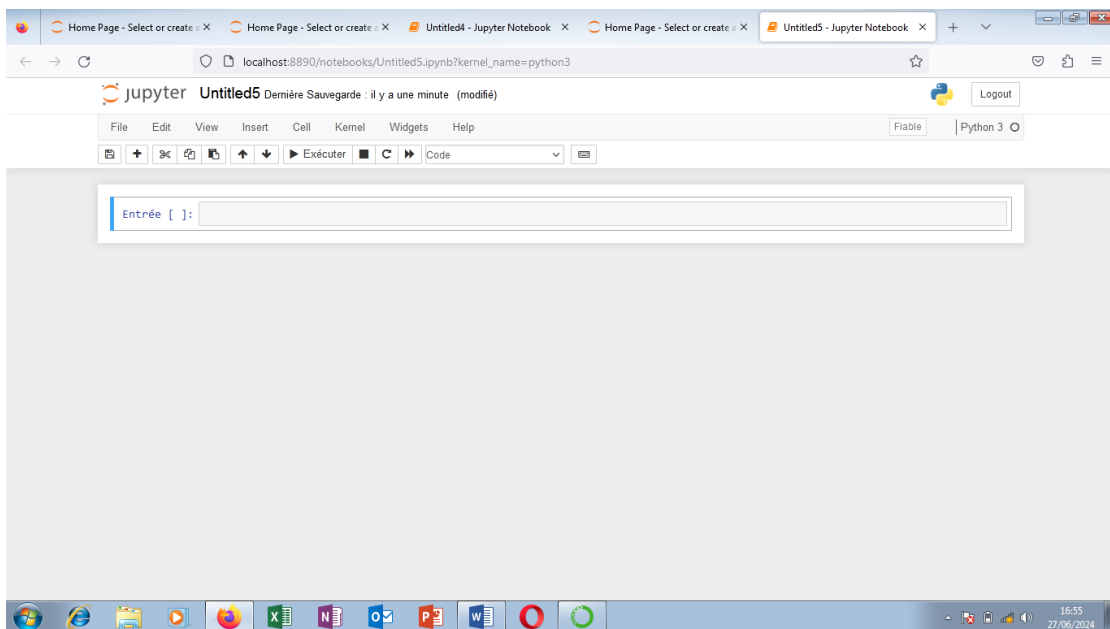


Figure 4.5:Fenetre d'exécution des programmes python

4.2.3 Les bibliothèques Python utilisées :

a. Matplotlib :

Matplotlib est une bibliothèque Python puissante dédiée à la création de graphiques et de visualisations de données. Elle permet de générer une grande variété de graphiques tels que des courbes, des histogrammes, des diagrammes circulaires, ainsi que des visualisations interactives, le tout de manière intuitive et flexible.

b. Tensorflow.keras.models.Sequential :

Cette classe fait partie du module Keras intégré à TensorFlow. Elle permet de construire des modèles de réseaux de neurones de manière séquentielle, c'est-à-dire en empilant les couches les unes après les autres. Cette approche est particulièrement adaptée pour des architectures simples et linéaires de réseaux de neurones

c. Tensorflow.keras.layers.Dense :

La couche Dense (ou couche entièrement connectée) permet d'ajouter une couche dans un modèle de réseau de neurones où chaque neurone est connecté à tous ceux de la couche précédente. Cette couche joue un rôle central dans l'apprentissage, en ajustant ses poids pour modéliser au mieux les relations entre les données d'entrée et la sortie attendue.

d. Sklearn.metrics :

Faisant partie de la bibliothèque scikit-learn, le module metrics fournit des outils pour évaluer les performances des modèles d'apprentissage automatique. Parmi eux, la fonction `mean_squared_error` calcule l'erreur quadratique moyenne entre les valeurs réelles et prédites, tandis que `r2_score` mesure le coefficient de détermination (R^2), indiquant la proportion de la variance des données expliquée par le modèle.

e. MinMaxScaler de sklearn.preprocessing :

Cette bibliothèque permet de transformer les données en les rescalant dans une plage définie, généralement entre 0 et 1. Cette mise à l'échelle est cruciale pour optimiser les performances des modèles statistiques et d'apprentissage automatique, notamment ceux sensibles aux variations d'échelle, comme les réseaux de neurones.

f. NumPy :

NumPy est la bibliothèque de base pour le calcul scientifique en Python. Elle facilite la manipulation de tableaux multidimensionnels et propose une large gamme de

fonctions mathématiques, y compris des routines d’algèbre linéaire, des transformées de Fourier, et des générateurs de nombres aléatoires. Sa syntaxe simple et expressive la rend accessible, même aux débutants.[46]

g. Pandas :

Pandas est une bibliothèque essentielle pour la manipulation et l’analyse de données. Elle offre des structures de données puissantes, comme les Data Frames, permettant de traiter, nettoyer, regrouper et filtrer les données avec peu de lignes de code. Pandas est particulièrement adaptée à l’analyse de données tabulaires ou temporelles.

h. `Train_test_split` de `sklearn.model_selection` :

Cette fonction permet de diviser un ensemble de données en deux parties : un ensemble d’entraînement et un ensemble de test. Cela permet d’évaluer la performance du modèle sur des données qu’il n’a jamais vues, évitant ainsi le sur apprentissage. La proportion de cette division est personnalisable (par exemple, 80% entraînement, 20% test).

i. `StandardScaler` de `sklearn.preprocessing` :

`StandardScaler` permet de centrer les données autour de la moyenne et de les normaliser selon leur écart type. Cette transformation est utile pour les modèles qui supposent une distribution normale des données ou qui sont sensibles à l’échelle des variables.[46]

j. `LinearRegression` de `sklearn.linear_model` :

Cette classe permet de créer un modèle de régression linéaire, l’un des modèles les plus simples et les plus utilisés en apprentissage automatique. Elle sert souvent de base de comparaison avec d’autres modèles plus complexes lors des phases expérimentales.

k. `MIPRegression` dans `sklearn.neural_network` de `scikit-learn` :

Fournit des outils pour construire et entraîner des réseaux de neurones artificiels, y compris différents types tels que MLP (Multi-layer Perceptron) . En important la classe `MLPRegressor` de cette bibliothèque, on peut créer et entraîner des modèles de Régression à plusieurs couches pour prédire des valeurs numériques.

l. `mean_squared_error` dans `sklearn.metrics` de `scikit-learn` :

Utilisée pour mesurer les performances des modèles dans la prédiction des données en Calculant la moyenne des erreurs quadratiques entre les valeurs prédites et les valeurs Réelle.

4.3 Programme Python pour les techniques de prédiction de la consommation :

Afin de comparer les performances d'un modèle de régression linéaire et d'un modèle de régression non linéaire , et d'un perceptron multicouche (MLP) pour prédire la consommation d'énergie électrique, nous allons suivre les étapes suivantes :

1. **Préparation des données** : Nettoyer et formater les données pour qu'elles soient compatibles avec les trois types de modèles.
2. **Création des modèles** : Concevoir et entraîner un modèle de régression linéaire et non linéaire d'un côté, et un modèle MLP de l'autre.
3. **Évaluation des performances** : Comparer les modèles à l'aide d'indicateurs comme l'erreur quadratique moyenne (MSE) et le coefficient de détermination (R^2).
4. **Visualisation des résultats** : Utiliser des graphiques pour illustrer les différences de performance entre les trois approches.

Dans ce contexte, nous allons aboutir à l'implémentation suivante :

#importation des bibliothèques

```
import numpy as np
import matplotlib.pyplot as plt
from sklearn.linear_model import LinearRegression
from sklearn.preprocessing import PolynomialFeatures, StandardScaler
from sklearn.pipeline import make_pipeline
from sklearn.neural_network import MLPRegressor
from sklearn.metrics import mean_squared_error, r2_score
from sklearn.model_selection import train_test_split
```

Données simulées

```
mois = np.arange(1, 13).reshape(-1, 1)
```

```
conso = np.array([320, 300, 310, 280, 270, 260, 250, 255, 265, 290, 310, 315])

# Séparer les données
X_train, X_test, y_train, y_test = train_test_split(mois, conso, test_size=0.3,
random_state=42)

# Régression Linéaire
model_lin = LinearRegression()
model_lin.fit(X_train, y_train)
pred_lin = model_lin.predict(X_test)

# Régression Polynomiale (degré 2)
poly_model = make_pipeline(PolynomialFeatures(degree=2), LinearRegression())
poly_model.fit(X_train, y_train)
pred_poly = poly_model.predict(X_test)

# Réseau de Neurones (MLP)
scaler_X = StandardScaler().fit(X_train)
scaler_y = StandardScaler().fit(y_train.reshape(-1, 1))

X_train_scaled = scaler_X.transform(X_train)
y_train_scaled = scaler_y.transform(y_train.reshape(-1, 1)).ravel()
X_test_scaled = scaler_X.transform(X_test)

mlp = MLPRegressor(hidden_layer_sizes=(10, 10), max_iter=2000,
random_state=42)
mlp.fit(X_train_scaled, y_train_scaled)
pred_mlp_scaled = mlp.predict(X_test_scaled)
pred_mlp = scaler_y.inverse_transform(pred_mlp_scaled.reshape(-1, 1)).ravel()

# Fonction pour afficher les résultats
def afficher_resultats(mois_test, y_true, preds, nom_modele):
    print(f"\n=== Résultats pour {nom_modele} ===")
```

```
print("Mois | Consommation réelle | Prédiction | Erreur absolue")
print("-"*45)
for m, vrai, pred in zip(mois_test.flatten(), y_true, preds):
    erreur = abs(vrai - pred)
    print(f"{m:4d} | {vrai:18.2f} | {pred:10.2f} | {erreur:14.2f}")
mse = mean_squared_error(y_true, preds)
r2 = r2_score(y_true, preds)
print(f"MSE : {mse:.2f} | R2 : {r2:.2f}")
```

Affichage des résultats pour chaque modèle

```
afficher_resultats(X_test, y_test, pred_lin, "Régression Linéaire")
afficher_resultats(X_test, y_test, pred_poly, "Régression Polynomiale")
afficher_resultats(X_test, y_test, pred_mlp, "Perceptron Multicouche")
```

Prédiction sur tous les mois pour affichage global

```
mois_entier = np.arange(1, 13).reshape(-1, 1)
pred_lin_all = model_lin.predict(mois_entier)
pred_poly_all = poly_model.predict(mois_entier)
mois_entier_scaled = scaler_X.transform(mois_entier)
pred_mlp_all = scaler_y.inverse_transform(mlp.predict(mois_entier_scaled).reshape(-1, 1)).ravel()
```

Tracer les courbes de tous les modèles

```
plt.figure(figsize=(10, 6))
plt.plot(mois_entier, conso, 'ko-', label='Consommation réelle', linewidth=2)
plt.plot(mois_entier, pred_lin_all, 'b--s', label='Régression Linéaire')
plt.plot(mois_entier, pred_poly_all, 'g--d', label='Régression Polynomiale')
plt.plot(mois_entier, pred_mlp_all, 'r--x', label='Perceptron Multicouche')

plt.title("Comparaison des Modèles sur les 12 mois")
plt.xlabel("Mois")
```

```
plt.ylabel("Consommation (kWh)")
plt.xticks(np.arange(1, 13))
plt.grid(True)
plt.legend()
plt.tight_layout()
plt.show()
```

Exemple de fichier CSV :

Mois,Consommation

Jan,320

Feb,305

Mar,310

Apr,280

May,265

Jun,260

Jul,250

Aug,255

...

...

...

...

Explication du programme :

1. Chargement des données :

Le programme charge les données à partir du fichier `energy_consumption.csv`. Ce fichier doit se trouver dans le même répertoire que le script, ou bien le chemin complet doit être spécifié.

2. Prétraitement des données :

- Les valeurs sont normalisées pour être comprises entre 0 et 1, ce qui facilite l'entraînement des modèles.

3. Division des données :

Les données sont réparties en deux ensembles :

-70 % pour l'entraînement

-30 % pour le test

4. Création et entraînement des modèles :

- Un modèle de régression linéaire et non linéaire est entraîné sur les données reshaped.
- Un perceptron multicouche (MLP) est également construit et entraîné sur les mêmes données reshaped.

5. Évaluation des modèles :

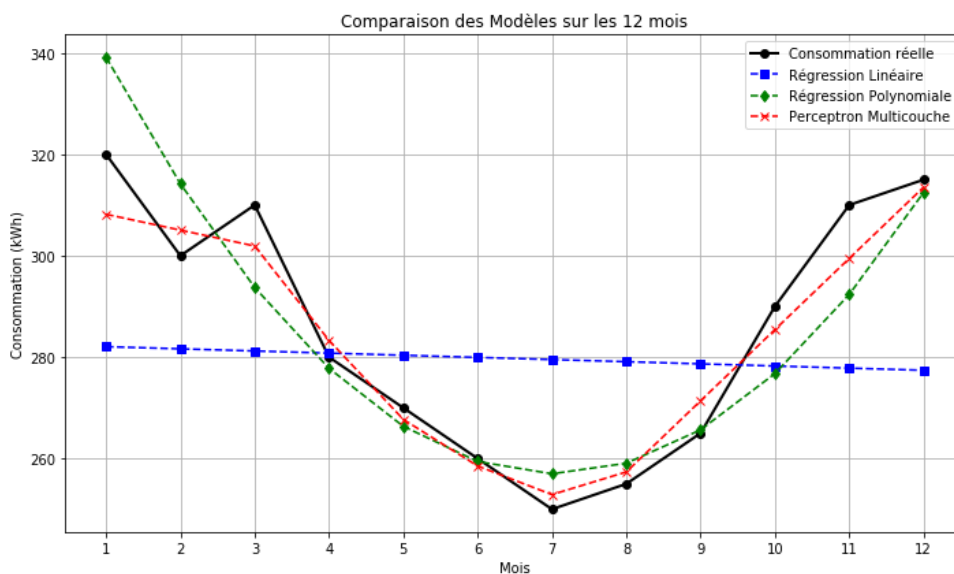
Les performances des modèles sont évaluées à l'aide de deux métriques :

- MSE (Mean Squared Error) : mesure l'erreur moyenne entre les prédictions et les valeurs réelles.
- R² (coefficient de détermination) : mesure la qualité de la prédiction

6. Visualisation des résultats :

Les prédictions des trois modèles sont comparées visuellement aux valeurs réelles à l'aide de graphiques, afin d'illustrer leur précision.

4.4 Les différentes courbes obtenus :



```

=== Résultats pour Régression Linéaire ===
Mois | Consommation réelle | Prédiction | Erreur absolue
-----
 11 |          310.00 |    277.83 |         32.17
 10 |          290.00 |    278.25 |         11.75
   1 |          320.00 |    282.06 |         37.94
   9 |          265.00 |    278.68 |         13.68
MSE : 699.77 | R² : -0.58

=== Résultats pour Régression Polynomiale ===
Mois | Consommation réelle | Prédiction | Erreur absolue
-----
 11 |          310.00 |    292.35 |         17.65
 10 |          290.00 |    276.75 |         13.25
   1 |          320.00 |    339.15 |         19.15
   9 |          265.00 |    265.66 |          0.66
MSE : 213.52 | R² : 0.52

=== Résultats pour Perceptron Multicouche ===
Mois | Consommation réelle | Prédiction | Erreur absolue
-----
 11 |          310.00 |    299.46 |         10.54
 10 |          290.00 |    285.43 |          4.57
   1 |          320.00 |    308.18 |         11.82
   9 |          265.00 |    271.39 |          6.39
MSE : 78.13 | R² : 0.82
    
```

4.5 Discussion des résultats :

Les résultats présentés concernent trois modèles de prédiction de la consommation d'énergie électrique :

1. Régression Linéaire
2. Régression Polynomiale
3. Perceptron Multicouche (réseau de neurones)

Analyse globale via le graphique:

Régression Linéaire (bleu) : Modèle très simpliste, la ligne est quasiment plate, ce qui ne capte aucune saisonnalité ni variation mensuelle.

Régression Polynomiale (vert) : Suit mieux la tendance globale de la consommation réelle. Elle capte bien les creux au milieu de l'année et les pics en hiver.

Perceptron Multicouche (rouge) : Très proche des données réelles sur presque toute l'année. Il capture avec précision les variations et semble être le modèle le plus performant visuellement.

2. Analyse quantitative (Tableaux de résultats):

➤ Régression Linéaire

MSE (Mean Squared Error) : `699.77` (le plus élevé)

R² (Coefficient de détermination) : `-0.58` (valeur négative → modèle non pertinent)

Erreurs absolues importantes sur plusieurs mois, jusqu'à 37.94 kWh

Modèle trop simple pour ce type de données temporelles non linéaires.

➤ Régression Polynomiale

MSE : `213.52` (amélioration significative)

R^2 : `0.52` (modèle commence à expliquer la variance)

Meilleure prise en compte des variations saisonnières, mais encore quelques erreurs notables, ex. mois 1 (erreur de 19.15 kWh)

Meilleur que la linéaire, mais limite en précision.

➤ Perceptron Multicouche

MSE : `78.13` (le plus faible)

R^2 : `0.82` (excellente capacité prédictive)

Faibles erreurs absolues, par exemple

Mois 10 : Erreur = 4.57 kWh

Mois 9 : Erreur = 6.39 kWh

C'est clairement le meilleur modèle des trois. Il arrive à capturer à la fois les pics et les creux avec une bonne précision.

4.6 Conclusion :

Ce dernier chapitre a été consacré à la présentation des outils de développement, avec un accent particulier sur la mise en œuvre d'un modèle de prédiction de la consommation d'énergie électrique basé sur les réseaux de neurones artificiels (RNA) de type MLP.

L'étude nous a permis de comparer deux approches de prévision : les réseaux de neurones MLP et la régression linéaire. Cette comparaison avait pour objectif d'évaluer la performance de chaque méthode et de déterminer laquelle s'avère la plus adaptée pour améliorer la précision des prédictions de la consommation énergétique.

Par ailleurs, nous avons illustré les résultats obtenus à travers les courbes représentant les valeurs réelles et celles prédites pour chaque technique.

Conclusion générale :

Conclusion générale et perspectives:

Le développement rapide des technologies et de l'urbanisation a entraîné une hausse significative de la demande en électricité, ce qui pourrait provoquer, à terme, une pénurie d'approvisionnement énergétique et une crise touchant aussi bien les producteurs que les consommateurs, l'électricité étant essentielle à tous les aspects de la vie moderne. Dans ce contexte, la prévision précise de la demande en énergie électrique constitue un enjeu majeur pour les décideurs afin de leur permettre de planifier et de gérer efficacement les ressources énergétiques.

Dans cette étude, nous avons exploré la possibilité de prévoir avec précision la consommation d'électricité en utilisant des techniques d'apprentissage automatique. Trois approches ont été mises en œuvre : la régression linéaire, la régression non linéaire, ainsi que le réseau de neurones artificiels MLP (Multi-Layer Perceptron). Ces modèles ont été appliqués à des données historiques de consommation électrique.

Après comparaison, les résultats ont montré que le modèle MLP offre une performance nettement supérieure à celle des modèles de régression pour prédire les valeurs futures de la consommation électrique.

Dans le cadre des perspectives futures, nous envisageons d'adopter des techniques avancées en apprentissage profond (Deep Learning) afin d'améliorer la précision des prévisions, ainsi que de développer un mécanisme de prévision à long terme, dans le but de renforcer la fiabilité et l'efficacité.

Bibliographie

- [1] «mafahem,» 13 02 2021. [En ligne]. Available :
<https://mafahem.com/%D8%AA%D8%B9%D8%B1%D9%8A%D9%81-%D8%A7%D9%84%D8%B7%D8%A7%D9%82%D8%A9-%D8%A7%D9%84%D9%83%D9%87%D8%B1%D8%A8%D8%A7%D8%A6%D9%8A%D8%A9>
- [2] [<https://fr.scribd.com/document/539401739/rapport-de-stage>].
- [3] Zerguine Bilal, « Modélisation d'un système de production électrique par la Cellule photovoltaïque » Mémoire De Magister, Université Badji Mokhtar Annaba, Algérie, 2010.
- [4] Toula Habib & Rahmouni Mohand Akli , « Prévission de la consommation D'énergie électrique en vue de la conduite et de la planification des réseaux Electriques en Algérie » Mémoire De Master, Université Abderrahmane Mira-Bejaia, 2016.
- [5] L'UE « autorise » la France à soutenir les producteurs d'énergie renouvelable.
- [6] Doc.Electable 2012- Université catholique de Louvain.
- [7] «wikipedia,» [En ligne]. Available :
https://ar.wikipedia.org/wiki/%D8%A7%D8%B3%D8%AA%D9%87%D9%84%D8%D9%83_%D8%A7%D9%84%D8%B7%D8%A7%D9%82%D8%A9?fbclid=IwAR3CkaCcSxhsawCebZdq_78N1HZKKIZCEvSsw-6WI220LUdCSzQd8mM9w60#cite_note-1.
[Accès le 16 03 2022].
- [8] calculs SDES, d'après les données de l'AIE.
- [9] Copyright © Ministère de l'énergie 2019 | Conception & réalisation ELIT.Spa Société du groupe SONELGAZ.
- [10] Direction Planification – Sonelgaz, M'sila.
- [11] Understanding the Global Energy Crisis (Purdue Studies in Public Policy) by Richard A. Simmons and Eugene D. Coyle | Mar 15, 2014, chapter 2.
- [12] <https://www.who.int/news/item/25-03-2014-7-million-premature-deaths-annually-linked-to-air-pollution>(consulté le 07/02/2023).

[13]Dr. Ahmed Qarareh Yusef Kabbas, Department of Curriculum and Instruction, Tafil

Technical University, Jordan, THE DEGREE OF RATIONALIZATION OF ENERGY

CONSUMPTION CONCEPTS INCLUDED IN THE SCIENCE TEXTBOOKS OF THE BASIC

STAGE IN JORDAN AND THE STUDENTS' ATTITUDES TOWARDS THEM, European

Scientific Journal, October 2015, edition vol.11.

[14]Division technique électricité (DTE)- Sonelgaz, Skikda.

[15] <https://www.sonelgaz.dz/fr/category/qui-sommes-nous>

[16] T.Wildi, « Electrotechnique »Avec la collaboration de Gilbert Sybille (ingénieur, institut de recherche d'Hydro-Québec) 4^{ème} édition : de boeck, 2005.

[17]Salem Aimene , «IA dans le secteur d'Énergie « PrédictionC as d'étude de Consommation d'Énergie »» Mémoire de master 2023].

[18]François B. et Michel V. « Les réseaux de neurones artificiels» Presses Universitaire, Paris, 1996].

[19] [https://www.researchgate.net/figure/Modele-dun-neuronebiologique_fig7_319939107]

[20] Bernard G. « Application de réseaux de neurones artificiels a la reconnaissAnce Au de. Caractères. Manuscrits» Thèse de Doctorat, Faculté polytechnique de Mons ,1996].

[21] [Boularas Noura et Djalab Charifa, «Système de la prévision mensuelle de la Consommation d'énergie électrique basée sur les réseaux de neurones artificielle» Mémoire de master 2020].

[22]N.J. Sairamy, L. Susmitha, S. Thomas George, M.S.P. Subathra, Chapter 12 – Hybrid Approach For Classification of Electroencephalographic Signals Using Time–Frequency Images With Wavelets and Texture Features, Editor(s) : D. Jude Hemanth, Deepak Gupta, Valentina Emilia Balas, In Intelligent Data-Centric Systems, Intelligent Data Analysis for Biomedical Applications, Academic Press, 2019, Pages 253-273, ISBN 9780128155530,

<https://doi.org/10.1016/B978-0-12-815553-0.00013-6>.

[23]Eñaut Muxika Olasagasti, «Application des réseaux de neurones à L'identification d'un axe de machine-outil » Sciences de l'ingénieur [physics], Institut National Polytechnique de Grenoble – INPG, 2002.

[24] G. Dreyfur, « Réseaux de neurones : Méthodologie et application », édition Eyrolles, 2004.

[25] Belgacem Amar, « Classification des signaux EGC avec un système-multiagent neuronale..», Mémoire Magister. Université Abou Bakr Belkaid-Tlemcen 2011-2012.

[26] Ali Djaidja, « Etude de la classification supervisée des données Environnementales à l'aide de réseaux de neurones de fonctions à base radiales » Mémoire de master, 2016.

[27] A.M. Ibrahim, « Fuzzy logic for embedded systems applications » Newnes Edition, United states of America, 2004.

[28] M.Ladjal, « Contribution au développement de systèmes de surveillance Innovants dédiés au contrôle de la qualité des eaux potables » Thèse de doctorat, Université de M'sila, 2013.

[29] Sahraoui Mustapha, « Contrôle robuste des systèmes non linéaires par les Approches les approches de l'intelligence artificielle.» thèse doctorat, Université D'Oran1.

[30] S.Zeghlache, « Commande Intelligente » cours, université Mohamed boudiafM'sila, 2008.

[31] Rachid Ladjadj, Les réseaux se neurones 2002/2003 Site WEB :

<http://www-igm.univ-mlv.fr/~dr/XPOSE2002/Neurones/index.php?rubrique=Accueil>.

[32]Hadj Ali Begdadi, Mohamade Senouci, « Réseaux de neurone théorie et Pratique» 2

Eme Edition, Office des publications universitaires, page(31,32).

[33]https://projeduc.github.io/intro_apprentissage_automatique/regression.html

[34]<https://www.idbc.fr/tutoriel-modele-de-regression-lineaire-comment-evaluer-leshypotheses-du-modele/>.

[35]Les multi layer perceptron (MLP) Clément Châtelain, novembre 2003.].

[36] [Hatem Mezaache, « Les réseaux de Neurones formels Et Les systèmes Neuro-Flous Pour l'apprentissage par renforcement » Mémoire de Magister, Université El Hadj Lakhdar Batna, 2008.] .

[37]https://www.researchgate.net/figure/Structure-de-modele-de-reseau-de-neuronesartificiels_fig5_322263283.

[38] Abdelahe Ali Elmesselali, Ahemade Abdelkader djoha, « Réseaux deNeurones pour la prédiction dans des séries chronologiques à l'aide de la méthode d'apprentissage par retropropagation postérieure » Mars 2019].

[39] A .Géron, Hands-On Machine Learning withScikitLearn.https://www.academia.edu/es/37865470/Hands_on_Machine_Learning_with_Scikit_Learn_and_Tensorflow, United States of America, 2017.

[40] R.Plipmann, « An introduction to computing with neurel network,IEEEASSP Mgazine » April 1987.

[41]Zeyu Wang, Ravi S. Srinivasan, A review of artificial intelligence-based building energy use Prediction : Contrasting the capabilities of single and ensemble prediction models, Renewable And Sustainable Energy Reviews, Volume 75, 2017, Pages 796-808, ISSN 1364-0321,

[42] Thibault Hubert, « Prévission de la demande et pilotage des flux en Approvisionnement lointain » Thèse de doctorat, L'ecole centrale paris et Manufactures, 2013.

[43]Faci Lina ,Tiabi Imene «Analyse d'opinion politique dans les réseaux sociaux» Mémoire de master , 2019.2020].

[44] [https://www.weblisto.com/fonctionnalite/2_installation_danaconda/].

[45] [https://www.memoireonline.com/12/22/13619/m_Etude-et-mise-en-place-dunoutil-de-classification-de-documents11.html]

[46] [D. Bertsekas. Dynamic Programming : Determinist. And Stochast. Models. Prentice-Hall, 1987].