

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTRE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE
SCIENTIFIQUE



UNIVERSITE ECHAHID HAMMA LAKHDAR D'EL-OUED



FACULTE DES SCIENCES EXACTES

Département d'informatique

Mémoire de Fin D'étude Présenté pour l'obtention du Diplôme de

MASTER ACADEMIQUE

Domaine : Mathématique et Informatique

Filière : Informatique

Spécialité : Systèmes Distribués et Intelligence Artificielle

Présenté par :

- BOUGUESBA OUARDA
- GUELBOU AMIRA

Thème

**Application d'un modèle d'apprentissage
automatique pour la prévision météorologique**

Soutenue le: 07/06/2023. Devant le jury:

BALI MOUADH..... Président

GHERBI KADDOUR.....Rapporteur

GUIA SANA SAHAR..... Encadreure

Année Universitaire: 2022/2023.

REMERCIEMENT

Louange à DIEU, qui nous a éclairés sur le chemin de la connaissance et de la connaissance, nous a aidés à accomplir ce devoir et nous a permis d'achever ce travail, et que la prière et la paix soient sur Son Prophète.

Avant tout, nous remercions DIEU Tout-Puissant qui nous a aidés depuis la première étape de notre parcours académique jusqu'à maintenant.

Maintenant, nous exprimons nos sincères remerciements, notre gratitude et notre appréciation à notre enseignante superviseure Guia Sana Sahar , pour sa bonne supervision et ses conseils. Nous sommes très fiers qu'elle ait été la professeure responsable de ce rapport, et à tous ceux qui ont contribué à nous aider de de loin ou de près, même avec une petite idée.

Nous adressons également nos remerciements aux membres du comité de discussion qui ont pris la peine de lire et de discuter de cette thèse, et nous n'oublions pas d'adresser nos remerciements à nos estimés professeurs qui ont participé avec nous à notre parcours académique au cours de notre carrière universitaire, et nous n'oublions pas tous les collègues et proches sans exception.

Dédicace

*Au nom de Dieu qui nous a permis de terminer ce modeste travail scientifique
que nous dédions :*

*À ceux qui ont été crédités du début à la fin, après Dieu Tout-Puissant, mes
parents bien-aimés, je leur souhaite bonne santé et bien-être*

À tous mes chers frères

*À mon partenaire dans la vie avant mon partenaire dans ce travail, ma chère
soeur "Ouarda"*

À tous ceux qui m'ont soutenu et soutenu

À mes amis et proches les plus chers avec qui les souvenirs m'ont rapproché

*À tous ceux qui m'ont appris une lettre du premier jour de ma carrière
universitaire*

AMIRA

Dédicace

À ceux qui m'ont mis sur le chemin de la vie, à ceux qui m'ont appris le dévouement au travail, la patience et l'ambition d'atteindre le meilleur, à ceux qui ont dépensé le précieux et le précieux sur mon chemin

A mes chers parents

A l'exemple du don, de la fierté et du sacrifice mes frères et soeurs

A celle qui partage mes nuits avec moi, mon amie et ma soeur, mon associée

"AMIRA"

A celui qui m'a inspiré une lueur d'espoir, m'a soutenu, et m'a motivé avec mes amis dans l'appart

À ceux qui sont restés avec nous, nous ont guidés et ont travaillé dur pour nous, notre professeur humble et décent, le Dr : "Guia Sana Sahar"

À tous les enseignants honorables, que Dieu vous bénisse avec la santé et le bien-être

Je vous dédie cette recherche

Et je vous informe que la réalisation de mon travail n'aurait pas été possible sans votre soutien, et j'espère qu'il sera satisfait de vous.

OUARDA

RÉSUMÉ :

Les effets de la météo imprègnent presque tous les aspects de notre vie quotidienne, des voyages au commerce en passant par le gouvernement. Fournir des prévisions météorologiques précises peut accroître l'efficacité de la planification et de l'allocation des ressources par les particuliers et les entreprises.

Le sujet abordé dans cette thèse est le développement d'un système de prévision météorologique par l'application d'un modèle d'apprentissage automatique (machine learning) basé sur l'apprentissage profond (Deep Learning). Le modèle est formé sur des données météorologiques passées, ce qui diffère des modèles numériques de prévision météorologique standard qui créent des représentations mathématiques des lois physiques.

Dans ce contexte, nous avons proposé les Mémoire à long et court terme (LSTMs) qui est une forme de RNN (Recurrent Neural Network) couramment utilisé pour la prédiction de séries temporelles ou nous nous sommes concentrés sur deux facteurs principaux : la température et l'humidité.

Mots clés: Prévision météorologique ; apprentissage automatique; deep learning ; séries temporelles; LSTM; la température; l'humidité.

ABSTRACT :

The effects of weather permeate nearly every aspect of our daily lives, from travel to commerce to government. Providing accurate weather forecasts can increase the efficiency of planning and resource allocation by individuals and businesses.

The subject addressed in this thesis is the development of a weather forecasting system by the application of a machine learning model based on deep learning. The model is trained on past weather data, which differs from standard numerical weather forecasting models which create mathematical representations of physical laws.

In this context, we have proposed Long and Short Term Memory (LSTMs) which is a form of RNN (Recurrent Neural Network) commonly used for time series prediction where we will focus on two main factors: temperature and humidity.

Keywords: Weather forecast ; machine learning; deep learning; time series; LSTM; temperature; humidity.

ملخص:

تتخلل تأثيرات الطقس تقريبًا كل جانب من جوانب حياتنا اليومية ، من السفر إلى التجارة إلى الحكومة. يمكن أن يؤدي تقديم تنبؤات دقيقة بالطقس إلى زيادة كفاءة التخطيط وتخصيص الموارد من قبل الأفراد والشركات.

الموضوع الذي نتناوله هذه الأطروحة هو تطوير نظام التنبؤ بالطقس من خلال تطبيق نموذج التعلم الآلي القائم على التعلم العميق. تم تدريب النموذج على بيانات الطقس السابقة ، والتي تختلف عن النماذج الرقمية القياسية للتنبؤ بالطقس والتي تخلق تمثيلات رياضية للقوانين الفيزيائية.

في هذا السياق ، اقترحنا الذاكرة طويلة وقصيرة المدى (LSTMs) والتي هي شكل من أشكال RNN (الشبكة العصبية المتكررة) المستخدمة بشكل شائع للتنبؤ بالسلسلة الزمنية ، حيث ركزنا على عاملين رئيسيين: درجة الحرارة والرطوبة.

الكلمات المفتاحية:

التنبؤ بالطقس، التعلم الآلي، التعلم العميق، السلاسل الزمنية، LSTM، درجة الحرارة، الرطوبة.

TABLE DES MATIÈRES

Table des matières	i
Table des figures	v
Liste des tableaux	1
La prévision météorologique	1
1 La prévision météorologique	3
1.1 Introduction	4
1.2 Définition du prévision météorologiques	4
1.3 Les applications de prévision météorologique et leur importance	4
1.3.1 Industrie	4
1.3.2 Transport	7
1.3.3 Gestion des catastrophes	7
1.3.4 Énergie	8
1.4 Types de prévisions météorologiques [1]	9
1.4.1 Méthode analogique	9
1.4.2 Méthode de la persistance et des tendances	9
1.4.3 Prévision numériques météorologiques	9
1.4.4 Regarde le ciel	9
1.4.5 Utilisation d'un baromètre	9
1.4.6 Présentation immédiate	10
1.4.7 Utilisation des modèles de prévision	10

1.4.8	Prévision d'ensemble	10
1.5	Les méthodes de prévisions météorologiques	11
1.5.1	Données de l'espace et des satellites	11
1.5.2	Données de la surface de la Terre	12
1.5.3	prévisions météorologiques par des modèles physiques de l'atmosphère	13
1.5.4	Technique Réseau neuronal artificiel(ANN)	13
1.6	L'intelligence Artificielle	13
1.6.1	Concept de base de l'intelligence artificielle (IA)	13
1.6.2	La nécessité d'apprendre l'IA	14
1.6.3	Qu'est-ce que l'Intelligence ?	14
1.6.4	Types d'intelligence	14
1.6.5	Composantes de l'intelligence	15
1.6.6	domaines de l'intelligence artificielle	16
1.6.7	Application de l'IA	16
1.7	Système à base de connaissances	20
1.8	System Expert SE	20
1.8.1	Définition	20
1.8.2	Classe les méthodologies ES[2]	21
1.8.3	les Objectifs de Système Expert et domaines d'utilisation	21
1.9	Conclusion	22
2	Approches basées sur l'apprentissage automatique	23
2.1	Introduction	24
2.2	Définition de l'apprentissage automatique (Machine Learning ML)	24
2.3	Algorithme d'apprentissage automatique	25
2.3.1	L'apprentissage supervisé (Supervised Learning SL)	25
2.3.2	Algorithme supervisé	28
2.3.3	Apprentissage non supervisé	30
2.4	Classification	32
2.5	Regression	32
2.5.1	Types de modèles de régression[3]	32
2.6	Techniques d'apprentissage automatique utilisées dans les prévisions météorologiques	33

2.6.1	Réseau neuronal	33
2.6.2	Le réseau bayésien	33
2.6.3	la régression linéaire	34
2.6.4	régression fonctionnelle	34
2.7	L'apprentissage en profondeur (Deep Learning)	34
2.7.1	définition	34
2.7.2	Réseau de neurones à convolution (CNN)	34
2.7.3	Machines Boltzmann à restriction conditionnelle (Conditionally Restricted Boltzmann Machines CRBM)	40
2.7.4	Applications de l'apprentissage en profondeur	41
2.7.5	Apprentissage par transfert	41
2.8	Techniques d'apprentissage en profondeur pour les prévisions météorologiques	42
2.8.1	Réseaux de neurones récurrents(RNN)	42
2.8.2	Mémoire à long et court terme (LSTM Networks)	43
2.9	Les travaux	44
2.10	Conclusion	46
3	Méthodologie de prévision météorologique	47
3.1	Introduction	48
3.2	données temporelles	48
3.3	RNNs(Les réseaux de neurones récurrents)	48
3.3.1	Définition	48
3.3.2	Architectures de réseaux de neurones récurrentes	49
3.3.3	Les RNN sont-ils trop expressifs ?	50
3.4	LSTM(Mémoire à long et court terme)	51
3.4.1	Définition	51
3.4.2	Applications connexes	52
3.5	Méthodologie	54
3.5.1	Comment créer un formulaire lstm	54
3.5.2	Architecture de réseau	57
3.5.3	Visualisez le LSTM avec nos prévisions météo	60
3.5.4	La structure générale du modèle proposé	62
3.6	conclusion	63

4 REALISATION DU SYSTEME	64
4.1 Introduction	65
4.2 Environnement de développement :	65
4.2.1 Environnement matériels(Hardware) :	65
4.2.2 Environnement logiciel(Software) :	65
4.3 Les étapes du code :	68
4.3.1 Dataset :	68
4.3.2 Section de prétraitement	69
4.3.3 Section de visualisation	71
4.3.4 Section modélisation prédictive	73
4.4 Conclusion	80
Bibliographie	82

TABLE DES FIGURES

1.1	La couverture des satellites en orbite polaire et des capteurs utilisés en opération[4]	11
1.2	capteurs sur les engins spatiaux géostationnaires[4]	12
1.3	composants de l'intelligence	16
1.4	La structure du système expert[5]	21
2.1	niveaux d'apprentissage automatique	25
2.2	Schéma montrant l'apprentissage supervisé	26
2.3	Arbre de décision	27
2.4	L'illustration de base de la classification KNN.[6]	29
2.5	Forêt aléatoire[7]	30
2.6	Diagramme montrant l'apprentissage non supervisé	30
2.7	Types d'apprentissage non supervisée	31
2.8	Technique Regroupement	31
2.9	Types de modèles de régression	32
2.10	Présentation du réseau de neurones convolutifs (CNN) Formation architecture et process. [8]	36
2.11	Ensemble de convolution (bleu). Ils sont liés à un même champ récepteur (rouge)[9]	38
2.12	regroupement avec un filtre 2x2 et un pas de 2 [10]	39
2.13	exempl CNN [11]	40
2.14	Une simple mémoire de blocs LSTM [12]	44
3.1	Un exemple de réseau neuronal récurrent entièrement connecté.	49
3.2	Un exemple de réseau récurrent simple.	50
3.3	Architecture d'un bloc LSTM vanille typique.	52

3.4	Architecture RNN LSTMP. Un seul bloc de mémoire est représenté pour plus de clarté.[13]	58
3.5	Schéma général du RNN LSTMP.[13]	59
3.6	la structure générale de lstm[14]	60
3.7	la couche de porte[14]	61
3.8	Portail d'entrée[14]	61
3.9	Porte de sortie[14]	62
3.10	Schéma général montrant l'architecture du réseau de neurones artificiels utilisé	63
4.1	Logo Python	66
4.2	TensorFlow Logo[15]	66
4.3	Pandas Logo[16]	66
4.4	Logo Keras[17]	67
4.5	Logo NumPy[18]	67
4.6	Logo Seaborn [19]	67
4.7	Logo Google colab	68
4.8	Code Python pour Importation des données	69
4.9	données de post-traitement	69
4.10	la liste des bibliothèques	69
4.11	Résumé des informations du fichier 'CSV'	70
4.12	Supprimer la colonne 'Daily Summary'	70
4.13	calculer le nombre de valeurs manquantes	71
4.14	Pré-traitement des données	71
4.15	la matrice de corrélation	72
4.16	nuage de points pour les colonnes "Température" et "Humidité"	72
4.17	comparer la vitesse du vent et la météo	73
4.18	Division des données	73
4.19	Code Python pour Model Lstm	74
4.20	Ajuster le modèle	74
4.21	modèle loss(températe)	75
4.22	modèle loss (humidité)	75
4.23	Prévision	75
4.24	Précision du modèle entraîné par rapport à la température	76
4.25	Précision du modèle entraîné pour l'humidité	77

4.26	taux d'erreur par rapport à la température(RMSE)	77
4.27	Taux d'erreur relatif à l'humidité(RMSE)	77
4.28	Taux d'erreur relatif à la température(MSE)	78
4.29	Taux d'erreur relatif à l'humidité(MSE)	78
4.30	comparer la température et l'humidité réelle et prédite	79
4.31	Le résultat	80
4.32	Exemple de prédiction de date	80

INTRODUCTION GÉNÉRALE

Nous sommes toujours avec ou à propos des prévisions météorologiques ; Nous le portons toujours avec nous et ne voulons jamais nous en séparer. En moyenne, nous pouvons rencontrer cela environ quatre à cinq fois par jour : journal télévisé, journal, tweets, chats, télévision, applications mobiles, Internet, etc.

Les prévisions météorologiques sont l'un des sujets les plus importants qui ont affecté la vie et les activités des gens sur une longue période. C'est un type d'activité scientifique qui contribue au bien-être social et économique dans de nombreuses régions du monde. Les gens peuvent également connaître et percevoir les changements atmosphériques à travers des variables telles que la température, la vitesse et la direction du vent. Les variations de ces paramètres météorologiques décrivent l'état de l'atmosphère à un moment donné.

La prévision météorologique est devenue un domaine de recherche important et a toujours été pratiquée depuis l'Antiquité. Il existe une variété d'utilisateurs finaux de prévisions météorologiques. Les avertissements météorologiques sont des prévisions importantes car ils sont utilisés pour protéger la vie et les biens. Les prévisions basées sur la température et les précipitations sont importantes pour l'agriculture, et les entreprises de services publics utilisent les prévisions météorologiques pour estimer la demande au cours des prochains jours. Il fournit des informations importantes sur les conditions météorologiques futures, dont certaines concernent la planification du contrôle climatique dans l'industrie de l'énergie. La prévision précise des conditions météorologiques est une tâche difficile en raison de la nature dynamique de l'atmosphère. Parmi ces variables, on a constaté que les plus importantes sont sélectionnées pour participer au processus de prédiction. Les variables et leurs plages diffèrent toujours d'un endroit à l'autre. Au cours de la dernière décennie, pour résoudre le problème de la prévision météorologique de nombreux efforts significatifs utilisant des modèles statistiques, y compris des techniques

d'apprentissage automatique ont été rapportés. Des modèles de réseaux de neurones ont été utilisés pour prédire la pluie, les écoulements annuels régionaux, la température, la vitesse du vent et l'humidité. Dans ce travail, nous essayons de trouver le meilleur moyen en termes de précision, de rapidité et de faible capacité pour mener à bien ce processus important dans notre vie quotidienne. Nous allons suivre la structure suivante pour répondre à notre objectif :

Introduction général.

Chapitre 1 : La prévision météorologique

Dans ce chapitre, nous apprenons l'importance de la prévision météorologique et les diverses techniques et méthodes anciennes dans ce processus.

Chapitre 2 : Approches basées sur l'apprentissage automatique

Dans ce chapitre, le principe du machine learning et du deep learning est défini et différentes techniques sont représentées.

Chapitre 3 : Méthodologie de prévision météorologique

Identifier et discuter de la technologie utilisée.

Chapitre 4 : Réalisation de système

Les différents étapes de code et les résultats obtenus sont présentés

Puis nous terminons par **Conclusion général.**

CHAPITRE 1

LA PRÉVISION MÉTÉOROLOGIQUE

1.1 Introduction

La météo est l'un des facteurs les plus importants qui affectent la vie humaine du point de vue sanitaire, commercial, agricole...etc. Par conséquent, les scientifiques effectuent le processus de prévision du temps pour éviter le plus grand pourcentage de risques. Dans ce chapitre, nous discuterons du concept et de l'importance du processus mentionné ci-dessus, ainsi que des méthodes les plus importantes adoptées.

1.2 Définition du prévision météorologiques

La prévision météorologique est l'application de la science et de la technologie pour prédire l'état de l'atmosphère à un endroit particulier. Les prévisions météorologiques sont faites en collectant des données quantitatives sur l'état actuel de l'atmosphère et en utilisant une compréhension scientifique des processus atmosphériques pour mettre en évidence l'évolution de ces derniers[20].

1.3 Les applications de prévision météorologique et leur importance

La prévision météorologique est d'une grande importance dans de nombreuses applications ; Où les prévisions météorologiques ont montré qu'il y a de grands changements dans les affaires, le tourisme, les sports et la production d'énergie. Dans ce titre, nous discuterons de la manière dont ces régions sont affectées par les prévisions météorologiques[1].

1.3.1 Industrie

Agriculture ou Industrie alimentaire

Selon la croissance démographique, il doit y avoir une croissance de la production alimentaire pour répondre à la demande nutritionnelle. Avec l'aide de mégadonnées pour les prévisions météorologiques, cela peut être fait efficacement. Reckford a déclaré : « Si nos agriculteurs ici peuvent utiliser les ressources de la manière la plus efficace, vous disposez d'un système de production plus durable à long terme ».

Les prévisions météorologiques peuvent aider les agriculteurs à se préparer aux sécheresses, aux

excès d'eau et à l'érosion des sols. La prévision des précipitations devient nécessaire lorsqu'il s'agit de la protection des aliments, ces prévisions aident à gérer le transport des aliments là où la pénurie est attendue, elles aident les agriculteurs à prendre des décisions concernant leurs cultures et les prix des denrées alimentaires peuvent également être estimés. Les grandes chaînes de supermarchés utilisent les prévisions météorologiques pour planifier leur gestion des stocks, sachant qu'une période de temps froid entraînera une augmentation des ventes d'aliments comme la soupe, tandis qu'une période de temps chaud augmentera la demande de crème glacée et de barbecues.

Industrie du tourisme :

Le tourisme ne signifie pas seulement voyager pour les vacances ou la liberté ; cela peut aussi être pour l'éducation, la visite de parents et d'amis, la conférence et la santé. Le tourisme est l'une des industries à la croissance la plus rapide et la plus importante ; il a une contribution significative à l'économie du pays. Le Conseil mondial du voyage et du tourisme a estimé que la contribution de les voyages et le tourisme au PIB(Le produit intérieur brut) mondial était de 9,8% en 2015-2016.

Les destinations touristiques sont sensibles au climat, elles pourraient être affectées positivement ou négativement par le changement des conditions météorologiques. Par conséquent, les prévisions météorologiques deviennent plus importantes en ce qui concerne la sécurité et le confort des touristes et les objets qui attirent les touristes (tels que la couverture de neige, le corail récifs et faune).

Industries peuvent estimer leurs bénéfices en fonction des prévisions météorologiques, et les touristes peuvent également se préparer en conséquence. Par conséquent, comme l'ont mentionné D. Scott et C. Lemieux, "les demandes d'informations climatiques précises et de plus en plus détaillées devraient augmenter considérablement afin de permettre aux entreprises touristiques et aux destinations afin de minimiser les risques associés et de tirer parti des nouvelles opportunités offertes par le changement climatique, d'une manière économiquement, socialement et écologiquement durable ".

Industrie de la construction :

La construction peut être affectée par le vent, la température, l'humidité et le temps humide. Ainsi, pour protéger votre personnel, vos opérations et vos actifs contre les risques liés aux conditions météorologiques, vous avez besoin des meilleures informations disponibles.

Les prévisions météorologiques peuvent aider à identifier les menaces avant qu'elles ne surviennent et vous pouvez planifier autour d'eux, en économisant votre argent et des interruptions inutiles ou des blessures (ou pire) pour le personnel.

la prévision peut aider à la construction de bâtiments efficaces. Ricardo Enríquez, María José Jiménez et M^a del Rosario Herasa ont montré que "l'incertitude des prévisions de rayonnement solaire a le plus grand impact sur les performances du MPC. Le MPC (Model Predictive Control) est un problème clé pour traiter les bâtiments à énergie nette zéro (NZEB) et les communautés"

Selon les normes britanniques, la pression du vent est un paramètre important lorsqu'il s'agit de la facilité d'utilisation des grues pour la construction et la vitesse du vent augmente également avec l'augmentation de la hauteur au-dessus du niveau du sol, il devient donc difficile de travailler après une hauteur particulière sans préparations supplémentaires, donc la prévision du vent devient nécessaire pour une construction efficace et sûre. Il faut accorder de l'importance aux détails des prévisions d'inondation, car ils contribuent à la construction de bâtiments durables et solides pour l'avenir. Les détails des prévisions météorologiques sont nécessaires pour se préparer à la reconstruction des bâtiments si des conditions sévères sont attendues ; Les détails des fortes précipitations doivent être pris en compte sur les chantiers de construction de barrages car ils peuvent endommager les véhicules, les équipements et faire de nombreux morts

Industrie du sport :

De nombreuses industries du sport embauchent leur personnel météorologue, car les industries peuvent subir des pertes dues à la foudre et aux précipitations. La foudre est un danger potentiellement mortel pour les golfeurs et certains tournois majeurs nécessiteront donc un service de prévision immédiate d'un fournisseur de prévisions afin d'assurer la sécurité des joueurs tout en minimisant les perturbations du jeu. Les prévisions de précipitations pendant les tournois peuvent indiquer quand couvrir les courts. De petits changements de vent peuvent

également avoir de gros impacts sur le résultat d'une course à la voile; tant d'équipes olympiques de voile emploient leurs propres météorologues.

1.3.2 Transport

Les conditions météorologiques prévues dans le monde entier pourraient servir à informer les compagnies maritimes et les équipages du risque de tempête, leur permettant de décider quand naviguer et quelles routes emprunter.

Dans des conditions météorologiques extrêmes, il y a retards dans les horaires de vol, mais nous nous concentrons sur le maintien du même horaire dès que possible avec des retards et des annulations de vols réduits et pour cela, nous avons besoin de certains outils. David A. Smith et le Dr Lance Sherry ont mentionné que " les rapports météorologiques tels que le Prévisions d'aérodrome terminal(Terminal Aerodrome Forecast TAF) , le rapport météorologique de routine pour l'aviation (METAR) et le produit de prévision convective collaboratif (Collaborative Convective Forecast Product CCFP) fournissent tous des informations brutes sur les prévisions météorologiques. Le service météorologique national (National Weather Service NWS) fournit Prévisions d'aérodrome terminal (les TAF comprennent une prévision de la vitesse et de la direction du vent de surface, de la visibilité et des nuages. Le type de temps, les obstacles à la vision et le cisaillement du vent à basse altitude sont inclus au besoin) aux pilotes de l'aviation commerciale et générale pour la protection de la vie et des biens "

En cas de routes, il devrait y avoir des déviations appropriées en fonction des conditions météorologiques prévues, car en cas de fortes pluies et de verglas, les voyageurs pourraient faire face à de graves conséquences. Les véhicules Ariel sans pilote (Ariel Unmanned Vehicles AUV) offrent un haut niveau de flexibilité mais sont confrontés à de graves impacts météorologiques. Pour une mission réussie avec UAV, il faut tenir compte des prévisions météorologiques lors de l'évaluation des risques et de la planification de la mission.

1.3.3 Gestion des catastrophes

Les catastrophes naturelles sont inévitables, mais de bonnes prévisions et avertissements peuvent sauver de nombreuses vies, réduire les dommages et les pertes économiques. La prévision des catastrophes naturelles nécessite des recherches approfondies. L'utilisation d'une modélisation informatique de plus en plus sophistiquée et d'ordinateurs puissants aide la National Oceanic and Atmospheric Administration à prévoir des tempêtes telles que l'ouragan/supertempête

Sandy. La prévision d'un ouragan nécessite de grandes données, des modèles haute résolution qui intègrent la physique à grande échelle et une représentation précise des conditions initiales, et les simulations de NWRP ont été couronnées de succès jusqu'à présent, a déclaré le Dr Sundararaman Gopalakrishnan, contribuant à améliorer les prévisions d'ouragan jusqu'à 20%.

Bien que la précision des prévisions et le délai dépendent de la type de danger. Pas seulement des ouragans, même des glissements de terrain et des inondations peut gravement blesser ou tuer des personnes. Les tornades ont fait de nombreux morts personnes dans le passé, mais maintenant le système utilisé par National Weather Le service se compose d'environ 150 antennes radar massives réparties à travers le pays (États-Unis) recueillant les informations météorologiques.

Ils sont assis sur des tours dédiées de plusieurs étages et peuvent suivre les tempêtes à plus de 100 miles en appliquant l'analyse des données aux données collectées. Depuis l'apparition des mégadonnées, les prévisions météorologiques se sont beaucoup améliorées. De nouveaux moyens sont trouvés pour puiser l'eau des réservoirs sur la base des prévisions d'inondations ou de sécheresses. Cela pourrait être un moyen efficace et peu coûteux de garder l'exemple vital a été vu en 2015 à New York, il y avait une situation de fortes chutes de neige et très peu de pluie, mais New York n'a pas eu à rationner l'eau, avec l'aide de prévisions informées exploitation des réservoirs (Informed Forecasting Reservoir Operations IFRO), la ville a continué à puiser de l'eau dans les principaux réservoirs à des taux normaux en attendant les beaux jours. en quelques semaines, tous les réservoirs de la ville ont commencé à se remplir avec la fonte des neiges. Une grande perte a été sauvée grâce à des prévisions météorologiques appropriées.

1.3.4 Énergie

De nos jours, l'utilisation des énergies renouvelables devient prédominante, il faut donc prévoir le temps pour collecter le maximum d'énergie à partir de sources d'énergie renouvelables. L'énergie éolienne et solaire sont les sources renouvelables largement utilisées pour la collecte d'énergie, mais celles-ci dépendent des conditions météorologiques, de sorte qu'une prévision précise est nécessaire pour répondre à la demande d'énergie via ces sources.

En particulier, de nombreux scénarios de planification et de contrôle du « réseau intelligent » reposent sur des prévisions précises à court terme de la production d'énergie renouvelable, ce qui nécessite à son tour des prévisions précises de la vitesse du vent, de la couverture nuageuse, de la température et d'autres variables similaires. Des prévisions météorologiques précises à court terme permettent donc une intégration harmonieuse des énergies renouvelables dans les

futurs systèmes électriques intelligents . Les sociétés de production d'électricité peuvent gagner plusieurs milliers de livres sur la base d'une seule prévision météorologique d'une vague de froid, car cela leur permet d'acheter du gaz à bas prix avant que la demande accrue par temps froid ne fasse grimper les prix.

1.4 Types de prévisions météorologiques [1]

1.4.1 Méthode analogique

Cette méthode peut être utilisée pour prévoir la météo car elle nécessite de trouver la date dans le passé avec la météo, c'est comme une prévision actuelle, ce qui est difficile à faire.

1.4.2 Méthode de la persistance et des tendances

La persévérance et l'inclinaison nécessitent moins d'expertise pour prédire le temps car cela dépend des tendances passées. Dans le monde, le temps change, tout comme les prévisions météorologiques pour aujourd'hui. Cela nécessite seulement que vous vous teniez au courant des températures actuelles et que vous connaissiez les conditions météorologiques de la région.

1.4.3 Prévision numériques météorologiques

Les prévisions météorologiques sur les prix dépendent des ordinateurs pour trouver la météo. Des supercalculateurs plus grands aident les météorologues à faire des prévisions météorologiques basées sur de nombreuses conditions météorologiques.

1.4.4 Regarde le ciel

En regardant le ciel, vous pouvez déterminer le temps en voyant le soleil ou la lune ou si vous regardez des nuages très élevés. Dans le cas où les brumes sont nuageuses, il y a une opportunité pour un climat affreux un peu plus tard. Pour décider quand la tempête arrive, regardez si les nuages bougent ou non.

1.4.5 Utilisation d'un baromètre

La pression barométrique est utilisée dans les prévisions depuis le 19ème siècle. Au moment où un cadre à basse pression se rapproche, et il y a une possibilité plus notable d'averse. Les incréments de pression sont liés à conditions météorologiques améliorées.

1.4.6 Présentation immédiate

Les prévisions météorologiques pour les six prochaines heures sont communément appelées prévisions immédiates. À ce stade, il est possible de prédire de petites choses comme des orages individuels avec la bonne précision, tout comme des choses différentes qui sont trop peu nombreuses pour être traitées par un ordinateur.

1.4.7 Utilisation des modèles de prévision

Les prévisionnistes humains étaient responsables de la création de toutes les conditions météorologiques indiquées par les données disponibles. Aujourd'hui, les informations humaines sont souvent confinées à la sélection de modèles en fonction de différentes limites, par ex. modèle de discrimination et de performance. Il utilise l'harmonie des modèles climatiques, ainsi que l'intégration des membres d'un large éventail d'espèces, peut aider à réduire les erreurs environnementales. Dans tous les cas, quelle que soit la gravité de l'erreur dans n'importe quel système individuel, des erreurs majeures dans toute correction directionnelle spécifique peuvent se produire dans n'importe quelle opération de modèle donnée. Les particuliers peuvent utiliser des données sur les résultats locaux, qui peuvent être trop petits pour être réglés par un modèle pour ajouter des détails à une prévision.

1.4.8 Prévision d'ensemble

Bien que le modèle météo prédise l'évolution des conditions météorologiques dans un avenir lointain, les erreurs de prévision augmenteront inévitablement avec le temps en raison des turbulences atmosphériques et des incohérences à première vue. Les informations qui peuvent être données dans les prévisions diminuent après un certain temps à mesure que ces erreurs augmentent. Cela se transforme en un point où les erreurs sont incroyables à tel point que l'estimation ne peut pas répondre à l'atmosphère réelle. Cependant, en regardant une offre de prédiction, il n'y a aucune indication de la probabilité d'une telle précision de prédiction. La prévisibilité comprend la production de plusieurs prédictions en séquence pour montrer l'incertitude à la première atmosphère (due à des erreurs visuelles et à un échantillon inadéquat). L'incertitude est une prédiction qui peut être vérifiée car différentes prédictions sont générées. Les prévisions d'ensemble continuent d'être utilisées pour les prévisions météorologiques. Les attentes de groupe nécessitent une compréhension complexe de l'univers et des modèles informatiques.

1.5 Les méthodes de prévisions météorologiques

1.5.1 Données de l'espace et des satellites

Les satellites météorologiques sont divisés en deux grandes catégories :

Données des engins spatiaux en orbite polaire

Les engins spatiaux en orbite polaire font le tour de la Terre à des altitudes généralement inférieures à 1000 km et transportent de nombreux capteurs actifs et passifs pour observer l'atmosphère et la surface (énumérés à la figure 1.1). Avec ces engins spatiaux, l'accent est mis sur la réalisation de mesures à toutes les latitudes avec une variété de capteurs embarqués, mais cela se fait au détriment de la résolution temporelle. Un satellite peut effectuer des mesures à partir du même emplacement une ou deux fois par jour. Le réseau hétérogène de capteurs hautement sophistiqués portés par les engins spatiaux en orbite polaire fournit des observations complémentaires. Les sondeurs et imageurs hyperfréquences et infrarouges fournissent des informations sur la température et l'humidité en mesurant le rayonnement émis le long des trajets au nadir ou proche du nadir, ce qui donne des résolutions spatiales typiques comprises entre 15 et 50 km. Cependant, la résolution verticale que l'on peut obtenir est assez limitée (entre 1 et 2 km pour l'infrarouge et 3 et 6 km pour l'hyperfréquence)[4].



FIGURE 1.1 – La couverture des satellites en orbite polaire et des capteurs utilisés en opération[4]

Données des engins spatiaux géostationnaires

Les engins spatiaux géostationnaires orbitent autour de la Terre à une altitude de 36 000 km et ont tendance à ne transporter qu'un seul capteur passif infrarouge et visible. Avec ces engins spatiaux, l'accent est mis sur la réalisation de mesures aux latitudes basses à moyennes avec une échelle spatiale très fine et une résolution temporelle très élevée (presque continue).

Cependant, en raison de la géométrie de la vue aux hautes latitudes, les données deviennent plus difficiles à utiliser (les vecteurs de mouvement atmosphérique (AMV) ne sont pas générés systématiquement 60° de latitude, voir figure 1.2) et les capteurs géostationnaires sont limités aux sondeurs visibles et infrarouges avec très mauvaise résolution spectrale. Cela limite leur capacité à effectuer des mesures sous les nuages, et même en ciel clair, les informations de température et d'humidité ont une résolution verticale beaucoup plus faible que celle fournie par les capteurs transportés sur les plates-formes polaires. Cependant, l'échantillonnage temporel très élevé permet de suivre très précisément le mouvement des caractéristiques atmosphériques telles que les nuages et la vapeur d'eau pour fournir des informations sur le vent[4].

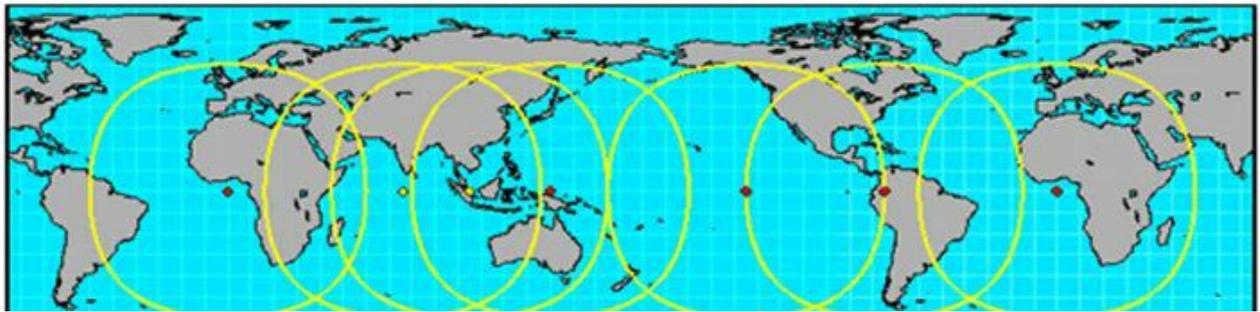


FIGURE 1.2 – capteurs sur les engins spatiaux géostationnaires[4]

figure

1.5.2 Données de la surface de la Terre

Les observations météorologiques de surface sont les principales données utilisées pour la sécurité ainsi que les causes climatiques pour prévoir les conditions météorologiques et émettre des avertissements dans le monde entier. Elle peut être prise manuellement par l'observateur météorologique, par ordinateur via des observateurs pour augmenter la station météorologique automatisée.

Le vaste réseau de stations météorologiques nécessaires pour produire une carte météorologique en comprendrait suffisamment pour être utile pour les prévisions à court terme.

À l'échelle mondiale, l'Organisation météorologique mondiale, qui regroupe plus de 130 pays, est responsable de la collecte des données requises et de la production de certaines cartes générales d'alerte.

Les observations météorologiques de surface de la pression atmosphérique, de la température, de la vitesse et de la direction du vent, de l'humidité et des précipitations sont effectuées près de la surface de la Terre par des observateurs formés ou automatisés.

L'Organisation météorologique mondiale s'efforce de normaliser les instruments, les pratiques

d'observation et le calendrier de ces observations dans le monde entier. Selon un accord international, des observations complètes régulières sont effectuées toutes les six heures à partir de minuit [21].

1.5.3 prévisions météorologiques par des modèles physiques de l'atmosphère

grâce à des simulations physiques dans lesquelles l'atmosphère est modélisée par échantillonnage, l'état actuel de l'atmosphère et l'état futur est calculé en résolvant des équations dynamiques, mais le système de diverses équations ordinaires qui régissent ce modèle physique instable compte tenu des turbulences météorologiques, ce qui fait douter des mesures initiales et de la précision des prévisions météorologiques [22].

1.5.4 Technique Réseau neuronal artificiel(ANN)

C'est un puissant outil de modélisation de données capable de capturer et de représenter des entrées/sorties complexes rapports, Il peut également être modifié pour produire une affectation d'un ensemble donné de données à des entités ou des relations entre les données[23].

1.6 L'intelligence Artificielle

1.6.1 Concept de base de l'intelligence artificielle (IA)

L'intelligence artificielle est un moyen de faire en sorte qu'un ordinateur, un robot contrôlé par ordinateur ou un programme pense intelligemment, de la même manière que le font les humains intelligents. L'intelligence artificielle est accomplie en étudiant comment l'esprit humain pense et comment les humains apprennent, décident et agissent tout en essayant de résoudre un problème, puis en utilisant les résultats de cette étude comme base pour développer des programmes et des systèmes intelligents.

Tout en exploitant la puissance des systèmes informatiques, la curiosité humaine l'amène à se demander : « Une machine peut-elle penser et agir comme des humains ?

Ainsi, le développement de l'intelligence artificielle a commencé dans le but de créer une intelligence similaire dans les machines que nous trouvons et détenons fortement chez les humains[24].

1.6.2 La nécessité d'apprendre l'IA

Parmi les raisons les plus importantes pour lesquelles nous nous soucions de l'intelligence artificielle, il y a les suivantes[24] :

- Il peut apprendre des données
- Il peut s'instruire
- Il peut répondre en temps réel
- atteint la précision
- Il peut organiser les données pour en tirer le meilleur parti
- Comprendre l'intelligence

1.6.3 Qu'est-ce que l'Intelligence ?

La capacité du système à agir de manière rationnelle (calculer, raisonner, percevoir les relations et les symétries, apprendre de l'expérience, stocker et récupérer des informations de la mémoire, résoudre des problèmes, comprendre des idées complexes, utiliser couramment le langage naturel, classer, généraliser et adapter de nouvelles situations)[24].

1.6.4 Types d'intelligence

L'intelligence est classée en plusieurs aspects[24] :

- Intelligence linguistique :
La capacité de parler, de reconnaître et d'utiliser les mécanismes de la phonologie (sons de la parole), de la syntaxe (grammaire) et de la sémantique (signification).
- Intelligence musicale :
La capacité de créer, de communiquer et de comprendre les significations du son, la compréhension de la hauteur, du rythme.
- Intelligence mathématique logique :
La capacité d'utiliser et de comprendre les relations en l'absence d'action ou d'objets. C'est aussi la capacité de comprendre des idées complexes et abstraites.
- Intelligence spatiale :
La capacité de percevoir des informations visuelles ou spatiales, de les modifier et de recréer des images visuelles sans référence aux objets, de construire des images 3D, de les déplacer et de les faire pivoter.

- intelligence personnelle :

La capacité de reconnaître et de faire des distinctions entre les sentiments, les croyances et les intentions des autres.

1.6.5 Composantes de l'intelligence

L'intelligence consiste à[24] :

- Raisonnement :

C'est l'ensemble des processus qui nous permettent de fournir une base de jugement, de prise de décision et de prédiction. Il existe en gros deux types :

- Raisonnement inductif.
- Raisonnement déductif.

- Apprentissage :

La capacité d'apprentissage est possédée par les humains, certaines espèces d'animaux et les systèmes activés par l'IA. L'apprentissage est classé comme suit :

- Apprentissage auditif.
- Apprentissage épisodique.
- Apprentissage moteur.
- L'apprentissage par observation.
- Apprentissage perceptif.
- Apprentissage relationnel.

- Résolution de problèmes :

C'est le processus dans lequel on perçoit et essaie d'arriver à une solution souhaitée à partir d'une situation actuelle en empruntant un chemin bloqué par des obstacles connus ou inconnus.

La résolution de problèmes comprend également la prise de décision, qui est le processus de sélection de l'alternative la plus appropriée parmi plusieurs alternatives pour atteindre l'objectif souhaité.

- Perception :

C'est le processus d'acquisition, d'interprétation, de sélection et d'organisation des informations sensorielles. Percevoir suppose sentir. Chez l'homme, la perception est facilitée par les organes sensoriels. Dans le domaine de l'IA, le mécanisme de perception rassemble les données acquises par les capteurs de manière significative.

— Intelligence linguistique :

C'est la capacité d'utiliser, de comprendre, de parler et d'écrire le langage verbal et écrit.

Il est important dans la communication interpersonnelle.

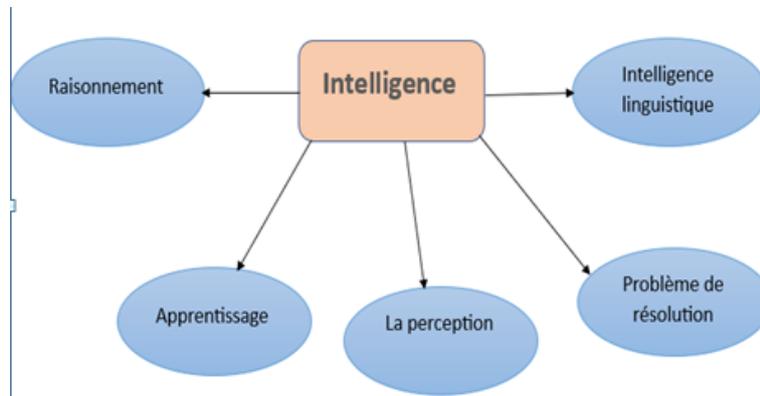


FIGURE 1.3 – composants de l'intelligence

1.6.6 domaines de l'intelligence artificielle

L'intelligence artificielle est un vaste domaine qui est utilisé pour trouver des solutions à divers problèmes. Parmi ses domaines les plus importants, nous voyons [24] :

- Apprentissage automatique (ML)
- Logique
- Recherche
- Réseaux de neurones artificiels
- Algorithme génétique
- Représentation des connaissances

1.6.7 Application de l'IA

Observations :

Les observations constituent la base des prévisions météorologiques et de la surveillance du climat. Les étapes typiques du traitement des observations météorologiques et climatiques sont la recherche d'informations, le contrôle de la qualité, la correction des biais et l'assimilation et/ou la fusion des données . En utilisant l'état de l'art, l'assimilation des données dans les modèles de prévision numérique du temps est coûteuse à la fois en termes d'effort de développement humain - afin de construire des opérateurs d'observation spécifiques pour chaque

type d'observation - et en termes de puissance de calcul - afin de résoudre en ligne les données. minimisation de la fonction de coût d'assimilation pour chaque pas de temps d'assimilation[25].

Prévision immédiate :

Pour de courtes plages de prévisions allant généralement jusqu'à 4 à 6 h dans le futur, l'extrapolation directe des observations, appelée prévision immédiate, est considérée comme plus précise qu'une prévision numérique du temps PNT . Pour la prévision immédiate par satellite, l'extrapolation des images satellitaires avec des méthodes de flux optique a fourni de meilleurs scores de compétence que les modèles PNT (Numerical Weather Prediction NWP), en particulier pour les phénomènes liés aux nuages, par exemple, le rayonnement de surface, les fortes précipitations et les orages. Un exemple d'application de la prévision immédiate d'orage est l'utilisation dans l'aviation pour éviter les situations météorologiques dangereuses[25].

Prévision par IA pure :

Contrairement à l'approche prévision numérique du temps (NWP) classique, où les observations sont assimilées à un modèle PNT basé sur une modélisation physique du comportement de l'atmosphère, il est possible de remplacer complètement le modèle PNT physique par un modèle basé sur l'IA purement basé sur les données sans aucune connaissances physiques a priori incluses, il a été démontré qu'un modèle de prévision purement IA peut avoir des performances comparables à un modèle de prévision numérique conventionnel, à condition que les modèles aient une résolution comparable. Un goulot d'étranglement pour le développement de prévisions purement basées sur l'IA à une résolution et des performances comparables aux prévisions PNT opérationnelles de pointe est la disponibilité de données de formation suffisantes. Les meilleurs résultats pratiques peuvent donc être attendus d'une combinaison de techniques de prévision numérique du temps et d'IA. Cela pourrait également faciliter l'acceptation de l'IA dans un domaine jusqu'ici dominé par la modélisation numérique (physique). un ensemble de données de référence pour l'évaluation de la prévision de l'IA pure a été fourni. La prévision par IA pure est un domaine de développement actif[25].

Prévisions hybrides IA prévision numérique du temps (NWP) :

Compte tenu de la limitation des données de formation disponibles, les meilleures performances de prévision peuvent être attendues d'une certaine forme de combinaison de techniques de prévision numérique du temps et d'IA. En août 2018, un défi de prévisions météorologiques par IA a été organisé pour la région, où les équipes en compétition ont été invitées à fournir en temps réel la meilleure température de l'air et l'humidité relative sur 36 h et la vitesse du vent à 10 m, sur la base de la sortie du modèle PNT. et les observations en surface de 10 stations météorologiques automatiques[25].

Post-traitement de la sortie prévision numérique du temps (NWP) :

Une façon courante d'améliorer la sortie des modèles PNT consiste à appliquer les statistiques de sortie du modèle Statistiques de sortie du modèle (Model Output Statistics MOS) pour corriger les erreurs systématiques des prévisions [25].

Combinaison multimodèle :

Les modèles de prévision numérique du temps sont développés et exploités de manière opérationnelle dans différents centres à travers le monde. La combinaison de plusieurs modèles peut être un moyen efficace de réduire l'incertitude des prévisions, comme le démontre l'utilisation de techniques de réseau neuronal pour les prévisions d'intensité des ouragans[25].

Réduction d'échelle :

L'exécution de modèles de prévision numérique du temps à haute résolution est coûteuse en termes de ressources informatiques. Les modèles de prévision numérique du temps qui permettent la convection à l'échelle mondiale sont actuellement aux limites de ce qui est possible avec les technologies conventionnelles de prévision numérique du temps. Une solution possible consiste à utiliser les technologies l'apprentissage profond (DL) pour réduire la portée des champs de vent sont donnés. Et aussi pour réduire la température[25].

Avertissements pour les conditions météorologiques à fort impact :

Malgré des efforts considérables pour faire progresser les météorologues dans la prévision numérique du temps, la prévision des phénomènes météorologiques extrêmes reste un défi. Des exemples d'utilisation de DL pour apprendre à partir des données comment prévoir des événements météorologiques de surface extrêmes en Amérique du Nord avec des échelles de temps allant de 1 à 5 jours sont également fournis[25].

Prévision saisonnière à infrasaisonnière :

Un aspect important du changement climatique est ce que l'on appelle l'amplification de l'Arctique (la température de l'Arctique augmente deux fois plus vite que la température mondiale), qui a des conséquences importantes sur le temps aux latitudes moyennes dans l'hémisphère nord. En particulier, une diminution du gradient de température entre l'équateur et le pôle Nord conduisant à un courant-jet plus faible et plus ondulant et à une incidence accrue d'embolie atmosphérique et de dessiccation structurelle aux latitudes moyennes, ce mécanisme s'est avéré mal représenté dans les conditions météorologiques conventionnelles. et les modèles climatiques et peuvent être mieux capturés par un système de prévision sous-saisonnier à saisonnier (S2S) basé sur l'apprentissage automatique[25].

Une méthode de prédiction par IA pure a également été introduite, qui est compétitive avec les derniers modèles de prévision numérique du temps aux temps S2S et qui est plus efficace en termes de temps de calcul.

Prévision décennale du climat :

CNN a été utilisé avec succès pour prédire habilement les événements El Niño Southern Oscillation (ENSO) avec des échelles de temps allant jusqu'à un an et demi et avec une bien meilleure compétence que les modèles de prédiction de physique dynamique. Un problème particulier avec la formation à la prévision décennale du climat est que la période d'observation disponible est trop courte pour réaliser une formation adéquate. Ce problème est résolu par l'utilisation de l'apprentissage par transfert. Premièrement, le CNN a déjà été testé sur des modèles de simulation ; Ensuite, la formation a été affinée en utilisant les retours d'expérience disponibles[25].

1.7 Système à base de connaissances

Un système basé sur la connaissance est développé pour le contrôle automatique d'un système d'alimentation dans l'état de rétablissement. L'heuristique de l'opérateur du système semble jouer un rôle central au cours de la restauration du système. On s'efforce donc de représenter ces heuristiques par un ensemble de connaissances dont le but est de rétablir l'alimentation sans surcharger aucune ligne de transmission. Alors que le contrôle de surcharge est un calcul numérique, le raisonnement dans le système basé sur la connaissance est un calcul symbolique. Une méthode pour lier ces deux différents types de calcul est proposée. Le système basé sur la connaissance est censé servir à la gestion d'un système d'alimentation à grande échelle dans l'état de restauration[26].

Il s'agit d'un système informatique développé pour résoudre des problèmes humains grâce à une combinaison d'intelligence artificielle et d'une base de données de connaissances spécifiques à un sujet. Les systèmes à base de connaissances sont basés sur les méthodes et les techniques de l'intelligence artificielle. Les composants de base des systèmes basés sur les connaissances sont la base de connaissances et les mécanismes d'inférence/inférence. Système à basé de connaissance (Knowledge Based System KBS), comme les systèmes de traitement des problèmes, travaille pour récupérer des informations[27].

1.8 System Expert SE

1.8.1 Définition

Les systèmes experts (Expert System ES) sont une sous-discipline de l'intelligence artificielle appliquée (IA), développée par la communauté de l'intelligence artificielle au milieu des années 1960. L'idée de base derrière l'ES est simplement que l'expertise, qui est un vaste ensemble de connaissances spécifiques à une tâche, est transférée de l'homme à l'ordinateur. Ces connaissances sont ensuite stockées dans l'ordinateur et les utilisateurs contactent l'ordinateur pour obtenir des conseils spécifiques au besoin. Un ordinateur peut faire des inférences et arriver à une conclusion définitive. Puis, en tant que conseiller humain, il donne des conseils et, si nécessaire, explique. ES fournit un moyen puissant et flexible d'obtenir des solutions à une variété de problèmes qui souvent ne peuvent pas être traités par d'autres. C'est pourquoi ils sont utilisés dans de nombreux secteurs de notre vie sociale et technologique, où leurs applications s'avèrent cruciales dans le processus d'aide à la décision et de résolution de problèmes[2].

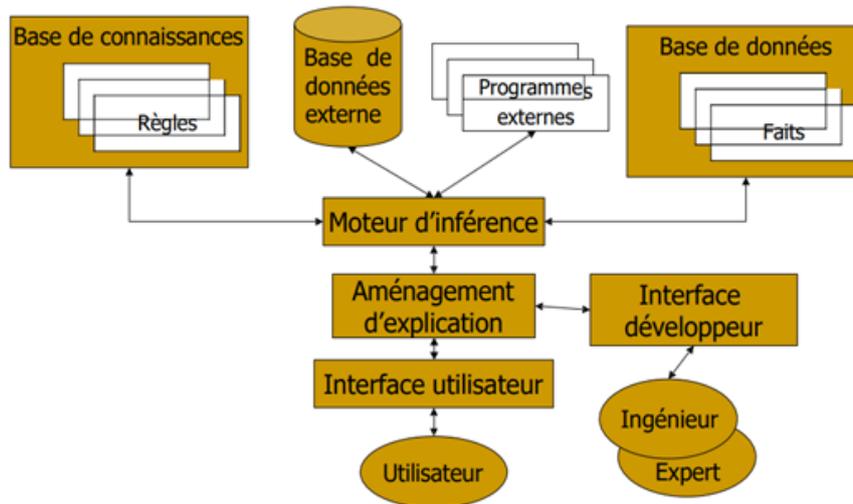


FIGURE 1.4 – La structure du système expert[5]

1.8.2 Classe les méthodologies ES[2]

- systèmes basés sur des règles,
- systèmes basés sur la connaissance,
- réseaux de neurones,
- applications environnementales floues,
- méthodologie orientée objet,
- inférence basée sur des cas (CBR),
- développement d'architecture de système
- systèmes d'agents intelligents
- la modélisation
- l'ontologie
- la méthodologie des bases de données ainsi que leurs applications dans divers domaines et problèmes de recherche.

1.8.3 les Objectifs de Système Expert et domaines d'utilisation

L'une des raisons d'appliquer le système expert est de fournir de meilleures solutions alternatives et d'aider les entreprises à relever les défis du marché mondial concurrentiel. En termes d'optimisation des activités de l'ensemble du processus de développement de produits, son espoir est d'éviter les pertes ou les sources de gaspillage de matériaux, de temps de production,

de main-d'œuvre, d'installations et d'installations investies par l'entreprise pour fabriquer un produit. De plus, la source de capital de l'entreprise peut être valorisée et ainsi réaliser un meilleur profit. La contribution du chercheur à ses revues, articles, documents de conférence et rédaction de thèse, ainsi que le domaine d'étude dans le système expert peuvent également être recherchés dans différents domaines d'étude. tels que l'ingénierie, la fabrication, la médecine, l'administration, l'armée, l'éducation et la prédiction météorologique [28].

1.9 Conclusion

Dans ce chapitre, nous avons appris l'importance des prévisions météorologiques dans tous les domaines de la vie, et nous avons également abordé les techniques anciennes les plus importantes utilisées en climatologie, car nous constatons que toutes ces techniques sont coûteuses et présentent des lacunes dans la précision de leurs résultats. En conséquence, nous devons rechercher des solutions utilisant de nouvelles technologies plus précises qu'auparavant.

CHAPITRE 2

APPROCHES BASÉES SUR L'APPRENTISSAGE AUTOMATIQUE

2.1 Introduction

Jusqu'à présent, nous n'avons vu dans le chapitre précédent que les prévisions météorologiques traditionnelles. Ces méthodes sont instables et ont tendance à se tromper dans leur recherche. De plus, on ne peut pas s'attendre à beaucoup de temps pour l'utiliser car il devient imprécis à ce moment-là. Ainsi, dans ce chapitre, nous examinons les techniques modernes les plus populaires de prévision météorologique (techniques d'apprentissage automatique et d'apprentissage en profondeur).

2.2 Définition de l'apprentissage automatique (Machine Learning ML)

L'apprentissage automatique (ML) est l'étude scientifique des algorithmes et des modèles statistiques que les systèmes informatiques utilisent pour effectuer une tâche spécifique sans être explicitement programmés. Algorithmes d'apprentissage dans de nombreuses applications que nous utilisons quotidiennement. Chaque fois qu'un moteur de recherche Web comme Google est utilisé pour effectuer des recherches sur Internet, l'une des raisons qui fonctionnent si bien est qu'un algorithme d'apprentissage a appris à classer les pages Web. Ces algorithmes sont utilisés à diverses fins telles que l'exploration de données, le traitement d'images, l'analyse prédictive, etc., pour n'en nommer que quelques-uns. Le principal avantage de l'utilisation de l'apprentissage automatique est qu'une fois qu'un algorithme a appris quoi faire avec les données, il peut faire son travail automatiquement.

Depuis leur évolution, les humains utilisent de nombreux types d'outils pour accomplir diverses tâches de manière plus simple. La créativité du cerveau humain a conduit à l'invention de différentes machines. Ces machines ont facilité la vie humaine en permettant aux gens de répondre à divers besoins de la vie, notamment les voyages, les industries et l'informatique. Et l'apprentissage automatique est l'un d'entre eux. L'apprentissage automatique (ML) est utilisé pour apprendre aux machines à gérer les données plus efficacement. Parfois, après avoir visualisé les données, nous ne pouvons pas interpréter les informations extraites des données. Dans ce cas, nous appliquons l'apprentissage automatique. Avec l'abondance d'ensembles de données disponibles, la demande d'apprentissage automatique est en augmentation. De nombreuses industries appliquent l'apprentissage automatique pour extraire des données pertinentes. Le but de l'apprentissage automatique est d'apprendre à partir des données. De nombreuses études ont été faites sur la façon de faire apprendre les machines par elles-mêmes sans être explicitement

programmées. De nombreux mathématiciens et programmeurs appliquent plusieurs approches pour trouver la solution à ce problème qui dispose d'énormes ensembles de données.

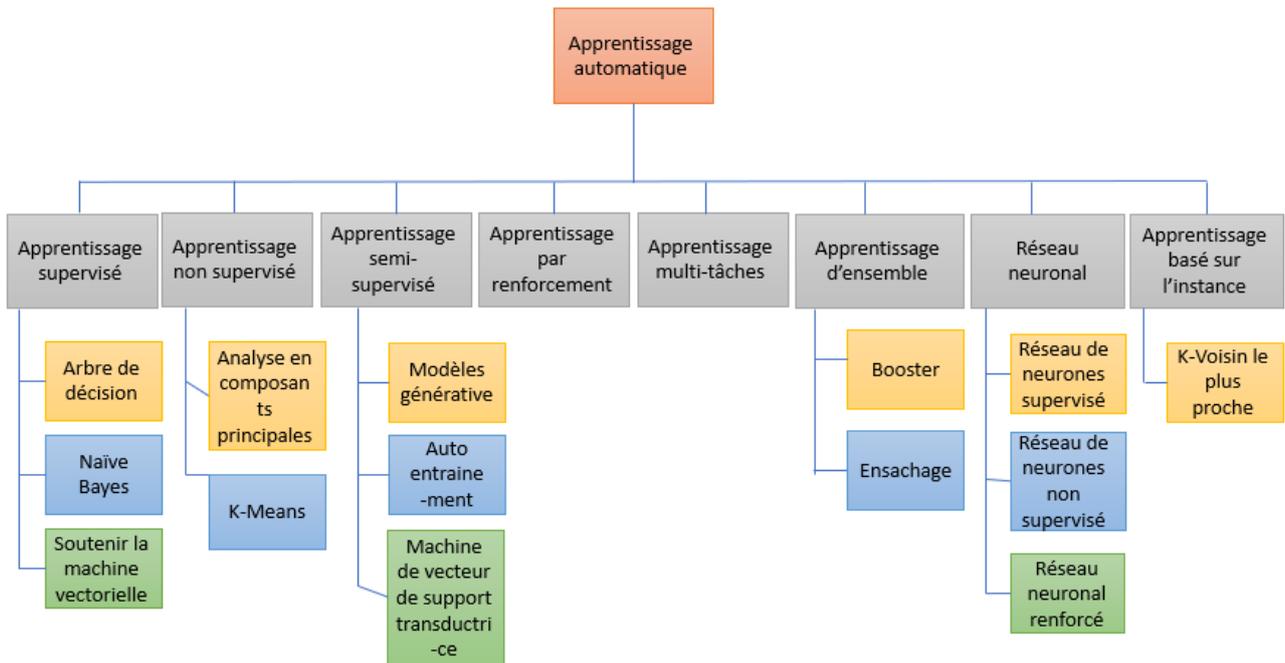


FIGURE 2.1 – niveaux d'apprentissage automatique

2.3 Algorithme d'apprentissage automatique

L'apprentissage automatique s'appuie sur différents algorithmes pour résoudre les problèmes de données. Les scientifiques des données aiment souligner qu'il n'y a pas un seul type d'algorithme unique qui soit le meilleur pour résoudre un problème. Le type d'algorithme utilisé dépend du type de problème que vous souhaitez résoudre, du nombre de variables, du type de modèle qui lui conviendrait le mieux, etc. Voici un bref aperçu de certains des algorithmes couramment utilisés dans l'apprentissage automatique (ML)[29] :

2.3.1 L'apprentissage supervisé (Supervised Learning SL)

L'apprentissage supervisé est la tâche d'apprentissage automatique consistant à apprendre une fonction qui mappe une entrée à une sortie en fonction d'exemples de paires entrée-sortie. Il déduit une fonction à partir de données d'apprentissage étiquetées consistant en un ensemble d'exemples d'apprentissage. Les algorithmes d'apprentissage automatique supervisé sont les algorithmes qui nécessitent une assistance externe.

L'ensemble de données d'entrée est divisé en ensemble de données d'apprentissage et de test.

L'ensemble de données de train a une variable de sortie qui doit être prédite ou classée. Tous les algorithmes apprennent une sorte de modèles à partir de l'ensemble de données d'apprentissage et les appliquent à l'ensemble de données de test pour la prédiction ou la classification. Le flux de travail des algorithmes d'apprentissage automatique supervisé est donné dans la figure ci-dessous.

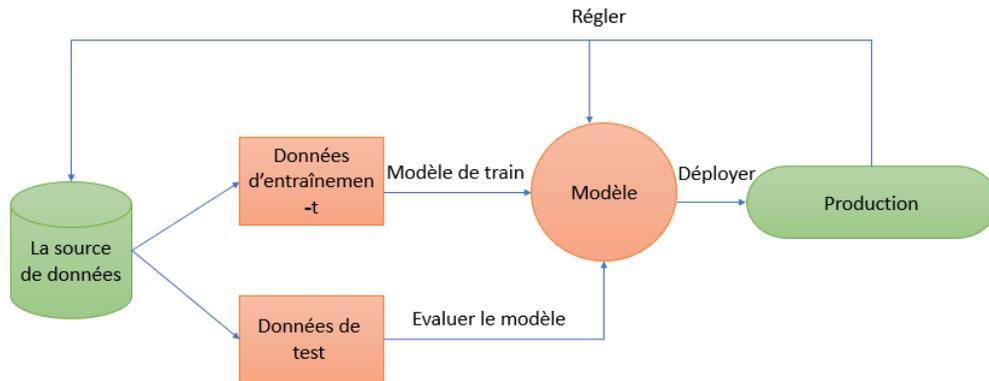


FIGURE 2.2 – Schéma montrant l'apprentissage supervisé

Les algorithmes d'apprentissage automatique supervisé les plus célèbres ont été discutés ici :

Arbre de décision

L'arbre de décision est un graphique pour représenter les choix et leurs résultats sous la forme d'un arbre. Les nœuds du graphique représentent un événement ou un choix et les bords du graphique représentent les règles ou conditions de décision. Chaque arbre se compose de nœuds et de branches. Chaque nœud représente les attributs dans un groupe qui doit être classé et chaque branche représente une valeur que le nœud peut prendre.

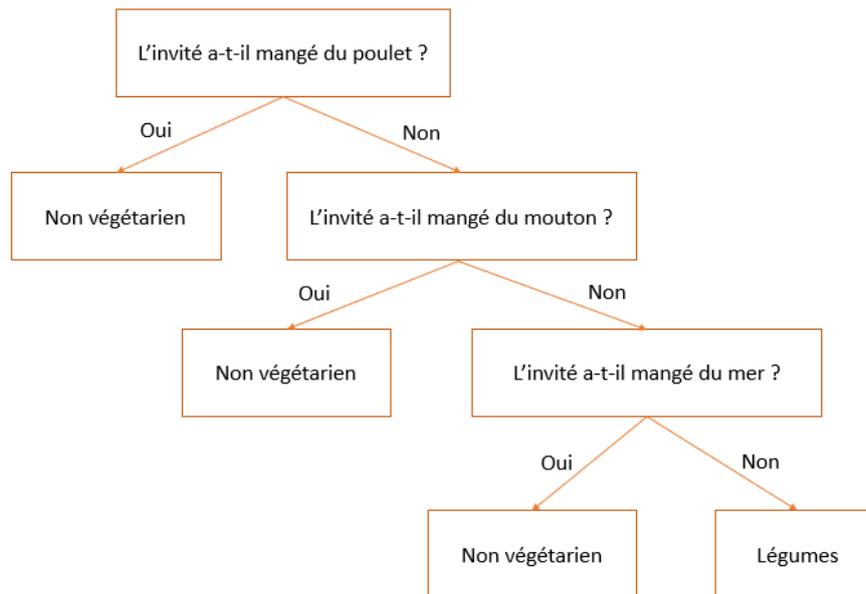


FIGURE 2.3 – Arbre de décision

Naive Bayes

Il s'agit d'une technique de classification basée sur le théorème de Bayes avec une hypothèse d'indépendance entre les prédicteurs. En termes simples, un classificateur Naive Bayes suppose que la présence d'une caractéristique particulière dans une classe n'est pas liée à la présence de toute autre caractéristique. Naive Bayes cible principalement l'industrie de la classification de textes. Il est principalement utilisé à des fins de regroupement et de classification en fonction de la probabilité conditionnelle de se produire.

Machine à vecteurs de support (Support Vector Machine SVM)

Est une approche traditionnelle d'apprentissage automatique qui peut encore aider à la catégorisation de grandes quantités de données. Est un algorithme d'apprentissage automatique supervisé utilisé pour la classification et/ou la régression. Il est plus couramment utilisé pour la classification, mais il peut également être très bénéfique pour la régression. SVM trouve essentiellement un hyper-plan qui définit une frontière entre les types de données. Cet hyperplan n'est rien d'autre qu'une ligne en deux dimensions.

2.3.2 Algorithme supervisé

Dans son sens le plus élémentaire, l'apprentissage automatique utilise des algorithmes logiciels qui apprennent et améliorent leurs opérations en analysant les données d'entrée pour faire des prédictions dans une plage acceptable. Au fur et à mesure que de nouvelles données sont introduites, ces algorithmes ont tendance à faire des prédictions plus précises. Bien qu'il existe certaines différences dans la façon dont les algorithmes d'apprentissage automatique sont regroupés, ils peuvent être divisés en trois catégories générales en fonction de leurs objectifs et de la manière dont la machine sous-jacente est enseignée.

Ces trois catégories sont : supervisé, non supervisé et semi-modéré.

Dans les algorithmes d'apprentissage automatique supervisé, un ensemble de données d'apprentissage étiqueté est d'abord utilisé pour entraîner le rythme de base de l'algorithme. Cet algorithme formé est ensuite transmis à l'ensemble de données de test non classifié pour les classer dans des groupes similaires.[30].

K-algorithme du plus proche voisin (K-nearest neighbors KNN)

K-algorithme du plus proche voisin (KNN) est un algorithme d'apprentissage paresseux non paramétrique et basé sur des instances qui est utilisé pour prédire la hiérarchie d'une nouvelle valeur d'apprentissage dans un ensemble de données où les valeurs de données sont séparées en quelques catégories. Étant donné que KNN stocke tous les états disponibles et nécessite d'examiner l'ensemble des données pour classer un nouveau point d'échantillonnage, la phase de formation minimale mais de test intensif de KNN se résume à la fois aux coûts de mémoire et de calcul.

KNN est une formation supervisée consistant en un ensemble de données spécifique qui contient des observations de formation (x, y) et veut représenter la corrélation entre x et y . L'objectif de KNN est de capturer une fonction $h : x \rightarrow y$ telle que si on lui donne une nouvelle valeur d'apprentissage x , $h(x)$ peut déterminer en toute confiance la sortie correspondante y . Dans la classification KNN, le nouveau point d'apprentissage est classé en fonction du plus grand nombre de votes de ses voisins, le point d'échantillonnage étant attribué au groupe le plus populaire parmi ses voisins les plus proches. Si $k = 1$, alors un nouveau point est affecté à son groupe le plus proche voisin. La figure suivante montre l'illustration de base de la classification KNN.[6]

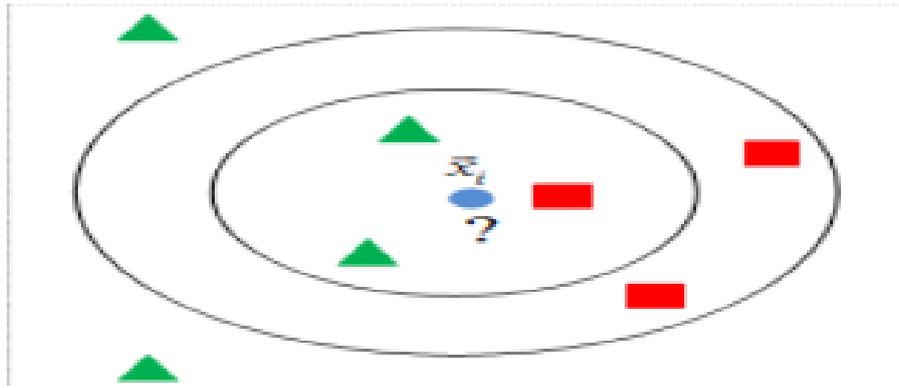


FIGURE 2.4 – L'illustration de base de la classification KNN.[6]

Si $k = 3$ l'échantillon d'essai (cercle bleu) est affecté au groupe du triangle vert et si $k = 5$ alors il est affecté au groupe du quadrilatère rouge.

Forêt aléatoire (**Random Forest RF**)

RF est une méthode d'apprentissage de groupe qui fonctionne en créant un grand nombre d'arbres de décision au fil du temps Le processus de formation (Breman 2001). Un arbre de décision est un modèle non paramétrique, décrit par un graphe arborescent, utilisé dans les tâches de classification et de régression. Dans un arbre de décision, la relation entre les caractéristiques et la variable cible est représentée par une série de conditions associées qui sont disposées dans une structure arborescente de haut en bas. Chaque condition de la forme $x_j > x_{j, th}$, où x_j est la valeur de la caractéristique à l'indice j , et $x_{j, th}$ est la limite inférieure, où la caractéristique et le seuil sont déterminés pendant le processus d'apprentissage. Pour décrire comment construire un tel arbre, nous considérons le cas d'une tâche de classification à deux classes. Le processus de formation commence avec l'ensemble de données de formation complet et un seul nœud d'arbre appelé la racine de l'arbre. L'algorithme recherche la "meilleure partition", qui est une combinaison d'une fonctionnalité et d'un seuil qui aboutit à la "meilleure" séparation entre les deux objets de classe[31].

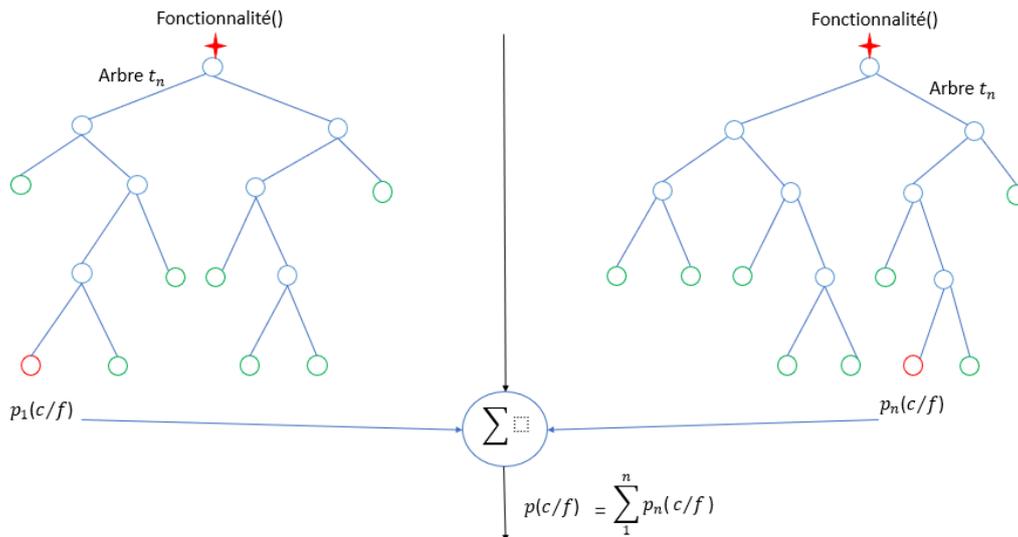


FIGURE 2.5 – Forêt aléatoire[7]

2.3.3 Apprentissage non supervisé

Ou des analyses d'apprentissage automatique non supervisées et des regroupements d'ensembles de données non étiquetés à l'aide d'algorithmes d'apprentissage automatique. Ces algorithmes trouvent des modèles et des données cachés sans aucune intervention humaine, c'est-à-dire que nous ne donnons pas de sortie à notre modèle. Le modèle de formation n'a que des valeurs de paramètre d'entrée et découvre les groupes ou les modèles par lui-même[24].

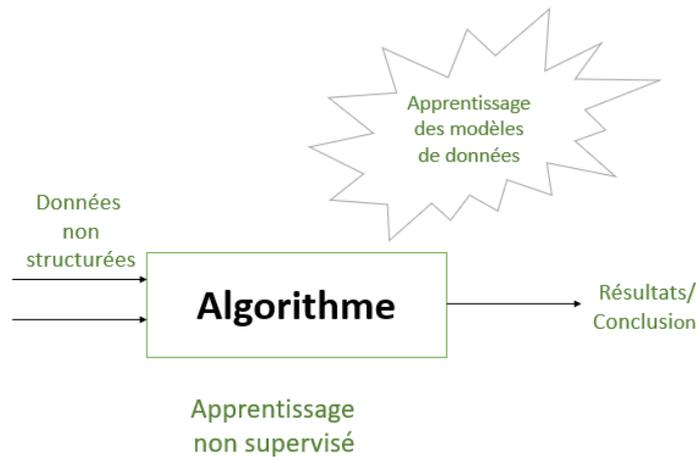


FIGURE 2.6 – Diagramme montrant l'apprentissage non supervisé

Les données d'entrée des modèles d'apprentissage non supervisé sont les suivantes :

- Données non structurées :
peuvent contenir des données bruyantes (insignifiantes), des valeurs manquantes ou des données inconnues.

— Données sans étiquette :

: les données ne contiennent qu'une valeur pour les paramètres d'entrée, il n'y a pas de valeur ciblée (sortie). Il est facile à collecter par rapport à celui étiqueté dans l'approche supervisée.

Types d'apprentissage non supervisé

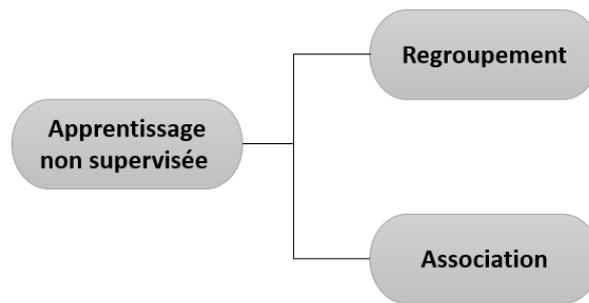


FIGURE 2.7 – Types d'apprentissage non supervisée

1. Regroupement (Clustering) :

De manière générale, cette technique est appliquée aux données de groupe en fonction de différents modèles, tels que des similitudes ou des différences, selon notre modèle de machine. Ces algorithmes sont utilisés pour traiter des objets de données bruts non classifiés en groupes[32].

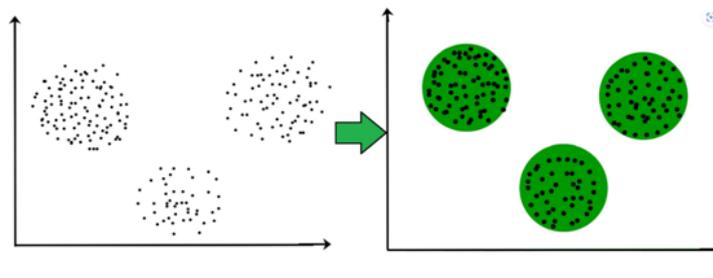


FIGURE 2.8 – Technique Regroupement

2. Association :

Cette technique est une technique de ML basée sur des règles qui découvre des relations très utiles entre les paramètres d'un grand ensemble de données. Cette technique est essentiellement utilisée pour l'analyse du panier de consommation qui aide à mieux comprendre la relation entre différents produits.

Quelques algorithmes :

- RSDAB (DBSCAN) :
Regroupement spatial basé sur la densité d'applications avec bruit.
- RIERH(BIRCH) :
Réduction itérative équilibrée et regroupement à l'aide de hiérarchies (Balanced iterative reduction and clustering using hierarchies).
- Classification hiérarchique.

2.4 Classification

Est une méthode d'apprentissage supervisé qui produit une ou plusieurs sorties catégorielles à partir de valeurs observées. De nombreuses applications d'IA nécessitent une classification, mais les applications de commerce électronique en bénéficient le plus[33].

2.5 Regression

La régression est une méthode statistique utilisée dans la finance, l'investissement et d'autres disciplines qui tente de déterminer la force et le caractère de la relation entre une variable dépendante(généralement désignée par Y) et une série d'autres variables (appelées variables indépendantes)[3].

2.5.1 Types de modèles de régression[3]

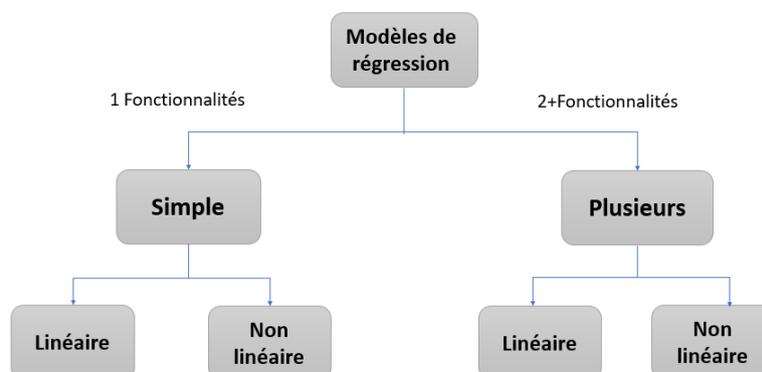


FIGURE 2.9 – Types de modèles de régression

Régression linéaire simple :

$$Y = a + bX + u$$

La régression linéaire multiple :

$$Y = a + b_1X_1 + b_2X_2 + b_3X_3 + \dots + b_tX_t + u$$

Y :La variable dépendante que vous essayez de prédire ou d'expliquer

X :La ou les variables explicatives (indépendantes) que vous utilisez pour prédire ou associer à Y

a :The y _intercept

b :(coefficient bêta) est la pente de la ou des variables explicatives

u :Le résidu de régression ou terme d'erreur

2.6 Techniques d'apprentissage automatique utilisées dans les prévisions météorologiques

Sûr parmi les technologies les plus utilisées sont :

2.6.1 Réseau neuronal

Les réseaux de neurones sont assez étonnants de par leur nature même, ils sont donc la façon la plus connue de penser aux équipements de prévision météorologique. La principale justification de cette notoriété est la capacité à reconnaître les conditions non linéaires des conditions atmosphériques passées et futures, contrairement aux modèles de systèmes linéaires et actifs[34].

2.6.2 Le réseau bayésien

Le réseau bayésien utilise des algorithmes d'apprentissage automatique pour déterminer le bon réseau bayésien et ses limites (température, adhérence, visibilité, etc.). Le calcul du réseau bayésien est coûteux en raison du grand nombre de conditions différentes[34].

2.6.3 la régression linéaire

Le premier algorithme utilisé est la régression linéaire, qui cherche à prédire les températures élevées et basses comme une combinaison linéaire de caractéristiques. Étant donné que la régression linéaire ne peut pas être utilisée avec les données de classification, cet algorithme n'a pas utilisé la classification météorologique pour chaque jour. En conséquence, seules huit caractéristiques ont été utilisées : température maximale, température minimale, humidité moyenne et pression barométrique moyenne pour chacun des deux derniers jours[22].

2.6.4 régression fonctionnelle

Le deuxième algorithme utilisé était une variété de régression fonctionnelle, qui recherche les modèles météorologiques historiques les plus similaires aux modèles météorologiques actuels, puis prédit le temps en fonction de ces modèles historiques[22].

2.7 L'apprentissage en profondeur (Deep Learning)

2.7.1 définition

L'apprentissage en profondeur est un domaine d'apprentissage automatique concerné par l'utilisation de réseaux de neurones artificiels (ANN) pour résoudre des tâches de vision par ordinateur telles que la classification d'images, la détection d'objets et l'estimation de pose. Diverses configurations d'ANN telles que les réseaux de neurones convolutifs (CNN), les réseaux de neurones récurrents (RNN), les réseaux de neurones profonds (DNN) peuvent extraire des caractéristiques de divers formats de données tels que du texte, des images, des vidéos, etc. Le Languagemodelingmot «profond» dans Deep Learning fait référence à plusieurs architectures de réseaux neuronaux en couches[3].

2.7.2 Réseau de neurones à convolution (CNN)

Définition

Un énorme intérêt pour l'apprentissage en profondeur a émergé ces dernières années. L'algorithme le mieux établi parmi les différents modèles d'apprentissage en profondeur est le réseau de neurones convolutifs (CNN), une classe de réseaux de neurones artificiels qui a été une méthode dominante dans les tâches de vision par ordinateur depuis que les résultats étonnants

ont été partagés dans un concours de reconnaissance d'objets connu comme concours de reconnaissance visuelle à grande échelle ImageNet (ILSVRC) en 2012[8].

Est un type de réseaux de neurones artificiels acycliques dans lequel le motif de connexion entre les neurones est inspiré par le cortex visuel des animaux, très utilisés dans le domaine de la vision par ordinateur. et ont aussi beaucoup de succès dans les reconnaissances faciales, la détection d'objets très utilisée dans les robots et les voitures automatiques. En gros, tout ce qui concerne la vision par ordinateur et les images.

De plus on peut utiliser les CNN dans tous les problèmes ayant en entrée une matrice. Par exemple, Gehring a utilisé une matrice de texte dans une tâche de traduction automatique de langue.

On note que le terme "convolutional" vient de l'opération de convolution de matrices utilisée dans le traitement de signal.

Deux nouveaux types de couche ont été ajoutés dans le réseau : la couche convolution (convolutional layer) et la couche de mise en commun (pool layer).[9]

Architecture

Au cours des dix dernières années, de nombreuses structures CNN ont été mises en place. L'architecture du modèle est un facteur critique dans l'optimisation des performances de diverses applications. Diverses modifications ont été apportées à l'architecture CNN de 1989 à aujourd'hui. Ces modifications comprennent des retouches structurelles, des régularisations, des améliorations de paramètres, etc. Au contraire, il convient de noter que la principale amélioration des performances de CNN est due en grande partie à la réorganisation de l'unité de traitement, ainsi qu'au développement de nouveaux blocs. En particulier, la plupart des nouveaux développements dans les architectures CNN ont été réalisés sur l'utilisation de la profondeur du réseau[35].

CNN se concentre principalement sur la prémisse que l'entrée sera des images. Cela se concentre sur l'architecture qui sera configurée de manière à répondre au besoin de gérer un type particulier de données.

Une différence majeure est que les neurones en couches d'un CNN sont composés de neurones organisés en trois dimensions, la dimension spatiale d'entrée (hauteur et largeur) et la profondeur. La profondeur ne fait pas référence au nombre total de couches dans l'ANN, mais à la troisième dimension du volume d'activation. Contrairement à l'ANNS standard, les neurones

d'une couche donnée ne communiqueront qu'avec une petite région de la couche qui la précède.

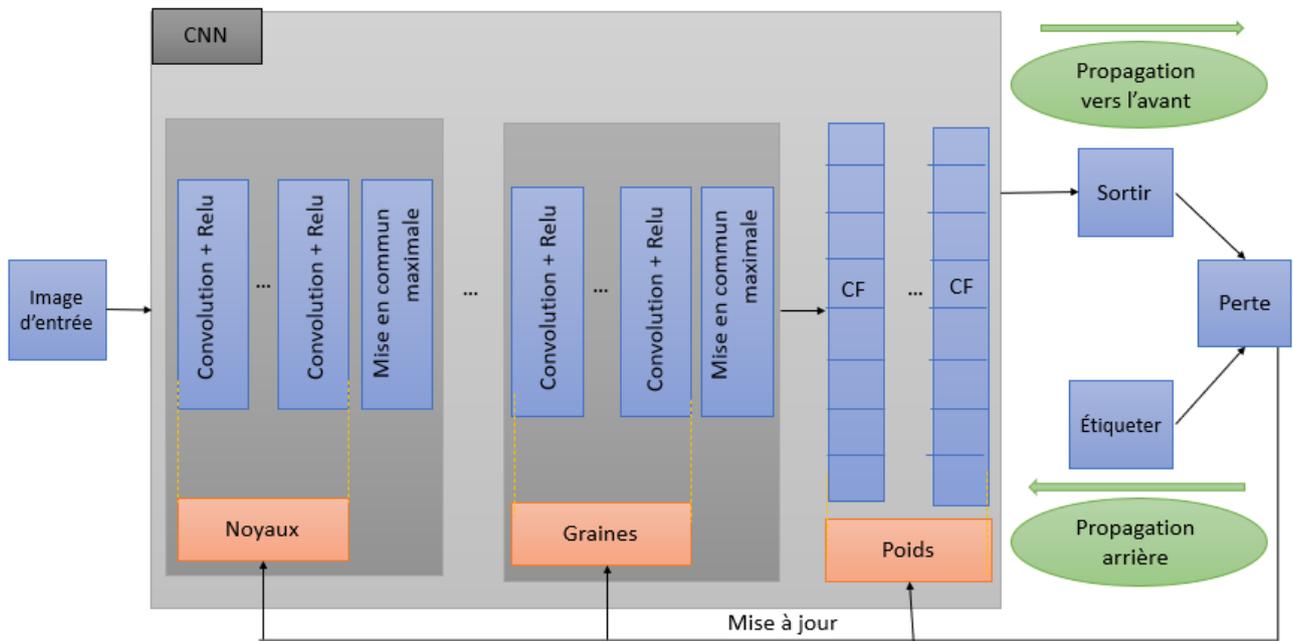


FIGURE 2.10 – Présentation du réseau de neurones convolutifs (CNN) Formation architecture et process. [8]

Un CNN se compose d'une pile de plusieurs blocs de construction : couches de convolution, couches de mise en commun (par exemple, mise en commun maximale) et couches entièrement connectées (Fully Connected Layers FCL). Sous le modèle de noyau donné, les performances et les poids sont calculés à l'aide de la fonction de perte. Parmi les types de structures CNN[36] :

1. LeNet :

LeNet est l'un des plus anciens CNN qui était principalement utilisé pour la reconnaissance des numéros. Ceci est toujours considéré comme l'un des travaux les plus importants dans le domaine de la reconnaissance des nombres. C'est cette architecture publiée en 1998 qui a initié le développement de CNN et plus tard de Deep CNN pour la reconnaissance des numéros basée sur la base de données MNIST. L'architecture générale de ce réseau consiste à appliquer une convolution (5×5) en entrée et une moyenne ultérieure (2×2) avec un pas de 2 qui se répète deux fois et se termine finalement par deux couches entièrement connectées. L'entrée de fin fournie pour le FCN est $120 \times 1 \times 1$. Le nombre de paramètres pris en compte est d'environ 60 000.

2. Alex Net :

Cette architecture a été publiée en 2012 et a été parmi les premiers CNN à remporter le 2012 ILSVRC (ImageNet Large Scale Visual Recognition Challenge). L'entrée soumise était d'environ 15 millions de données d'image RVB avec des dimensions de $3 \times 224 \times 224$ (qui ont ensuite été corrigées en 227×227) à partir d'environ 22 000 catégories. La structure de ce réseau est similaire à celle de LeNet sauf qu'il est plus profond.

Les processus consistent en 11×11 , 5×5 , 3×3 convolutions, une agrégation maximale de 3×3 se terminant par deux couches entièrement connectées de 4096 couches chacune.

3. VGG(16) Net (Visual Geometry Group) :

VGG signifie Engineering Optics Group. Ce réseau particulier a été présenté au défi ILSVRC 2014 où, bien qu'il ait été finaliste, il a été largement accepté et apprécié. La conception était similaire à celle d'AlexNet, ce qui signifie également que VGG Net possède également un grand nombre de fonctionnalités. Ce réseau contient environ 138 millions de paramètres. Il y a un total de 16 couches convolutives dans VGG 16, réparties sur 3 blocs contenant 2 couches de convolutions 3×3 suivies d'un maximum de regroupement 2×2 et 2 blocs contenant 3 couches de convolutions 3×3 suivies d'un maximum de regroupement 2×2 . L'architecture est complétée par deux couches entièrement connectées de 4096 couches cachées chacune.

4. GoogleNet :

GoogLeNet a également suivi le modèle de bloc et chaque bloc est appelé Inception Module. GoogLeNet utilise un total de 9 modules de démarrage. Cette architecture a remporté l'ILSVRC 2014. Ce réseau est profond de 22 couches mais compensé par un ratio relativement plus faible. de paramètres est d'environ 5 millions par rapport aux 138 millions de paramètres du deuxième VGG. Chaque couche a plusieurs tailles de filtre (1×1 , 3×3 , 5×5) et le filtre à mettre à jour est déterminé par backprop. Chaque unité dispose également d'une couche de mise en commun maximale de 3×3 . Chaque couche de convolution était précédée d'une couche de goulot d'étranglement de convolution 1×1 afin de réduire la profondeur de la carte des caractéristiques.

5. Microsoft ResNet :

ResNet ou Deep Residual Network a remporté le défi ImageNet 2015, dépassant pour la première fois l'erreur de précision humaine avec un taux d'erreur d'environ 3,6 %. Le réseau est très profond et le réseau présenté au défi avait 152 couches de profondeur. Il a été observé qu'à mesure que la profondeur de la grille augmente, la précision devient saturée puis se détériore rapidement, non seulement avec une équipe de grille plus profonde a

également dû résoudre le problème du gradient de fuite. Afin de contrer cela, ResNet a introduit la fonction de saut de connexion.

Afin de calculer, l'entrée et la sortie sont copiées dans la couche suivante, principalement pour apprendre le reste du calcul précédent. Le nombre de paramètres calculés était d'environ 65 millions. Certaines couches ont également un goulot d'étranglement qui commence et se termine par une convolution 1×1 . La normalisation par lots a été utilisée après chaque convolution.

Les couches CNN

L'architecture CNN se compose de plusieurs couches pour réduire les besoins de traitement :

— Couche de convolution (CONV) :

La couche de convolution est la couche la plus basique mais aussi la plus importante dans un CNN. Il concatène ou multiplie essentiellement la matrice de pixels générée de l'image ou de l'objet sélectionné pour produire une carte d'activation de l'image sélectionnée.

Le principal avantage d'une carte d'activation est qu'elle stocke toutes les caractéristiques distinctives d'une image donnée tout en réduisant la quantité de données à traiter[36].

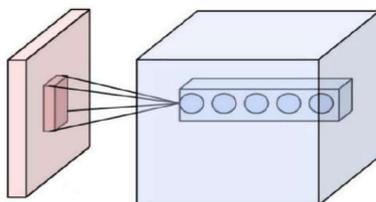


FIGURE 2.11 – Ensemble de convolution (bleu). Ils sont liés à un même champ récepteur (rouge)[9]

— Couche de regroupement (Pooling POOL) :

La tâche principale de la couche de regroupement(pooling) est de sous-échantillonner les cartes d'entités. Ces cartes sont générées en suivant des opérations convolutives. En d'autres termes, cette approche réduit les cartes d'entités à grande échelle pour créer des cartes d'entités plus petites.

En même temps, il conserve la majorité des informations (ou caractéristiques) prévalant à chaque étape de la phase de compilation. D'une manière similaire au processus convolutif, la taille à la fois de la foulée et du noyau est initialement allouée avant que

l'opération de compilation ne soit effectuée. Plusieurs types de méthodes de regroupement sont disponibles pour une utilisation dans différentes couches de regroupement. Ces méthodes incluent le regroupement arborescent, le regroupement de porte, le clustering moyen, le regroupement minimum, le regroupement maximum, le regroupement moyen global (GAP) et le regroupement maximum global. Les méthodes de regroupement les plus courantes et les plus fréquemment utilisées sont les regroupements max, min et GAP.[35]

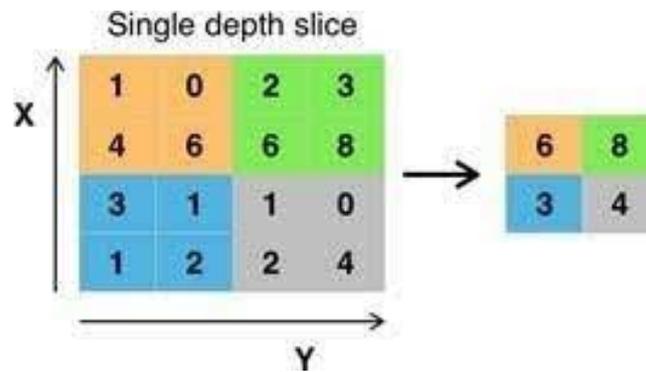


FIGURE 2.12 – regroupement avec un filtre 2x2 et un pas de 2 [10]

— Couches de correction (RELU) :

La couche ReLU est utilisée pour implémenter un élément de fonction d'activation qui convertit toutes les valeurs négatives en zéro, de sorte que le seuil est converti en zéro. Cela n'affecte pas la taille ou les paramètres excessifs.[36]

— Couche entièrement connectée (FC) :

cette couche est généralement située à la fin de toutes les structures CNN. Au sein de cette couche, chaque neurone est connecté à tous les neurones de la couche précédente, l'approche dite de connexion complète (FC). Il est utilisé comme une classe CNN. Il suit la méthode de base du réseau neuronal cognitif multicouche traditionnel, car il s'agit d'une sorte de réseau neuronal artificiel. L'entrée dans la couche FC provient de la dernière couche de regroupement ou de convolution. Cette entrée est sous forme vectorielle, générée à partir de cartes d'entités du cachet de la poste.[35]

Exemple CNN (Une analyse des réseaux de neurones convolutifs pour la classification d'images)[11]

— Couche d'entrée : la première couche de chaque CNN utilisé est la « couche d'entrée » qui capture et redimensionne les images pour les transmettre à des couches supplémentaires pour l'extraction de caractéristiques.

- Couche de convolution (conv) : les quelques couches suivantes sont des "couches de convolution" qui agissent comme des filtres d'image, détectant ainsi les caractéristiques des images et les utilisant également pour calculer les points caractéristiques correspondants pendant les tests.
- Couche de regroupement (pool) : les ensembles de fonctionnalités extraits sont ensuite transmis à la couche de regroupement. Cette couche prend de grandes images et les réduit tout en conservant les informations les plus importantes.
- Couche d'unité linéaire corrigée(ReLU) : La prochaine « unité linéaire corrigée » ou couche ReLU remplace chaque nombre négatif de la couche de mise en commun par un 0. Cela aide le CNN à rester mathématiquement stable en empêchant les valeurs acquises de rester bloquées près de zéro ou d'exploser vers l'infini.
- Couche entièrement connectée(FC) : la couche finale est constituée des couches entièrement connectées qui prennent les images filtrées de haut niveau et les traduisent en classes avec des étiquettes.

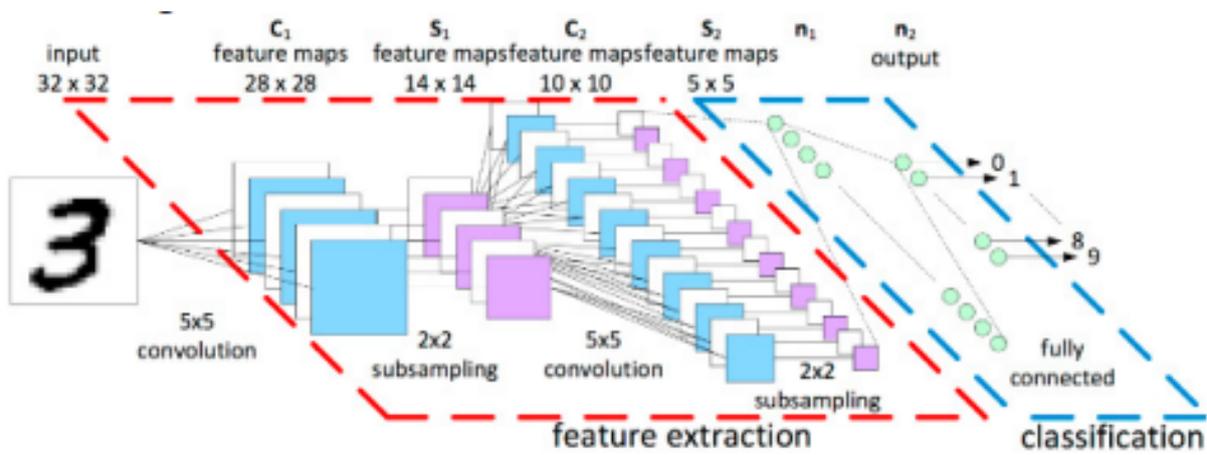


FIGURE 2.13 – exemple CNN [11]

2.7.3 Machines Boltzmann à restriction conditionnelle (Conditionally Restricted Boltzmann Machines CRBM)

Les machines Boltzmann contraintes sont des modèles d'apprentissage en profondeur pour résoudre différents problèmes, par exemple, le filtrage collaboratif, la classification et la modélisation des problèmes de données de capture de mouvement[34].

2.7.4 Applications de l'apprentissage en profondeur

L'apprentissage en profondeur a plusieurs applications, et de nombreuses technologies étonnantes intègrent désormais l'apprentissage en profondeur pour augmenter les performances des tâches. Voici quelques exemples[37] :

- Parole et audio (Speech and audio).
- Image, video, and multimodality.
- Language de modèle (language modeling).
- Natural language processing.
- Information retrieval.

2.7.5 Apprentissage par transfert

-Qu'est-ce que l'apprentissage par transfert ?

L'apprentissage par transfert est l'amélioration de l'apprentissage d'une nouvelle tâche en transférant les connaissances d'une tâche connexe qui a déjà été apprise. Alors que la plupart des algorithmes d'apprentissage automatique sont conçus pour s'attaquer à des tâches uniques, le développement d'algorithmes qui facilitent l'apprentissage par transfert est un sujet d'intérêt constant dans la communauté de l'apprentissage automatique[38].

L'apprentissage par transfert signifie prendre les parties pertinentes d'un modèle d'apprentissage automatique pré-formé et l'appliquer à un problème nouveau mais similaire. Ce seront généralement les informations de base pour que le modèle fonctionne, avec de nouveaux aspects ajoutés au modèle pour résoudre une tâche spécifique. Les programmeurs devront identifier les zones du modèle qui sont pertinentes pour la nouvelle tâche, et quelles parties devront être recyclées. Par exemple, le nouveau modèle peut conserver les opérations qui permettent à la machine de sélectionner des objets ou des données, mais recycler le modèle pour sélectionner un objet spécifique différent.

-A quoi sert l'apprentissage par transfert ?

L'apprentissage par transfert est généralement utilisé :

* Pour gagner du temps et des ressources en évitant d'avoir à former plusieurs modèles d'apprentissage automatique à partir de zéro pour effectuer des tâches similaires.

* En tant que gain d'efficacité dans les domaines de l'apprentissage automatique qui nécessitent de grandes quantités de ressources telles que la catégorisation d'images ou le traitement

du langage naturel.

* Pour nier un manque de données de formation étiquetées détenues par une organisation, en utilisant des modèles pré-formés[39].

- Comment fonctionne l'apprentissage par transfert ?

Il existe deux manières souvent utilisées :

1. Développer une approche modèle
2. Approche de modèle pré-formé : À cet égard, nous nous intéresserons uniquement à l'approche du modèle pré-entraîné car il est largement utilisé dans le domaine de l'apprentissage en profondeur.

-Défis et opportunités pour l'apprentissage en profondeur[40] :

*Taille de données

*Qualité des données

*Temporalité

*Complexité du domaine

*Interprétabilité

Tous ces défis présentent une gamme d'opportunités et de possibilités de recherche futures pour améliorer le domaine. et c'est à travers :

*Enrichissement des fonctionnalités

*Modèle de confidentialité

*Intégrer des connaissances spécialisées

*Modélisation temporelle

*Modélisation interprétable

2.8 Techniques d'apprentissage en profondeur pour les prévisions météorologiques

2.8.1 Réseaux de neurones récurrents(RNN)

Les réseaux de neurones récurrents (RNN) sont l'une des architectures d'apprentissage profond supervisé les plus avancées et sont principalement utilisés avec des séries temporelles. Dans cette architecture, les couches cachées sont interconnectées dans le temps et peuvent alors

conserver en mémoire les états des couches précédentes. Les connexions récurrentes ajoutent de l'état ou de la mémoire au réseau et lui permettent d'apprendre et d'exploiter la nature ordonnée des observations dans les séquences d'entrée. Cependant, avec de longues séquences de données, les modèles sont parfois confrontés au problème de la disparition ou de l'explosion du gradient. Ainsi, le réseau n'est pas en mesure de bien fonctionner. Pour résoudre le problème du gradient de fuite, un type spécial de RNN, le réseau Longue mémoire à court terme (Long Short-Term Memory LSTM) a été introduit. Depuis, de nombreuses améliorations ont été apportées par les chercheurs et c'est maintenant l'architecture la plus populaire utilisée pour les problèmes de prédiction[12].

- Un réseau neuronal récurrent (RNN) est un modèle de séquence neuronale qui atteint une performance de pointe dans des tâches importantes telles que la modélisation du langage, la reconnaissance vocale et la traduction automatique. Il est bien connu que les applications réussies des réseaux de neurones nécessitent une bonne organisation. Malheureusement, le décrochage, la méthode de régularisation la plus puissante pour les réseaux de neurones à anticipation, ne fonctionne pas bien avec les RNN. En conséquence, les applications pratiques des RNN utilisent souvent de très petits modèles, car les grands RNN ont tendance à être suréquipés. Les méthodes de régularisation existantes fournissent des améliorations relativement faibles pour les RNN. Le décrochage, lorsqu'il est utilisé correctement, réduit considérablement le surajustement dans les LSTM, évalué sur trois problèmes différents...[41]

2.8.2 Mémoire à long et court terme (LSTM Networks)

Les réseaux LSTM sont une variante particulière de RNN. Dans cette architecture, il y a quatre couches qui interagissent d'une manière particulière[12] :

- la porte d'information.
- la porte d'oubli.
- la porte d'entrée.
- la porte de sortie.

La figure (2.14) montre la configuration d'un simple bloc de mémoire LSTM. Notez que dans les configurations réelles, il peut avoir plus de portes.

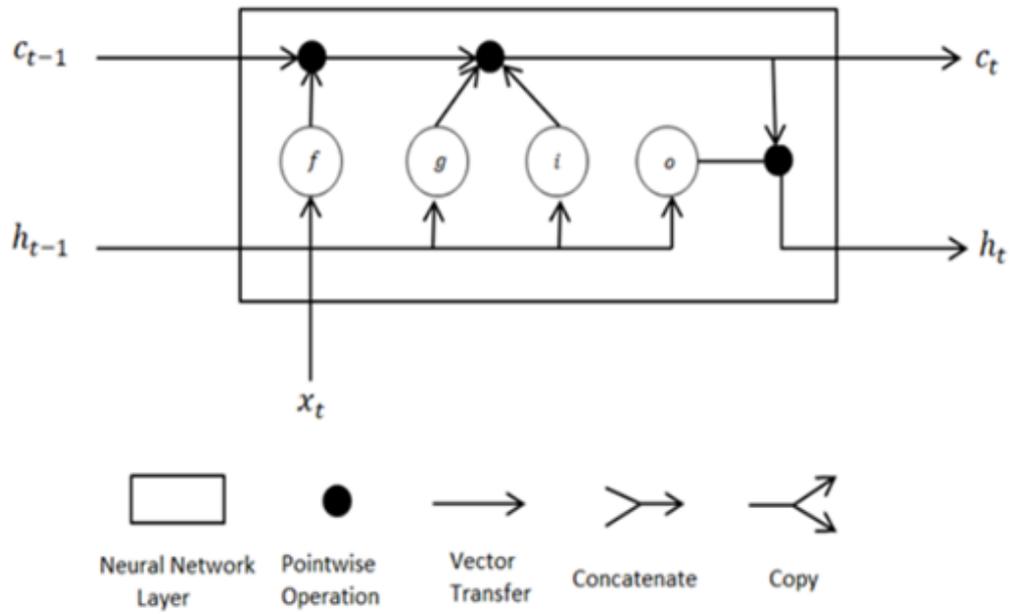


FIGURE 2.14 – Une simple mémoire de blocs LSTM [12]

2.9 Les travaux

Le tableau ci-dessous présente certains des travaux antérieurs qui utilisaient l'apprentissage automatique et l'apprentissage en profondeur dans le domaine des prévisions météorologiques, accompagnés d'une explication simple de chaque méthode.

Reference	Méthode	résumé
[22]	Apprentissage automatique (la régression linéaire)	Il fonctionne pour prédire les températures élevées et basses comme un ensemble linéaire de caractéristiques, seules huit caractéristiques ont été utilisées car la régression linéaire ne peut pas être utilisée avec les données de classification.
[42]	Apprentissage en profondeur (DLWP)	Il prédit de manière réursive six variables atmosphériques majeures avec une résolution temporelle de six heures. Ce puissant modèle de calcul utilise des réseaux de neurones convolutifs (CNN) sur un réseau sphérique cubique pour produire des prédictions globales.

Reference	Méthode	résumé
[43]	Réseaux de neurones récurrents (RNN) (Les réseaux Elman)	Un réseau neuronal récurrent (RNN) est un réseau neuronal artificiel (NN) utilisé pour la prédiction de séries temporelles. Les réseaux Elman sont une classe de RNN composée d'une ou plusieurs couches cachées. Ce réseau est généralement la fonction d'activation du pôle sigmoïde de la couche cachée et la fonction linéaire (borylène) de la couche résultante.

TABLE 2.1 – Travaux antérieurs sur les techniques de prévision météorologique

2.10 Conclusion

Différentes méthodes basées sur l'apprentissage en profondeur et l'apprentissage automatique apportent des améliorations par rapport aux solutions traditionnelles, mais il n'y a pas de découverte parfaite, car il s'agit d'un domaine de recherche où les chercheurs proposent toujours de nouveaux modèles et méthodes afin d'obtenir de meilleurs résultats.

Dans cette recherche, nous avons choisi le modèle Lstm, qui est une variante des réseaux de neurones récurrents (RNN) dans le domaine de l'apprentissage profond, pour être utilisé et étudié dans le chapitre suivant.

CHAPITRE 3

MÉTHODOLOGIE DE PRÉVISION MÉTÉOROLOGIQUE

3.1 Introduction

Il existe plusieurs techniques qui ont été utilisées pour prédire le temps, toutes visant à améliorer la précision des prévisions. Dans ce chapitre, nous discuterons de la méthode que nous avons utilisée et approfondirons la description de la structure de base du modèle, en fournissant davantage de détails.

3.2 données temporelles

Les séries chronologiques sont une classe importante d'objets de données temporelles et peuvent être facilement obtenues à partir d'applications scientifiques et financières. Une série chronologique est un ensemble d'observations faites dans l'ordre chronologique. La nature des données de séries chronologiques comprend : un grand volume de données, des dimensions élevées et nécessaire pour une mise à jour continue. De plus, les données de séries chronologiques, qui sont à la fois de nature numérique et continue, sont toujours considérées comme un tout plutôt que comme un champ numérique individuel. L'utilisation croissante des données de séries chronologiques a déclenché de nombreuses recherches et développements dans le domaine de l'exploration de données.^[44]

3.3 RNNs(Les réseaux de neurones récurrents)

3.3.1 Définition

Les réseaux de neurones récurrents ne sont pas les seuls modèles capables de représenter les dépendances temporelles. Les chaînes de Markov, qui modélisent les transitions entre les états dans une séquence observée, ont été décrites pour la première fois par le mathématicien Andrey Markov en 1906. Les modèles de Markov cachés (Hidden Markov Models HMM), qui modélisent une séquence observée comme dépendant de manière probabiliste d'une séquence d'états non observés, ont été décrits dans les années 1950 et ont été largement étudiés depuis les années 1960 [Stratonovich, 1960]. Cependant, les approches traditionnelles des modèles de Markov sont limitées car leurs états doivent être tirés d'un espace d'états discrets S de taille modeste.

Les réseaux de neurones récurrents (RNN) sont des modèles connexionnistes qui capturent la dynamique des séquences via des cycles dans le réseau de nœuds. Contrairement aux réseaux de neurones à anticipation standard, les réseaux récurrents conservent un état qui peut représenter

des informations à partir d'une fenêtre de contexte arbitrairement longue[45].

3.3.2 Architectures de réseaux de neurones récurrentes

Les architectures vont des réseaux entièrement interconnectés (figure 3.1) aux réseaux partiellement connectés (figure 3.2), y compris les réseaux multicouches à anticipation avec des couches d'entrée et de sortie distinctes. Les réseaux entièrement connectés n'ont pas de couches d'entrée distinctes de nœuds, et chaque nœud a une entrée de tous les autres nœuds. Une rétroaction vers le nœud lui-même est possible [46].

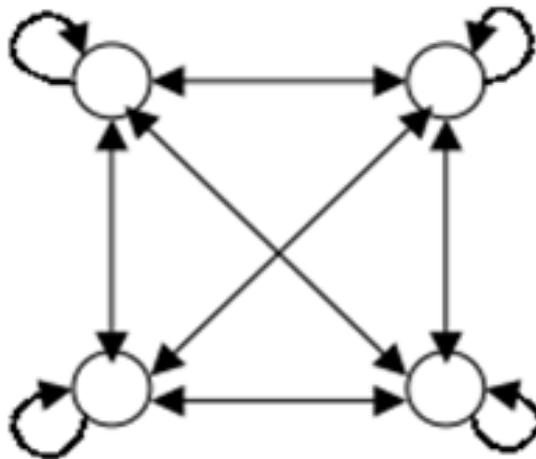


FIGURE 3.1 – Un exemple de réseau neuronal récurrent entièrement connecté.

Des réseaux neuronaux simples partiellement récurrents (figure 3.2) ont été utilisés pour apprendre des chaînes de caractères. Bien que certains nœuds fassent partie d'une structure d'anticipation,

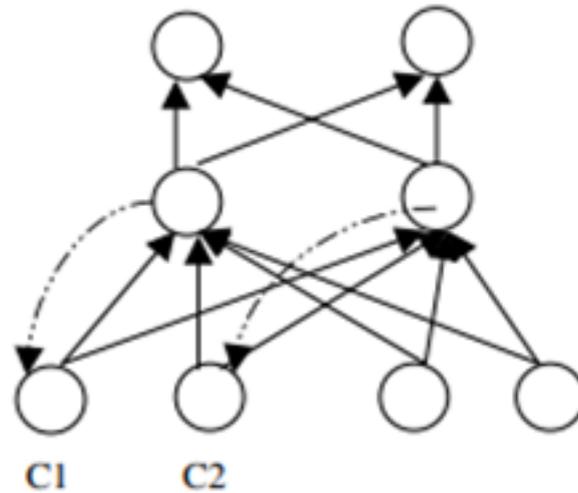


FIGURE 3.2 – Un exemple de réseau récurrent simple.

d'autres nœuds fournissent le contexte séquentiel et reçoivent des commentaires d'autres nœuds. Les poids des unités de contexte (C1 et C2) sont traités comme ceux des unités d'entrée, par exemple en utilisant la rétropropagation. Les unités de contexte reçoivent une rétroaction temporisée depuis, dans le cas de la figure (3.2), les unités de seconde couche. Les données de formation se composent d'entrées et de leurs sorties successives souhaitées. Le réseau peut être entraîné à prédire la lettre suivante dans une chaîne de caractères et à valider une chaîne de caractères.

Deux méthodes fondamentales peuvent être utilisées pour ajouter une rétroaction dans les réseaux de neurones multicouches à anticipation. retour de la couche masquée à la partie contexte de la couche d'entrée. Cette approche accorde plus d'attention à la séquence des valeurs d'entrée et au retour de la couche de sortie vers les nœuds de contexte de la couche d'entrée et met davantage l'accent sur la séquence des valeurs de sortie[46].

3.3.3 Les RNN sont-ils trop expressifs ?

Premièrement, étant donné toute architecture fixe (ensemble de nœuds, d'arêtes et de fonctions d'activation), les réseaux de neurones récurrents avec cette architecture sont différentiables de bout en bout. La dérivée de la fonction de perte peut être calculée par rapport à chacun des paramètres (pondérations) du modèle. Ainsi, les RNN se prêtent à une formation basée sur le gradient. Deuxièmement, alors que l'exhaustivité de Turing des RNN est une propriété impressionnante, étant donné un RNN de taille fixe avec une architecture spécifique, il n'est en fait pas possible de reproduire un programme arbitraire. De plus, contrairement à un programme composé en C, un réseau neuronal récurrent peut être régularisé via des techniques standard

qui aident à prévenir le surajustement, comme la perte de poids, le décrochage et la limitation des degrés de liberté.[45]

3.4 LSTM(Mémoire à long et court terme)

3.4.1 Définition

Le modèle LSTM est un puissant système neuronal récurrent spécialement conçu pour surmonter les problèmes de gradient explosif/évanescent qui surviennent généralement lors de l'apprentissage de dépendances à long terme, même lorsque les intervalles de temps minimaux sont très longs. En général, cela peut être évité en utilisant un circuit d'erreur constante (CEC), qui maintient le signal d'erreur dans chaque cellule unitaire.

En fait, ces cellules sont elles-mêmes des réseaux récurrents, avec une structure intéressante dans la façon dont le CEC est étendu avec des fonctionnalités supplémentaires, à savoir la porte d'entrée et la porte de sortie, formant la cellule mémoire.

Les connexions auto-répétitives font référence à une rétroaction avec un décalage d'une étape. Le module vanilla LSTM se compose d'une cellule, d'une porte d'entrée, d'une porte de sortie et d'une porte d'oubli. Cette porte d'oubli ne faisait pas initialement partie du réseau LSTM, mais a été proposée par Gers et al. Permet au réseau de réinitialiser son état. La cellule mémorise les valeurs à des intervalles de temps aléatoires et les trois portes régulent le flux d'informations associées à la cellule.

En bref, l'architecture LSTM consiste en un ensemble de sous-réseaux fréquemment connectés, appelés blocs de mémoire. L'idée derrière un bloc de mémoire est de maintenir son état dans le temps et de réguler le flux d'informations avec des unités fermées non linéaires. La figure(3.3) présente l'architecture d'un cluster LSTM vanilla, qui comprend des portes, un signal d'entrée $x(t)$, un signal de sortie $y(t)$, des fonctions d'activation et des connexions judas. La sortie du bloc est connectée de manière redondante à l'entrée du bloc et à toutes les portes [47].

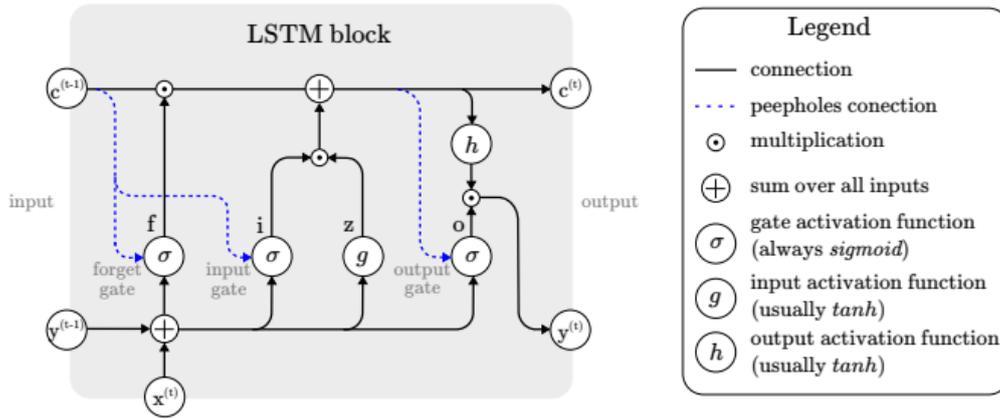


FIGURE 3.3 – Architecture d’un bloc LSTM vanille typique.

[47]

3.4.2 Applications connexes

Le réseau LSTM est appliqué dans un large éventail de domaines problématiques, à la fois individuellement et en combinaison avec d’autres architectures d’apprentissage en profondeur. Comme indiqué précédemment, LSTM est l’un des réseaux les plus avancés pour le traitement des séries chronologiques. Pour cette raison, la vanille LSTM est toujours l’une des options de réseau les plus populaires, bien qu’elle puisse être combinée avec d’autres réseaux pour créer des modèles hybrides. LSTM est bien adapté pour traiter les prédictions de séries chronologiques, ainsi que tout autre problème nécessitant une mémoire temporelle [47].

Voici quelques-uns des sujets auxquels le modèle est le plus adapté [47] :

Prédiction de séries chronologiques :

Lorsqu’il s’agit de séries chronologiques dans les données, les données de séries chronologiques viennent immédiatement à l’esprit. Cependant, il s’agit d’un concept large. Dans le sens le plus littéral de la prévision des séries chronologiques, le modèle LSTM a été appliqué aux prévisions des marchés financiers, par exemple, par Fisher, Cross, Yan et Ouyang. En raison de propriétés complexes telles que la corrélation non linéaire, la variabilité et la séquence, les données financières posent un défi majeur en matière de prévision. Cependant, Fisher et Cross ont montré que le réseau LSTM surpasse les benchmarks traditionnels : forêt aléatoire, réseau neuronal profond standard et régression logistique standard. Ce résultat a confirmé que LSTM est supérieur aux méthodes standard pour prédire la production de pétrole. Dans leurs

recherches, ils ont empilé plusieurs couches de blocs LSTM les uns sur les autres de manière hiérarchique. Cela a augmenté la capacité du modèle à gérer des tâches temporelles et lui a permis de mieux capturer la structure de la séquence de données. En essayant de prédire le prix du marché du pétrole, les auteurs sont arrivés aux mêmes conclusions. Le modèle de prédiction proposé, composé d'une architecture LSTM vanille, s'est avéré supérieur.

Cependant, la méthode proposée peut également être généralisée à d'autres applications. Il s'agit d'une caractéristique importante du cadre, car il a été démontré que l'erreur de prédiction peut être considérablement réduite en utilisant cette approche.

Traitement du langage naturel

LSTM est une force avec laquelle il faut compter dans l'apprentissage des langues, à la fois hors contexte et sensible au contexte. Le traitement du langage naturel est un domaine de recherche qui explore comment les ordinateurs peuvent être utilisés pour comprendre et traiter du texte ou de la parole en langage naturel pour faire des choses utiles. La reconnaissance vocale utilisant le modèle LSTM a d'abord été réalisée car il a l'avantage majeur de gérer de longs délais. Des résultats similaires au modèle de Markov caché (HMM) ont été obtenus dans cette expérience. Ce travail a ensuite lancé une exploration plus approfondie de LSTM dans ce domaine. Les systèmes de dialogue doivent être capables de répondre à une entrée audio hors champ, plutôt que de donner une réponse aléatoire. Dans un classificateur binaire construit à l'aide de deux couches LSTM.

Naturellement, de nombreux travaux ont contribué au domaine du traitement du langage naturel en utilisant (l'un des types de) LSTM. Les exemples incluent la segmentation des mots chinois, la segmentation morphologique, l'extraction des relations, le mappage du texte naturel aux entités de la base de connaissances, la prédiction des emoji et les tâches de traduction.

Sous-titrage d'images et de vidéos

Jusqu'à présent, nous avons discuté des prédictions de séries chronologiques de base et du traitement du langage naturel. Cependant, il peut être demandé à un ordinateur de décrire ce qui peut être vu dans une image ou une vidéo dans un format de parole proche de la nature. C'est ce qu'on appelle le sous-titrage d'images et de vidéos. Du point de vue de notre étude de la littérature, nous remarquons que ce domaine fonctionne souvent avec une architecture hybride CNN-LSTM, suivant ainsi le cadre encodeur-décodeur. Par exemple, faire en sorte qu'un CNN alimente une séquence de trames vers des couches LSTM pour générer la séquence de mots, où

les connaissances linguistiques intégrées à partir de grands corpus de texte.

L'étude de Chen et ses collègues s'appuie sur les dernières avancées en matière de vision par ordinateur pour permettre aux "robots de parler". En d'autres termes, l'objectif de cette recherche était d'alimenter le modèle avec des images de voitures, car la détection de voitures est un sujet brûlant dans la technologie de conduite autonome, qui générerait alors une description textuelle de l'image dans un langage humain compréhensible. À cet égard, CNN a été appliqué pour extraire des propositions de surface de véhicule à inclure dans des fenêtres de taille fixe. LSTM peut alors générer une description d'une phrase de l'entrée d'image étroitement liée à l'image d'entrée avec des mots de longueur variable. Comparé à quatre autres algorithmes apparentés, le modèle proposé par Chen et al s'est avéré supérieur.

vision par ordinateur

LSTM a rapporté des performances exceptionnelles en raison de la capacité inhérente du modèle à traiter les transformations spatio-temporelles. Une variation significative des performances a été détectée dans ces tests, indiquant qu'il y a encore place à l'amélioration. Zhang et ses collègues ont exploré les effets de l'attention dans le LSTM convolutif par rapport à la reconnaissance des gestes et ont découvert que les structures convolutives dans le déclenchement ne jouent pas de rôle dans l'attention spatiale. Au lieu de cela, la réduction de ces structures se traduit par une meilleure résolution, une taille de paramètre inférieure et une consommation de calcul inférieure. Ils ont donc introduit une nouvelle variante de LSTM.

-Bien sûr, l'utilisation de l'architecture LSTM n'est pas limitée aux applications décrites, il existe de nombreuses autres applications qui utilisent l'architecture LSTM en raison de sa supériorité.

3.5 Méthodologie

3.5.1 Comment créer un formulaire lstm

Dans le but d'illustrer le fonctionnement du modèle LSTM, nous supposons un réseau de blocs de traitement N et d'entrées M . Le passage vers l'avant dans ce système neuronal récurrent est décrit ci-dessous [47] :

1. Entrée de bloc :

cette étape consiste à mettre à jour le composant d'entrée de bloc, qui combine l'entrée actuelle $x(t)$ avec la sortie de l'unité LSTM $y(t-1)$ dans la dernière itération. Cela peut

être fait comme indiqué ci-dessous :

$$Z^{(t)} = g(W_z x^{(t)} + R_z y^{(t-1)} + b_z)$$

où W_z et R_z sont les poids associés respectivement à $x^{(t)}$ et $y^{(t-1)}$, tandis que b_z représente le vecteur de poids de biais.

2. Porte d'entrée :

Dans cette étape, nous mettons à jour la porte d'entrée qui combine l'entrée actuelle $x^{(t)}$, la sortie de cette unité LSTM $y^{(t-1)}$ et la valeur de cellule $c^{(t-1)}$ dans la dernière itération.

L'équation suivante illustre cette procédure :

$$i^{(t)} = q((W_i x^{(t)} + R_i y^{(t-1)} + p_i) * (c^{(t-1)} + b_i))$$

où désigne (*) la multiplication ponctuelle de deux vecteurs, w_i , R_i et p_i sont les poids associés à $x^{(t)}$, $y^{(t-1)}$ et $c^{(t-1)}$, respectivement, tandis que b_i représente pour le vecteur de biais associé à cette composante.

Dans les étapes précédentes, la couche LSTM détermine quelles informations doivent être conservées dans les états de cellule du réseau $c^{(t)}$.

Cela comprenait la sélection des valeurs candidates $z^{(t)}$ qui pourraient potentiellement être ajoutées aux états de cellule, et les valeurs d'activation $i^{(t)}$ des portes d'entrée.

3. Oubliez la porte :

Dans cette étape, l'unité LSTM détermine quelles informations doivent être supprimées de ses états de cellule précédents $c^{(t-1)}$. Par conséquent, les valeurs d'activation $f^{(t)}$ des portes d'oubli au pas de temps t sont calculées sur la base de l'entrée actuelle $x^{(t)}$, les sorties $y^{(t-1)}$ et l'état $c^{(t-1)}$ des cellules mémoire à la précédente le pas de temps $(t-1)$, les connexions des judas et les termes de biais b_f des portes oubliées. Cela peut être fait comme suit :

$$f^{(t)} = q((W_f x^{(t)} + R_f y^{(t-1)} + p_f) * (c^{(t-1)} + b_f))$$

où W_f , R_f et p_f sont les poids associés à $x^{(t)}$, $y^{(t-1)}$ et $c^{(t-1)}$, respectivement, tandis que b_f désigne le vecteur de poids de biais.

4. Cellule :

Cette étape calcule la valeur de cellule, qui combine l'entrée de bloc $z^{(t)}$, la porte d'entrée $i^{(t)}$ et les valeurs de porte d'oubli $f^{(t)}$, avec la valeur de cellule précédente. Cela peut être fait comme illustré ci-dessous : $c^{(t)} = z^{(t)} * i^{(t)} + c^{(t-1)} * f^{(t)}$

5. Porte de sortie :

Cette étape calcule la porte de sortie, qui combine le courant entrée $x^{(t)}$, la sortie de cette unité LSTM $y^{(t-1)}$ et la valeur de cellule $c^{(t-1)}$ dans la dernière itération. Cela peut être fait comme illustré ci-dessous :

$$O^{(t)} = q(w_o x^{(t)} + R_o y^{(t-1)} + p_o * c^{(t)} + b_o)$$

où W_o , R_o et p_o sont les poids associés respectivement à $x^{(t)}$, $y^{(t-1)}$ et $c^{(t-1)}$, tandis que b_o désigne le vecteur de poids de biais.

6. Bloquer la sortie :

Enfin, nous calculons la sortie du bloc, qui combine la valeur actuelle de la cellule $c^{(t)}$ avec la valeur actuelle de la porte de sortie comme suit :

$$y^{(t)} = g(c^{(t)}) * o^{(t)}$$

Il semble opportun de souligner que la fonctionnalité de cette architecture a inspiré les auteurs à promouvoir l'apprentissage de réseaux très profonds. Le mécanisme fermé a été utilisé dans les réseaux dits autoroutiers pour permettre la circulation sans entrave de l'information à travers de nombreuses couches. Cela peut être considéré comme une autre preuve de concept, montrant que les portes fonctionnent. Bien que vanilla LSTM fonctionne très bien, de nombreux travaux ont examiné les possibilités d'amélioration des performances. Par exemple, Su et Kuo ont développé le modèle LSTM étendu, qui a encore amélioré la précision des prédictions.

Dans de nombreux domaines d'application en améliorant la capacité de mémoire. Cela montre qu'il est encore possible d'apporter des améliorations théoriques à une architecture de performance déjà bien développée. Dans les travaux de Bayer et al. La recherche d'améliorations du modèle était déjà en cours. Les auteurs ont recherché une alternative architecturale à LSTM pour améliorer les capacités d'apprentissage séquentiel. Ils ont réussi à faire évoluer des structures de cellules mémoire capables d'apprendre des langages formels sensibles au contexte grâce à la lignée de gradient, ce qui, à bien des égards, est comparable aux performances de LSTM. Les auteurs se sont appuyés sur des réseaux récurrents de neurones à pointes et ont développé des réseaux de neurones épineux à mémoire à long terme (LSNN) comprenant des neurones adaptatifs. Lors de tests où la taille du LSNN était similaire à celle du LSTM, les performances se sont avérées très similaires à celles du LSTM. Ceci est un autre exemple de la précision de LSTM est et est toujours.

3.5.2 Architecture de réseau

L'architecture LSTM se compose d'un ensemble de sous-réseaux connectés de manière récurrente, appelés blocs de mémoire. Ces blocs peuvent être considérés comme une version différentiable des puces de mémoire dans un ordinateur numérique. Chaque bloc contient une ou plusieurs cellules de mémoire auto-connectées et trois unités multiplicatives - les portes d'entrée, de sortie et d'oubli - qui fournissent des analogues continus des opérations d'écriture, de lecture et de réinitialisation pour les cellules.[48]

LSTM conventionnel

Le LSTM contient des unités spéciales appelées blocs de mémoire dans la couche cachée récurrente. Les blocs de mémoire contiennent des cellules de mémoire avec des auto-connexions stockant l'état temporel du réseau en plus d'unités multiplicatives spéciales appelées portes pour contrôler le flux d'informations. Chaque bloc de mémoire dans l'architecture d'origine contenait une porte d'entrée et une porte de sortie.

La porte d'entrée contrôle le flux d'activations d'entrée dans la cellule de mémoire. La porte de sortie contrôle le flux de sortie des activations de cellules dans le reste du réseau. Plus tard, la porte d'oubli a été ajoutée au bloc de mémoire. Cela a résolu une faiblesse des modèles LSTM les empêchant de traiter des flux d'entrée continus qui ne sont pas segmentés en sous-séquences. La porte d'oubli met à l'échelle l'état interne de la cellule avant de l'ajouter comme entrée à la cellule via la connexion auto-récurrente de la cellule, oubliant ou réinitialisant ainsi de manière adaptative la mémoire de la cellule. De plus, l'architecture LSTM moderne contient des connexions de judas entre ses cellules internes et les portes de la même cellule pour apprendre une synchronisation précise des sorties[13].

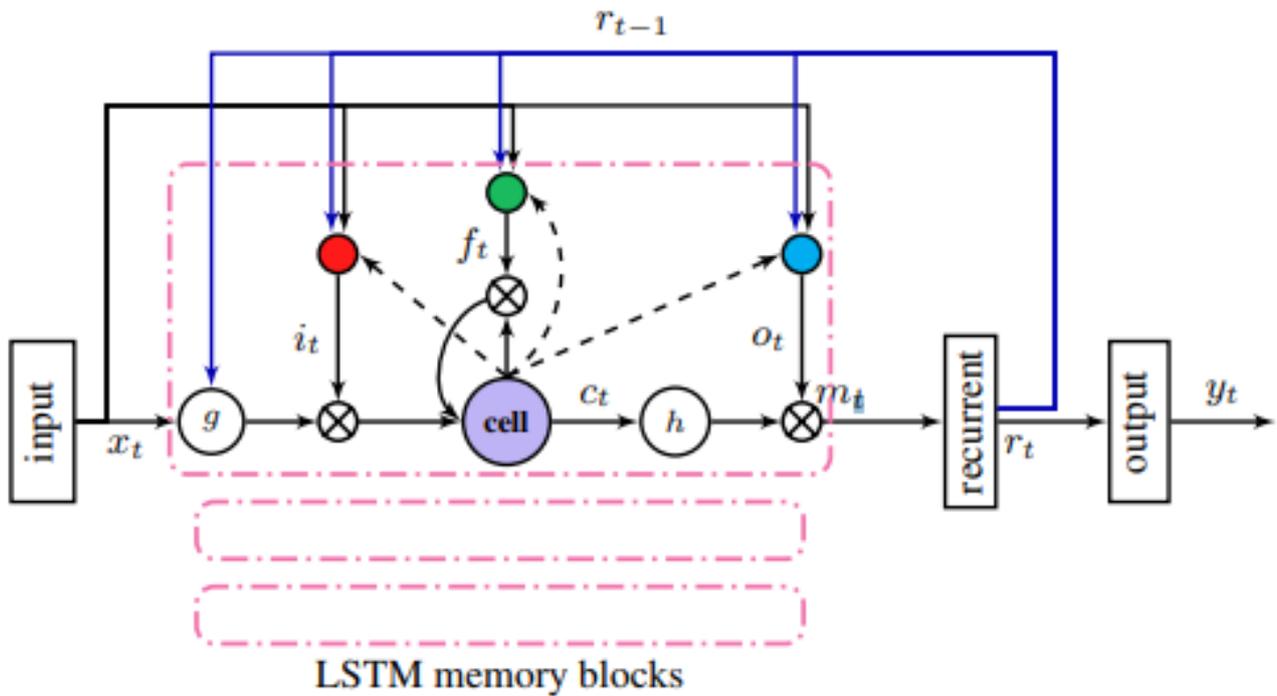


FIGURE 3.4 – Architecture RNN LSTM. Un seul bloc de mémoire est représenté pour plus de clarté.[13]

LSTM profond

Comme pour les DNN avec des architectures plus profondes, les RNN LSTM profonds ont été utilisés avec succès pour la reconnaissance vocale. Les RNN LSTM profonds sont construits en empilant plusieurs couches LSTM. Notez que les RNN LSTM sont déjà des architectures profondes dans le sens où ils peuvent être considérés comme un réseau de neurones feed-forward déroulé dans le temps où chaque couche partage les mêmes paramètres de modèle. On peut voir que les entrées du modèle passent par plusieurs couches non linéaires comme dans les DNN, mais les caractéristiques d'un instant donné ne sont traitées que par une seule couche non linéaire avant de contribuer à la sortie pour cet instant. Par conséquent, la profondeur des RNN LSTM profonds a une signification supplémentaire. L'entrée du réseau à un pas de temps donné passe par plusieurs couches LSTM en plus de la propagation à travers les couches temporelles et LSTM. Il a été avancé que les couches profondes des RNN permettent au réseau d'apprendre à différentes échelles de temps sur l'entrée. Les RNN LSTM profonds offrent un autre avantage par rapport aux RNN LSTM standard : ils peuvent mieux utiliser les paramètres en les répartissant dans l'espace à travers plusieurs couches. Par exemple, plutôt que d'augmenter la taille mémoire d'un modèle standard d'un facteur 2, on peut avoir 4 couches avec approximativement le même nombre de paramètres. Cela se traduit par des entrées passant

par plus d'opérations non linéaires par pas de temps[13].

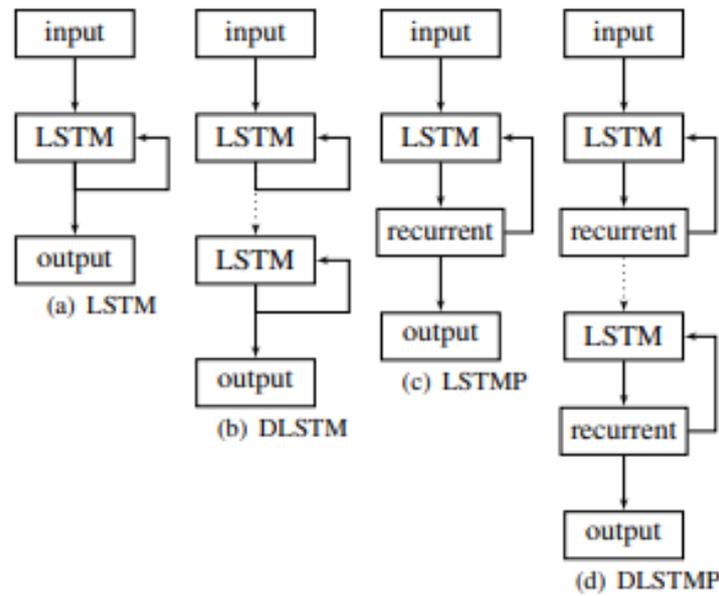


FIGURE 3.5 – Schéma général du RNN LSTMMP.[13]

LSTMP - LSTM avec couche de projection récurrente

L'architecture LSTM RNN standard comporte une couche d'entrée, une couche LSTM récurrente et une couche de sortie. La couche d'entrée est connectée à la couche LSTM. Les connexions récurrentes dans la couche LSTM vont directement des unités de sortie de cellule aux unités d'entrée de cellule, aux portes d'entrée, aux portes de sortie et aux portes oubliées. Les unités de sortie de cellule sont également connectées à la couche de sortie du réseau[13].

LSTMP profond

Semblable au LSTM profond, Un LSTMP profond comporte plusieurs couches LSTM chacune avec une couche de projection récurrente séparée sont empilées. LSTMP permet d'augmenter la mémoire du modèle indépendamment de la couche de sortie et des connexions récurrentes. Cependant, l'augmentation de la taille de la mémoire rend le modèle plus sujet au surajustement en mémorisant les données de la séquence d'entrée. Les réseaux de neurones profonds (DNN) se généralisent mieux aux exemples invisibles avec une profondeur croissante. La profondeur rend les modèles plus difficiles à suradapter aux données de formation, car les entrées du réseau doivent passer par de nombreuses fonctions non linéaires. Avec cette motivation, nous avons expérimenté des architectures LSTMP profondes, où l'objectif est d'augmenter la taille de la mémoire et la puissance de généralisation du modèle[13].

3.5.3 Visualisez le LSTM avec nos prévisions météo

Les conditions météorologiques dans notre cas dépendent de : La direction dans laquelle le temps allait dans les heures précédentes, il peut diminuer ou augmenter. D'autres facteurs peuvent également influencer, notamment : Type, température, humidité, vitesse du vent, relevement du vent, visibilité, pression.

Nous utiliserons le LSTM conventionnel car, d'après ce que nous avons conclu de notre étude, il est compatible avec les séries temporelles.

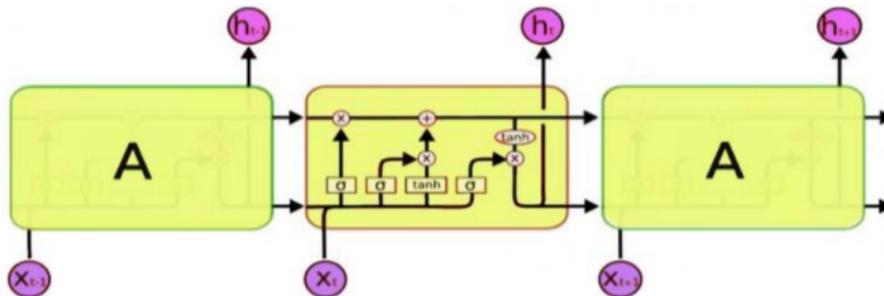


FIGURE 3.6 – la structure générale de lstm[14]

Architecture du LSTMs

Un réseau LSTM typique se compose de différents blocs de mémoire appelés cellules (les rectangles que nous voyons dans la figure 3.6).

Il y a deux cas qui sont déplacés vers la cellule suivante ; État de la cellule et état caché.

L'état de la cellule est la ligne horizontale sur la figure et agit comme un tapis roulant qui transporte certaines données de manière linéaire à travers le canal de données.

Oubliez la couche de porte : La couche sinusoidale définit les données qui ne sont pas importantes et nous devons les supprimer. Le calcul est effectué en examinant la nouvelle entrée et l'horodatage précédent qui génère finalement un nombre compris entre 0 et 1 pour chaque nombre dans cet état de cellule.

En tant que modèle binaire typique, 1 représente le maintien de l'état de la cellule tandis que 0 représente sa suppression.

Cette porte prend deux entrées ; $h_{(t-1)}$ et x_t sont ensuite multipliés par les matrices de poids et le biais est ajouté puis la fonction sigmoïde est appliquée à cette valeur.

Ce vecteur obtenu à partir de la fonction sigmoïde est multiplié par l'état de la cellule.

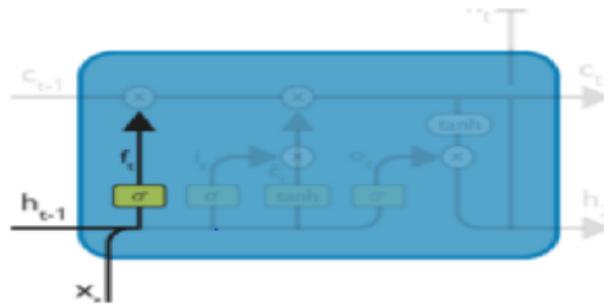


FIGURE 3.7 – la couche de porte[14]

Portail d’entrée : Le processus d’ajout de nouvelles informations peut être effectué via le portail d’entrée.

Par exemple : dans le cas actuel, les données d’une journée ensoleillée normale sont activées et tout à coup il y a des éclairs et il pleut, ce qui provoque des changements dans les données qui affecteront les données futures. Donc, cette information doit être ajoutée dans la situation actuelle.

L’ajout de ces informations est essentiellement un processus en trois étapes, comme le montre le diagramme ci-dessous.

Deux métiers :

1. Sigmoide qui filtrera à nouveau les informations de x_t et $h_{(t-1)}$
2. Tanh qui créera un vecteur contenant toutes les valeurs possibles pouvant être ajoutées (comme réalisé à partir de $h_{(t-1)}$ et x_t à l’état de la cellule.

Multipliez la valeur du filtre régulateur (la porte sigmoïde) au vecteur généré (la fonction tanh), puis ajoutez ces informations utiles à l’état de la cellule via le processus d’addition.

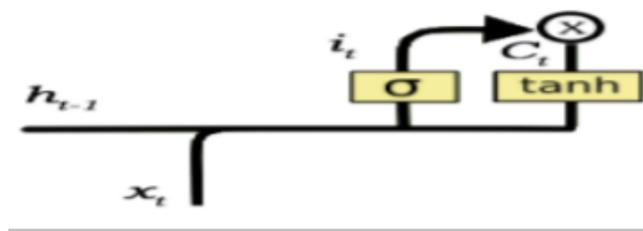


FIGURE 3.8 – Portail d’entrée[14]

Porte de sortie La tâche de sélectionner des informations utiles à partir de l’état actuel de la cellule et de les afficher en tant que sortie est effectuée via la porte de sortie.

3 étapes :

1. Fonction Tanh appliquée à l'état de la cellule pour que tous les vecteurs candidats soient envoyés en sortie.
2. La fonction sigmoïde pour filtrer les facteurs générés par la fonction tanh.
3. Multipliez la valeur de ce filtre régulateur au vecteur généré à l'étape 1, envoyez-le en sortie et également à l'état caché de la cellule suivante.

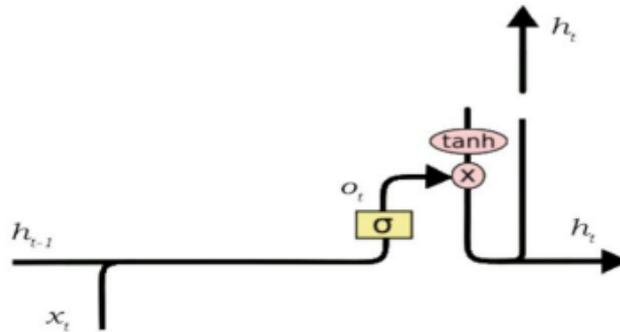


FIGURE 3.9 – Porte de sortie[14]

3.5.4 La structure générale du modèle proposé

La structure générale du modèle RNN proposé comprend les éléments suivants :

- Couche LSTM avec 64 unités ou cellules de mémoire.
- Après la couche LSTM, une couche de 256 unités Dense a été ajoutée et nommée "FC1" dans la figure 3.10.
- Une couche d'activation 'ReLU' pour introduire des propriétés non linéaires dans le modèle.
- Couche de suppression pour éviter une divergence élevée et améliorer la capacité du modèle à gérer les données d'entraînement.
- Une couche composée d'une seule unité Dense, nommée "out layer"

La figure 3.10 illustre l'architecture générale du modèle proposé

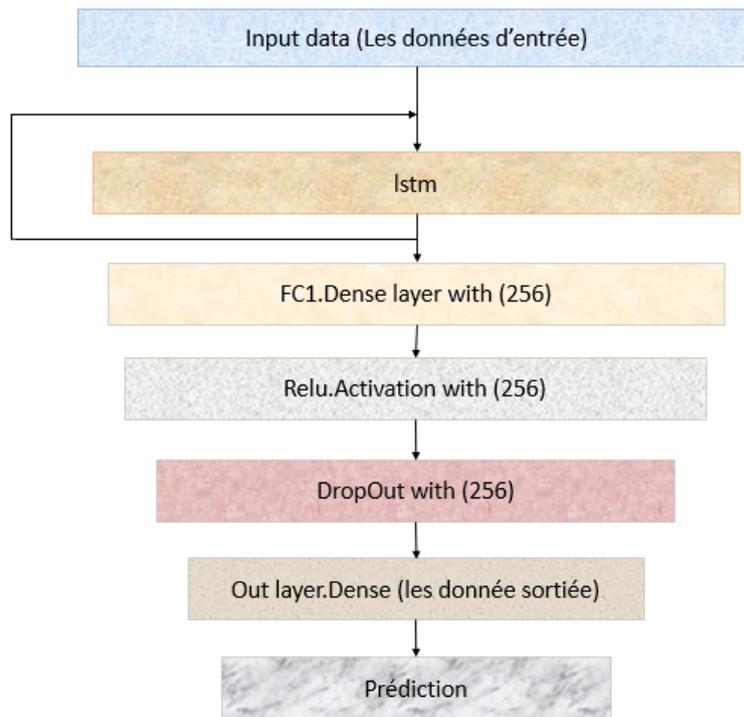


FIGURE 3.10 – Schéma général montrant l'architecture du réseau de neurones artificiels utilisé

3.6 conclusion

Nous avons expliqué la structure du modèle proposé et le rôle de l'utilisation de la technique LSTM dans le processus de prédiction afin d'obtenir des prédictions avec une meilleure précision. Dans le chapitre suivant, nous décrirons en détail la mise en œuvre de cette idée.

CHAPITRE 4

REALISATION DU SYSTEME

4.1 Introduction

Après avoir diagnostiqué le problème à traiter, défini les concepts théoriques et précisé la méthode que nous avons utilisée, nous aborderons dans ce dernier chapitre l'aspect pratique en présentant les résultats obtenus.

4.2 Environnement de développement :

4.2.1 Environnement matériels(Hardware) :

Nous présentons les expériences détaillées et les étapes d'évaluation pour tester l'efficacité de notre modèle. Nos expériences ont été basées sur un ensemble de données du jeu de données de séries chronologiques (Weather Dataset[49]). Toutes les expériences ont été réalisées sur un ordinateur HP équipé d'un processeur Intel(R) Core(TM) i5-3230M N3060 @ 2,60 GHz 2,60 GHz et 4 Go de RAM.

4.2.2 Environnement logiciel(Software) :

Il existe plusieurs langages de programmation et packages différents qui peuvent être utilisés dans ce domaine, nous avons choisi le langage de programmation Python et quelques bibliothèques et frameworks communs pour implémenter la méthode proposée.

Python :

Python est l'un des langages de programmation les plus populaires au monde ces dernières années. Il est utilisé pour tout, de l'apprentissage automatique à la création de sites Web et aux tests de logiciels. Il peut être utilisé aussi bien par les développeurs que par les non-développeurs.

Python est l'un des langages de programmation informatique les plus populaires au monde ces dernières années, étant utilisé pour tout, de l'apprentissage automatique à la création de sites Web et aux tests de logiciels. Ils sont souvent utilisés pour créer des sites Web, des programmes, automatiser des tâches et effectuer des analyses de données. Python est un langage à usage général, ce qui signifie qu'il peut être utilisé pour créer une grande variété de programmes différents et qu'il n'est pas spécialisé pour des problèmes spécifiques. Cette polyvalence, ainsi que sa facilité d'utilisation pour les débutants, en ont fait l'un des langages de programmation les plus utilisés aujourd'hui.

Parmi les domaines d'utilisation du langage Python :Analyse de données et l'apprentissage

automatique, développement web, Automatisation ou script, Test et prototypage de logiciels, tâches quotidiennes [50].



FIGURE 4.1 – Logo Python

[51]

TensorFlow :

TensorFlow Il s'agit d'une plate-forme d'apprentissage automatique complète et open source, et dispose d'un écosystème complet et flexible d'outils, de bibliothèques et de ressources communautaires qui permettent aux chercheurs et aux développeurs de pousser facilement les dernières avancées en matière d'apprentissage automatique et de les déployer avec ML[15].



FIGURE 4.2 – TensorFlow Logo[15]

Pandas :

pandas est un outil d'analyse et de traitement de données open source rapide, puissant, flexible et facile à utiliser, basé sur le langage de programmation Python[16].



FIGURE 4.3 – Pandas Logo[16]

Keras :

Keras est l'un des éléments clés de la nouvelle infrastructure de modélisation de YouTube Discovery. Il apporte une API claire et cohérente et une manière commune d'exprimer des idées de modélisation à 8 équipes sur les principales surfaces de recommandations YouTube[17].



FIGURE 4.4 – Logo Keras[17]

Numpy :

NumPy est le package de base pour le calcul scientifique en Python. Il s'agit d'une bibliothèque Python qui fournit un objet tableau multidimensionnel, divers objets dérivés (tels que des matrices et des matrices masquées) et une variété de routines pour des opérations rapides sur des tableaux, y compris la manipulation mathématique et logique de la forme, le tri, la sélection, l'entrée/sortie, transformées de Fourier discrètes, algèbre linéaire de base et simulation aléatoire d'opérations statistiques de base et bien plus encore[18].



FIGURE 4.5 – Logo NumPy[18]

Seaborn :

Seaborn est une bibliothèque Python de visualisation de données basée sur matplotlib. Il fournit une interface de haut niveau pour dessiner des graphiques statistiques attrayants et informatifs[19].



FIGURE 4.6 – Logo Seaborn [19]

Google colab :

Colaboratory, ou "Colab" en abrégé, est un produit de Google Research. Colab permet à quiconque d'écrire et d'exécuter du code Python arbitraire via le navigateur, et est particulièrement adapté à l'apprentissage automatique, à l'analyse de données et à l'éducation. Plus techniquement, Colab est un service d'ordinateur portable hébergé par Jupyter qui ne nécessite aucune

configuration pour être utilisé, tout en offrant un accès gratuit aux ressources informatiques, y compris les GPU[52].



FIGURE 4.7 – Logo Google colab

4.3 Les étapes du code :

Dans cette partie nous décrivons l'ensemble des données et le code source utilisée dans ce travail.

4.3.1 Dataset :

L'ensemble de données que nous avons étudié (prévisions de température météo) a été extrait du site kaggle[49], composé de lignes 96453 et de colonnes 12. Nous divisons l'ensemble de données en deux parties, un groupe de formation et un groupe de test.

Dictionnaire de données

- Formatted Date : date et heure des données météorologiques enregistrées
- Summary :Résumé météo des données enregistrées
- Precip Type :Type de précipitation, le cas échéant
- Temperature (C) :Température en Celsius
- Apparent Temperature (C) :température apparente en degrés Celsius
- Humidity : Niveau d'humidité
- Wind Speed (km/h) :Vitesse du vent en kilomètres par heure
- Wind Bearing (degrees) : Relèvement du vent en degrés
- Visibility (km) :Visibilité en kilomètres
- Loud Cover :une valeur binaire indiquant si les données sont bruyantes
- Pressure (millibars) :Pression atmosphérique en millibars
- Daily Summary : résumé météo pour toute la journée

```
from google.colab import drive
drive.mount('/content/drive')
```

FIGURE 4.8 – Code Python pour Importation des données

- **Importation des données** : illustre les instructions de téléchargement des données à partir de Drive à Google Colab.

	Formatted Date	Summary	Precip Type	Temperature (C)	Apparent Temperature (C)	Humidity	Wind Speed (km/h)	Wind Bearing (degrees)	Visibility (km)	Loud Cover	Pressure (millibars)	Daily Summary
0	2006-04-01 00:00:00.000 +0200	Partly Cloudy	rain	9.472222	7.388889	0.89	14.1197	251.0	15.8263	0.0	1015.13	Partly cloudy throughout the day.
1	2006-04-01 01:00:00.000 +0200	Partly Cloudy	rain	9.355556	7.227778	0.86	14.2646	259.0	15.8263	0.0	1015.63	Partly cloudy throughout the day.
2	2006-04-01 02:00:00.000 +0200	Mostly Cloudy	rain	9.377778	9.377778	0.89	3.9284	204.0	14.9569	0.0	1015.94	Partly cloudy throughout the day.
3	2006-04-01 03:00:00.000 +0200	Partly Cloudy	rain	8.288889	5.944444	0.83	14.1036	269.0	15.8263	0.0	1016.41	Partly cloudy throughout the day.
4	2006-04-01 04:00:00.000 +0200	Mostly Cloudy	rain	8.755556	6.977778	0.83	11.0446	259.0	15.8263	0.0	1016.51	Partly cloudy throughout the day.

FIGURE 4.9 – données de post-traitement

- **La liste des bibliothèques utilisées** :

```
import tensorflow as tf
import os
import pandas as pd
import numpy as np
import seaborn as sn
from sklearn.preprocessing import LabelEncoder, OneHotEncoder, MinMaxScaler
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import LSTM, Activation, Dropout
from sklearn.metrics import mean_squared_error
from matplotlib import pyplot
```

FIGURE 4.10 – la liste des bibliothèques

4.3.2 Section de prétraitement

C'est l'étape de préparation et de traitement de l'ensemble de données, son but est d'organiser et d'exploiter les données et de trouver les données manquantes de manière spécifique. Dans ce qui suit, nous mentionnons quelques-unes des opérations que nous avons effectuées à ce stade.

- Affiche un résumé des informations pour la variable 'df' qui contient les données lues dans le fichier 'csv'. Des informations telles que le nombre de lignes et de colonnes dans les données, les types de données dans chaque colonne et le nombre de valeurs non vides dans chaque colonne sont imprimées. Ces informations sont très utiles pour comprendre à quoi ressemblent les données, s'assurer qu'elles ont été lues correctement et pour déterminer tout nettoyage ou transformation de données que vous devez effectuer.

```
df.info()

<class 'pandas.core.frame.DataFrame'>
RangeIndex: 96453 entries, 0 to 96452
Data columns (total 12 columns):
#   Column                                Non-Null Count  Dtype
---  ---                                ---
0   Formatted Date                        96453 non-null  object
1   Summary                               96453 non-null  object
2   Precip Type                           95936 non-null  object
3   Temperature (C)                       96453 non-null  float64
4   Apparent Temperature (C)              96453 non-null  float64
5   Humidity                              96453 non-null  float64
6   Wind Speed (km/h)                     96453 non-null  float64
7   Wind Bearing (degrees)                 96453 non-null  float64
8   Visibility (km)                        96453 non-null  float64
9   Loud Cover                             96453 non-null  float64
10  Pressure (millibars)                   96453 non-null  float64
11  Daily Summary                          96453 non-null  object
dtypes: float64(8), object(4)
memory usage: 8.8+ MB
```

FIGURE 4.11 – Résumé des informations du fichier 'CSV'

- Supprimez certaines colonnes qui contiennent des informations sans importance, y compris la colonne 'Daily Summary'

```
df=df.drop(['Daily Summary'],axis=1)
```

FIGURE 4.12 – Supprimer la colonne 'Daily Summary'

- calculer le nombre de valeurs manquantes dans chaque colonne pour déterminer comment les traiter, soit en les supprimant, soit en les remplissant.

```
df.isnull().sum()
Formatted Date      0
Summary             0
PrecipType          517
Temperature (C)     0
Apparent Temperature (C) 0
Humidity            0
Wind Speed (km/h)   0
Wind Bearing (degrees) 0
Visibility (km)     0
Loud Cover          0
Pressure (millibars) 0
dtype: int64
```

FIGURE 4.13 – calculer le nombre de valeurs manquantes

— Afficher les données après les avoir traitées.

	Summary	PrecipType	Temperature	Humidity	WindSpeed	WindBearings	Visibilty	Pressure
date								
0	19	0	9.472222	0.89	14.1197	251.0	15.8263	1015.13
1	19	0	9.355556	0.86	14.2646	259.0	15.8263	1015.63
2	17	0	9.377778	0.89	3.9284	204.0	14.9569	1015.94
3	19	0	8.288889	0.83	14.1036	269.0	15.8263	1016.41
4	17	0	8.755556	0.83	11.0446	259.0	15.8263	1016.51

FIGURE 4.14 – Pré-traitement des données

4.3.3 Section de visualisation

Dans cette section, les données sont représentées sur des graphiques afin que nous puissions les comparer et conclure la relation entre les données.

— Carte thermique de la matrice de corrélation pour DataFrame df. La carte thermique affichera les valeurs de corrélation entre chaque paire de barres, la couleur indiquant la force de corrélation.

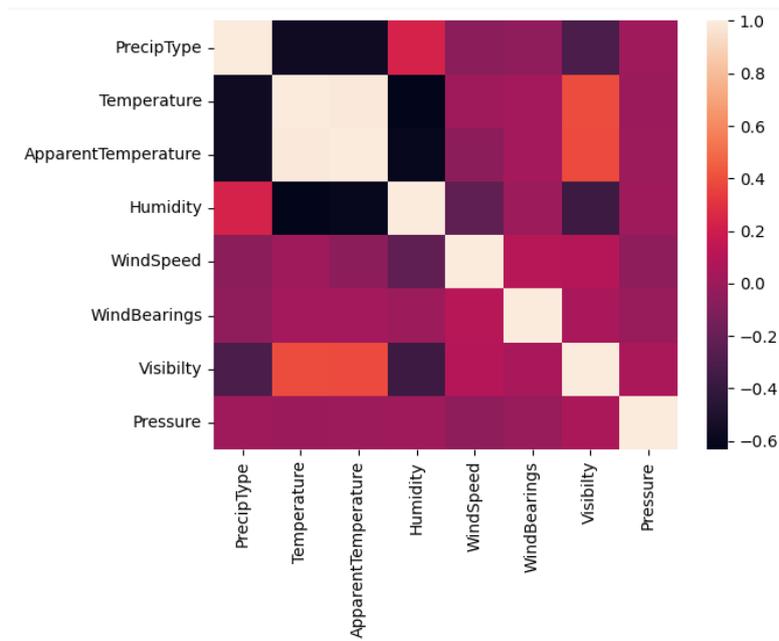


FIGURE 4.15 – la matrice de corrélation

— Créez une visualisation de nuage de points pour les colonnes "Température" et "Humidité" à partir de DataFrame df. Les points du nuage de points sont colorés en fonction des valeurs de "température".

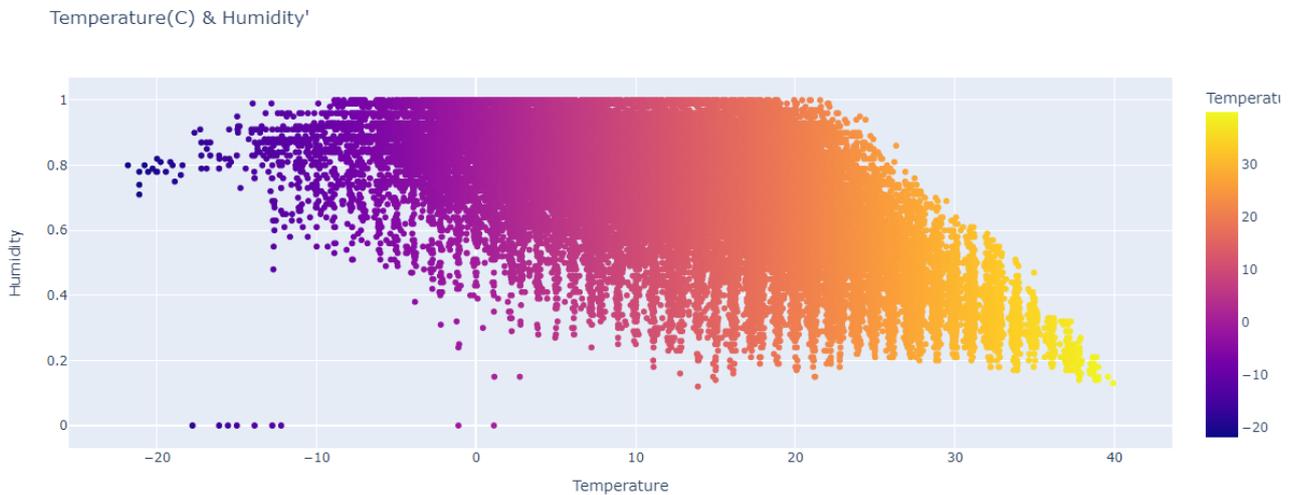


FIGURE 4.16 – nuage de points pour les colonnes "Température" et "Humidité"

— Créer un graphique pour comparer la vitesse du vent et la météo.

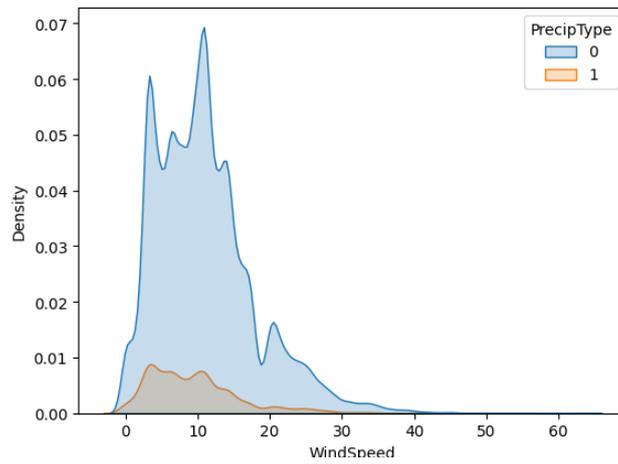


FIGURE 4.17 – comparer la vitesse du vent et la météo

4.3.4 Section modélisation prédictive

La troisième et dernière étape consiste à créer et former un modèle d'IA(Lstm).

Division des données

Dans cette étape, nous divisons les données en données d'entraînement et en données de test.

-Notre total total de données est de 96452 (100%).

-Données de formation 87690 (90,91%).

-Données d'essai 8760 (9,08 %).

```
train = values[n_train_hours:, :]  
test = values[:n_train_hours,:]
```

FIGURE 4.18 – Division des données

Modèle Lstm :

```
# design network
model = Sequential()
model.add(LSTM(30, input_shape=(train_X.shape[1], train_X.shape[2]))) # input_shape=(no. of i/p, dimension), result=(1,50)
# test
model.add(Dense(256,name='FC1')) #256
model.add(Activation('relu'))
model.add(Dropout(0.2))
# end
model.add(Dense(1,name='out_layer'))
model.compile(loss='mean_squared_error',optimizer='adam', metrics=['mean_squared_error'])
```

FIGURE 4.19 – Code Python pour Model Lstm

— Dans ce code, le réseau de neurones est entraîné à l'aide de la fonction "fit".

```
# fit network
history = model.fit(train_X, train_Y, epochs=100, batch_size=128, validation_data=(test_X, test_Y), verbose=2, shuffle=False) #,

Epoch 1/100
69/69 - 3s - loss: 0.0391 - mean_squared_error: 0.0391 - val_loss: 0.0104 - val_mean_squared_error: 0.0104 - 3s/epoch - 46ms/step
Epoch 2/100
69/69 - 2s - loss: 0.0126 - mean_squared_error: 0.0126 - val_loss: 0.0114 - val_mean_squared_error: 0.0114 - 2s/epoch - 22ms/step
Epoch 3/100
69/69 - 1s - loss: 0.0082 - mean_squared_error: 0.0082 - val_loss: 0.0056 - val_mean_squared_error: 0.0056 - 1s/epoch - 17ms/step
Epoch 4/100
69/69 - 2s - loss: 0.0050 - mean_squared_error: 0.0050 - val_loss: 0.0023 - val_mean_squared_error: 0.0023 - 2s/epoch - 22ms/step
Epoch 5/100
69/69 - 2s - loss: 0.0036 - mean_squared_error: 0.0036 - val_loss: 0.0022 - val_mean_squared_error: 0.0022 - 2s/epoch - 23ms/step
Epoch 6/100
69/69 - 1s - loss: 0.0029 - mean_squared_error: 0.0029 - val_loss: 0.0023 - val_mean_squared_error: 0.0023 - 1s/epoch - 18ms/step
Epoch 7/100
69/69 - 1s - loss: 0.0028 - mean_squared_error: 0.0028 - val_loss: 0.0017 - val_mean_squared_error: 0.0017 - 1s/epoch - 17ms/step
Epoch 8/100
69/69 - 1s - loss: 0.0026 - mean_squared_error: 0.0026 - val_loss: 0.0022 - val_mean_squared_error: 0.0022 - 1s/epoch - 21ms/step
Epoch 9/100
```

FIGURE 4.20 – Ajuster le modèle

Evaluation du modèle

— Ce code est utilisé pour tracer les lignes de colonne et tester la fonction de perte au fil du temps. L'historique de formation et la date de test du modèle sont utilisés pour déterminer dans quelle mesure le modèle peut fonctionner avec les données futures. Ces lignes aident à déterminer quand l'entraînement doit s'arrêter pour éviter le surentraînement et augmenter les coûts du modèle. Plus la colonne et les lignes de train et validation sont proches les unes des autres, plus le modèle sera précis pour prédire les nouvelles données.

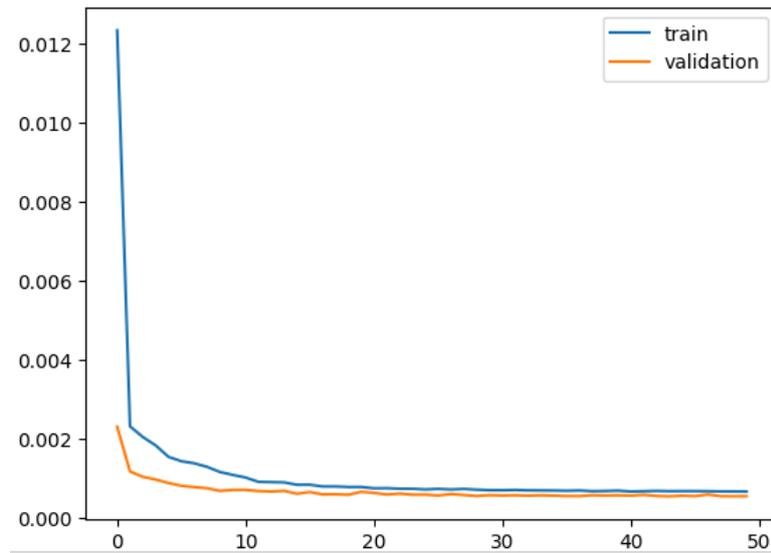


FIGURE 4.21 – modèle loss(température)

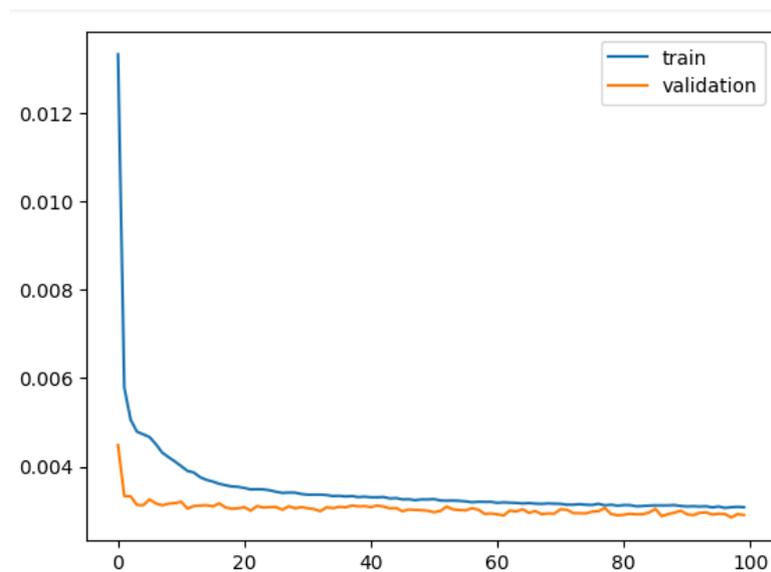


FIGURE 4.22 – modèle loss (humidité)

- La prédiction est faite à l'aide du modèle formé sur les données de formation des données de test à l'aide de la fonction "prédire", et la matrice de test a été reformatée pour correspondre à la forme d'origine pour une utilisation dans le calcul des métriques de base.

```
# make a prediction
test_Y_predicted = model.predict(test_X)
test_X = test_X.reshape((test_X.shape[0], n_hours*n_features))
```

FIGURE 4.23 – Prévission

- Ce code est utilisé pour afficher les données réelles et attendues pour la précision du modèle formé. Il trace les données réelles et attendues en fonction du temps (dans ce cas, les 100 premiers points) à l'aide de la bibliothèque pyplot de matplotlib. La première étape consiste à tracer l'ensemble de données réel , l'étape suivante consiste à tracer l'ensemble de données prédit, et pyplot.legend() est utilisé pour afficher la balise graph.

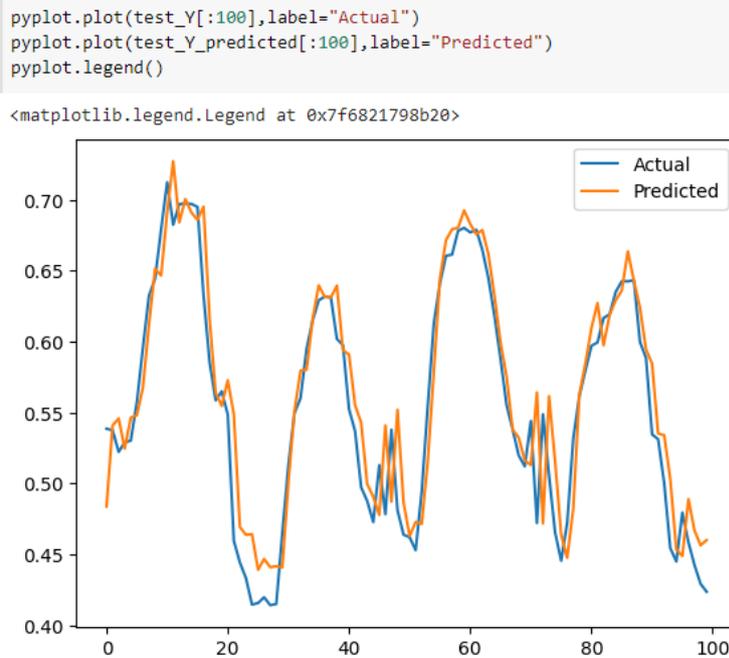


FIGURE 4.24 – Précision du modèle entraîné par rapport à la température

- Affiche les données réelles et projetées pour la précision du modèle formé par rapport à l'humidité telle que la température.

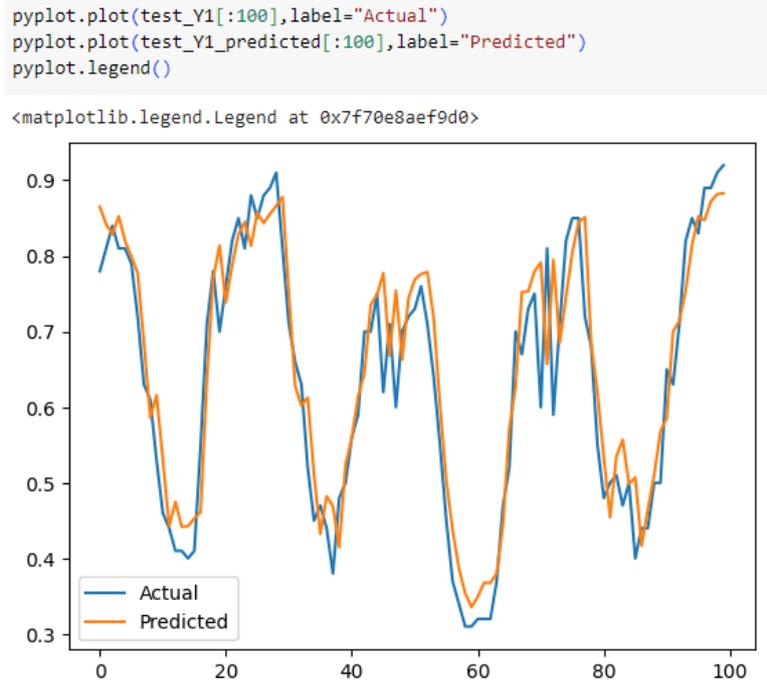


FIGURE 4.25 – Précision du modèle entraîné pour l’humidité

Résultats et expériences

— **taux d’erreur :**

Ce code calcule racine carrée de l’erreur quadratique moyenne (RMSE : Root Mean Squared Error) entre les valeurs réelles et attendues. La fonction `sqrt()` est utilisée pour calculer la racine carrée de la valeur renvoyée par la fonction `mean-squared-error()`, qui calcule l’erreur quadratique moyenne entre les valeurs réelles et prédites. Le résultat RMSE est imprimé à la fin du code.

```

# calculate RMSE
from math import sqrt
rmse = sqrt(mean_squared_error(inv_test_Y, inv_test_Y_predicted))
print('Test RMSE: %.3f' % rmse)

```

Test RMSE: 1.454

FIGURE 4.26 – taux d’erreur par rapport à la température(RMSE)

```

from math import sqrt
rmse = sqrt(mean_squared_error(inv_test_Y1, inv_test_Y1_predicted))
print('Test RMSE: %.3f' % rmse)

```

Test RMSE: 3.282

FIGURE 4.27 – Taux d’erreur relatif à l’humidité(RMSE)

La fonction `mean-squared-error()` calcule l'erreur quadratique moyenne (MSE : Mean Squared Error).

Le MSE est une autre mesure couramment utilisée pour vérifier la fiabilité d'un modèle de régression. Il mesure les écarts entre les valeurs prédites et les valeurs réellement observées.

Voici comment le MSE est calculé [53] :

$$MSE = (1/n) * \sum (y_{pred} - y_{actual})^2$$

Où :

- MSE : Erreur Quadratique Moyenne
- n : Nombre de mesure
- y_{pred} : Valeur prédite par le modèle
- y_{actual} : Valeur réelle

L'extrait de code des figures 4.28 et 4.29 calcule l'erreur quadratique moyenne (MSE) entre deux tableaux (les valeurs réelles et prédites).

```
import math
from sklearn.metrics import mean_squared_error
mse = mean_squared_error(inv_test_Y, inv_test_Y_predicted)
print('Test MSE: %.3f' % mse) |
```

Test MSE: 2.174

FIGURE 4.28 – Taux d'erreur relatif à la température(MSE)

figure

```
import math
from sklearn.metrics import mean_squared_error
mse = mean_squared_error(inv_test_Y1, inv_test_Y1_predicted)
print('Test MSE: %.3f' % mse)
```

Test MSE: 11.174

FIGURE 4.29 – Taux d'erreur relatif à l'humidité(MSE)

figure

- **La différence entre le calcul du taux d'erreur en régression et en classification :**

La différence entre le calcul du taux d'erreur de régression et la classification réside dans la nature du problème de prédiction et les échelles d'évaluation utilisées.

Dans la régression, le but est de prédire une valeur continue ou une quantité numérique. La métrique d'évaluation la plus courante pour les problèmes de régression est l'erreur quadratique moyenne (MSE) ou sa variante, la racine carrée de l'erreur quadratique moyenne (RMSE). Ces mesures mesurent la différence quadratique moyenne entre Valeurs attendues (inv-test-Y-predicted) et valeurs réelles (inv-test-Y). Plus le MSE ou RMSE est faible, meilleures sont les performances du modèle de régression.

Le calcul RMSE dans le code que nous avons fourni est un exemple d'évaluation d'erreur dans un problème de régression.

D'autre part, dans la classification, l'objectif est de prédire à quelle classe appartient un point de données. Les métriques d'évaluation pour les modèles de classification incluent : Exactitude (accuracy), précision (precision), rappel (recall), score (F1 score) et autres. Ces métriques comparent les étiquettes de classe prédites avec les étiquettes de classe réelles.

Par exemple, l'exactitude (accuracy) mesure le pourcentage d'étiquettes correctement prédites par le modèle à partir de tous les sortes de prédictions faites [54].

— **temps d'exécution** : L'intégralité du code est exécuté en 6 minutes.

— **Des tests** :

Ce code figure 4.30 crée un DataFrame nommé result contenant deux colonnes, la première contient la température réelle pour la période sur laquelle le modèle a été testé et la seconde contient la température attendue qui a été prédite à l'aide du modèle.

Et deux autres colonnes, la première contient l'humidité réelle et la seconde contient l'humidité attendue.

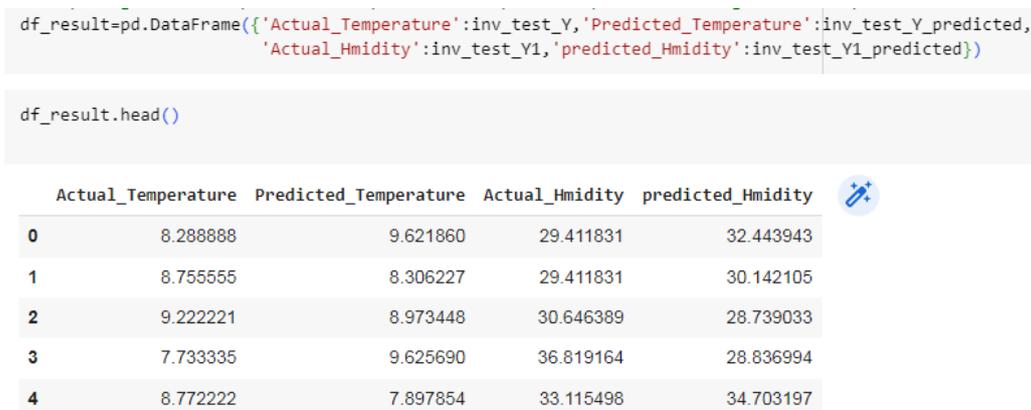


FIGURE 4.30 – comparer la température et l'humidité réelle et prédite

Cette commande figure 4.31 enregistre un DataFrame contenant les températures réelles et les prévisions dans un fichier csv .

```
df_result.to_csv("weather.csv")
```

FIGURE 4.31 – Le résultat

— Prédiction de température :

Nous utilisons un modèle de prédiction de température :

Nous créons d'abord un tableau 2D à l'aide de `np.array()` et spécifions la date de prédiction. Dans cet exemple, la date 07/01/2017 est définie comme date de prévision.

La deuxième étape consiste à effectuer la prévision en utilisant le modèle pour prédire la valeur en fonction de la date de prévision spécifiée.

`-model.predict()` est la fonction utilisée pour effectuer une prédiction basée sur un modèle entraîné. Ensuite, nous imprimons la valeur attendue pour le 07/01/2017.

```
prediction_date = np.array([[20170107]])
predicted_value = model.predict(prediction_date)

print("Predicted value for 2017/01/07:", predicted_value)

1/1 [=====] - 0s 119ms/step
Predicted value for 2017/01/07: [[11.249756]]
```

FIGURE 4.32 – Exemple de prédiction de date

4.4 Conclusion

Dans ce chapitre, nous avons présenté les étapes de l'implémentation en expliquant les outils utilisés pour mettre en œuvre le modèle proposé. Nous concluons que les résultats obtenus peuvent varier en fonction du modèle utilisé et de l'ensemble de données utilisé. Enfin, les résultats obtenus sont acceptables.

CONCLUSION GÉNÉRALE

La météo est l'un des facteurs les plus importants qui affectent positivement ou négativement divers domaines tels que l'économie, l'industrie, etc. Il est donc essentiel de prédire le temps afin de prendre des précautions et d'agir de manière prudente.

De plus, deux facteurs clés jouent un rôle majeur dans l'obtention de résultats précis : l'ensemble de données utilisé et la structure du modèle. Il existe également plusieurs méthodes de prévision du temps, mais certaines peuvent être moins précises. Dans notre thèse, nous nous sommes efforcés de trouver un ensemble de données permettant d'obtenir des prédictions plus précises en utilisant un modèle basé sur l'architecture LSTM largement utilisée pour la prédiction à l'aide de séries temporelles comme une variante des réseaux de neurones récurrents (RNN). Nous avons obtenu un taux de précision supérieur à 90% sur l'ensemble des données utilisées. À l'avenir, il est possible d'améliorer davantage ces résultats en entraînant le modèle sur plusieurs autres ensembles de données disponibles et populaires. Cela permettrait d'enrichir le modèle avec une plus grande variété de données et de contextes, ce qui pourrait conduire à des prédictions plus précises et plus fiables.

BIBLIOGRAPHIE

- [1] H. Jain and R. Jain, “Big data in weather forecasting : Applications and challenges,” in *2017 International conference on big data analytics and computational intelligence (ICB-DAC)*. IEEE, 2017, pp. 138–142.
- [2] S.-H. Liao, “Expert system methodologies and applications—a decade review from 1995 to 2004,” *Expert systems with applications*, vol. 28, no. 1, pp. 93–103, 2005.
- [3] *What is Regression ? Definition, Calculation, and Example*. [Online]. Available : url:<https://www.investopedia.com/terms/r/regression.asp>
- [4] T. McNally, M. Bonavita, and J.-N. Thépaut, “The role of satellite data in the forecasting of hurricane sandy,” *Monthly Weather Review*, vol. 142, no. 2, pp. 634–646, 2014.
- [5] G. Cormier, “Systèmes intelligents,” PDF file, 2004. [Online]. Available : http://www8.umoncton.ca/umcm-cormier_gabriel/SystemesIntelligents/GIND5439_Chapitre2.pdf
- [6] M. M. R. Khan, R. B. Arif, M. A. B. Siddique, and M. R. Oishe, “Study and observation of the variation of accuracies of knn, svm, lmn, enn algorithms on eleven different datasets from uci machine learning repository,” in *2018 4th International Conference on Electrical Engineering and Information & Communication Technology (iCEEiCT)*. IEEE, 2018, pp. 124–129.
- [7] M. OULMI and S. KALOUNE, “Classification d’objets avec le deep learning,” Ph.D. dissertation, UNIVERSITE AKLI MOHAND OULHADJ-BOUIRA, 2017.
- [8] R. Yamashita, M. Nishio, R. K. G. Do, and K. Togashi, “Convolutional neural networks : an overview and application in radiology,” *Insights into imaging*, vol. 9, pp. 611–629, 2018.
- [9] N. Malki and T. Guerram, *Classification automatique des textes par Les réseaux de neurones à convolution*, 2019.

- [10] *Pooling*. [Online]. Available : https://www.google.com/search?q=Pooling+avec+un+filtre+cnn&rlz=1C1CHBD_arDZ1025DZ1025&sxsrf=APwXEdehThEY-dqXPthx2jrZyXV_8XBVgg:1684949217771&source=lnms&tbm=isch&sa=X&ved=2ahUKEwjO0Nv8vI7_AhWIV6QEHbbLD4UQ_AUoAXoECAEQAw#imgrc=E-ZVj-jAD7CgGM
- [11] N. Sharma, V. Jain, and A. Mishra, “An analysis of convolutional neural networks for image classification,” *Procedia computer science*, vol. 132, pp. 377–384, 2018.
- [12] W. Moskolai, W. Abdou, A. Dipanda, and D. T. Kolyang, “Application of lstm architectures for next frame forecasting in sentinel-1 images time series,” *arXiv preprint arXiv :2009.00841*, 2020.
- [13] H. Sak, A. W. Senior, and F. Beaufays, “Long short-term memory recurrent neural network architectures for large scale acoustic modeling,” 2014.
- [14] [Online]. Available : <https://www.analyticsvidhya.com/blog/2017/12/fundamentals-of-deep-learning-introduction-to-lstm/>
- [15] *TensorFlow Logo*. [Online]. Available : <https://www.tensorflow.org/?hl=ar>
- [16] *About Pandas*. [Online]. Available : <https://pandas.pydata.org/>
- [17] *Simple. Flexible. Powerful*. [Online]. Available : <https://keras.io/>
- [18] *What is NumPy?* [Online]. Available : <https://numpy.org/doc/stable/user/whatisnumpy.html>
- [19] *statistical data visualization*. [Online]. Available : <https://seaborn.pydata.org/>
- [20] K. Abhishek, M. Singh, S. Ghosh, and A. Anand, “Weather forecasting model using artificial neural network,” *Procedia Technology*, vol. 4, pp. 311–318, 2012.
- [21] A. Iseh and T. Woma, “Weather forecasting models, methods and applications,” *Int. J. Eng. Res. Technol*, vol. 2, pp. 1945–1956, 2013.
- [22] M. Holmstrom, D. Liu, and C. Vo, “Machine learning applied to weather forecasting,” *Meteorol. Appl*, vol. 10, pp. 1–5, 2016.
- [23] S. S. Baboo and I. K. Shereef, “An efficient weather forecasting system using artificial neural network,” *International journal of environmental science and development*, vol. 1, no. 4, p. 321, 2010.
- [24] *ML / Types of Learning – Part 2*. [Online]. Available : [https://www.geeksforgeeks.org/ml-types-learning-part-2/?ref=lbp\(unsupervised\)](https://www.geeksforgeeks.org/ml-types-learning-part-2/?ref=lbp(unsupervised))

- [25] S. Dewitte, J. P. Cornelis, R. Müller, and A. Munteanu, “Artificial intelligence revolutionises weather forecast, climate monitoring and decadal prediction,” *Remote Sensing*, vol. 13, no. 16, p. 3209, 2021.
- [26] T. Sakaguchi and K. Matsumoto, “Development of a knowledge based system for power system restoration,” *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-102, no. 2, pp. 320–329, 1983.
- [27] H.-C. Huang, “Designing a knowledge-based system for strategic planning : A balanced scorecard perspective,” *Expert systems with applications*, vol. 36, no. 1, pp. 209–218, 2009.
- [28] C. F. Tan, L. Wahidin, S. Khalil, N. Tamaldin, J. Hu, and G. Rauterberg, “The application of expert system : A review of research and applications,” *ARPJ Journal of Engineering and Applied Sciences*, vol. 11, no. 4, pp. 2448–2453, 2016.
- [29] B. Mahesh, “Machine learning algorithms -a review,” 01 2019.
- [30] S. Uddin, A. Khan, M. E. Hossain, and M. A. Moni, “Comparing different supervised machine learning algorithms for disease prediction,” *BMC medical informatics and decision making*, vol. 19, no. 1, pp. 1–16, 2019.
- [31] I. Reis, D. Baron, and S. Shahaf, “Probabilistic random forest : A machine learning algorithm for noisy data sets,” *The Astronomical Journal*, vol. 157, no. 1, p. 16, 2018.
- [32] *Clustering in Machine Learning*. [Online]. Available : <https://www.geeksforgeeks.org/clustering-in-machine-learning/>
- [33] Classification algorithm in machine learning. [Online]. Available : <https://www.javatpoint.com/classification-algorithm-in-machine-learning>
- [34] M. Bhawsar, V. Tewari, and P. Khare, “A survey of weather forecasting based on machine learning and deep learning techniques,” *International Journal of Emerging Trends in Engineering Research*, vol. 9, no. 7, 2021.
- [35] L. Alzubaidi, J. Zhang, A. J. Humaidi, A. Al-Dujaili, Y. Duan, O. Al-Shamma, J. Santamaría, M. A. Fadhel, M. Al-Amidie, and L. Farhan, “Review of deep learning : Concepts, cnn architectures, challenges, applications, future directions,” *Journal of big Data*, vol. 8, pp. 1–74, 2021.
- [36] A. Ajit, K. Acharya, and A. Samanta, “A review of convolutional neural networks,” in *2020 international conference on emerging trends in information technology and engineering (ic-ETITE)*. IEEE, 2020, pp. 1–5.

- [37] L. Deng, “A tutorial survey of architectures, algorithms, and applications for deep learning,” *APSIPA transactions on Signal and Information Processing*, vol. 3, p. e2, 2014.
- [38] L. Torrey and J. Shavlik, “Transfer learning,” in *Handbook of research on machine learning applications and trends : algorithms, methods, and techniques*. IGI global, 2010, pp. 242–264.
- [39] *transfer learning*. [Online]. Available : <https://www.seldon.io/transfer-learning>
- [40] R. Miotto, F. Wang, S. Wang, X. Jiang, and J. T. Dudley, “Deep learning for healthcare : review, opportunities and challenges,” *Briefings in Bioinformatics*, vol. 19, no. 6, pp. 1236–1246, 05 2017.
- [41] W. Zaremba, I. Sutskever, and O. Vinyals, “Recurrent neural network regularization,” *arXiv preprint arXiv :1409.2329*, 2014.
- [42] J. A. Weyn, D. R. Durran, R. Caruana, and N. Cresswell-Clay, “Sub-seasonal forecasting with a large ensemble of deep-learning weather prediction models,” *Journal of Advances in Modeling Earth Systems*, vol. 13, no. 7, p. e2021MS002502, 2021.
- [43] A. G. Salman, Y. Heryadi, E. Abdurahman, and W. Suparta, “Single layer & multi-layer long short-term memory (lstm) model with intermediate variables for weather forecasting,” *Procedia Computer Science*, vol. 135, pp. 89–98, 2018.
- [44] T.-c. Fu, “A review on time series data mining,” *Engineering Applications of Artificial Intelligence*, vol. 24, no. 1, pp. 164–181, 2011.
- [45] Z. C. Lipton, J. Berkowitz, and C. Elkan, “A critical review of recurrent neural networks for sequence learning,” *arXiv preprint arXiv :1506.00019*, 2015.
- [46] L. R. Medsker and L. Jain, “Recurrent neural networks,” *Design and Applications*, vol. 5, pp. 64–67, 2001.
- [47] G. Van Houdt, C. Mosquera, and G. Nápoles, “A review on the long short-term memory model,” *Artificial Intelligence Review*, vol. 53, pp. 5929–5955, 2020.
- [48] A. Graves and A. Graves, “Long short-term memory,” *Supervised sequence labelling with recurrent neural networks*, pp. 37–45, 2012.
- [49] *Weather Dataset*. [Online]. Available : <https://www.kaggle.com/datasets/muthuj7/weather-dataset?resource=download>
- [50] *What Is Python Used For? A Beginner’s Guide*. [Online]. Available : <https://www.coursera.org/articles/what-is-python-used-for-a-beginners-guide-to-using-python>
- [51] *Python Logo*. [Online]. Available : <https://www.python.org/>

- [52] *Frequently Asked Questions*. [Online]. Available : <https://research.google.com/colaboratory/faq.html>
- [53] DataScientest, “Erreur quadratique moyenne,” Website, n.d. [Online]. Available : <https://datascientest.com/erreur-quadratique-moyenne>
- [54] Complex Systems AI, “Métriques pour la classification,” Website, n.d. [Online]. Available : <https://complex-systems-ai.com/analyse-des-donnees/metriques-pour-la-classification/>