

République Algérienne Démocratique Et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université Mouloud Mammeri, Tizi-Ouzou



Faculté de Génie Electrique et de l'Informatique
Département D'Electronique

Thèse de doctorat LMD

Spécialité : **Electronique**

Présentée par

HAMDAD Sadjia

**Sujet : Apport de l'estimation des précipitations par satellite à
l'analyse et la prévision de la sécheresse dans le Nord de l'Algérie.**

Devant le jury d'examen composé de :

M. OUALLOUCHE Fethi	M.C.A à l'UMMTO	Président
M. LAZRI Mourad	Professeur à l'UMMTO	Rapporteur
M. LABADI Karim	Professeur à l'ECAM-EPMI, Cergy Pontoise	Co-Rapporteur
M. BELHOCINE Mahmoud	Directeur de la recherche au CDTA	Examineur
M. ALOUACHE Djamel	M.C.A à l'UMMTO	Examineur
M. AMEUR Soltane	Professeur à l'UMMTO	Invité

Remerciements

Grâce à Dieu, ce travail de thèse est à terme.

Ma reconnaissance très chaleureuse va tout d'abord à Monsieur le Professeur Mourad LAZRI, mon directeur de thèse, avec qui j'avais le plaisir de travailler tout au long de cette thèse. Ses connaissances et son appétence pour le domaine, sa patience et sa disponibilité m'ont été précieuse dans la réalisation du présent travail.

Mes vifs remerciements à mon co-directeur de thèse, Monsieur Karim LABADI, Professeur à l'ECAM-EPMI, Cergy Pontoise, pour m'avoir accueillie dans son laboratoire et pour son écoute et ses conseils éclairés tout au long de la préparation de ma thèse.

Je tiens aussi à remercier chaleureusement les membres de jury :

Je souhaite exprimer ma gratitude toute particulière à Monsieur Fethi OUALLOUCHE, Maître de conférences à l'Université de Mouloud Mammeri de Tizi-Ouzou, d'avoir accepté de présider mon jury.

Je tiens à remercier particulièrement Monsieur Mahmoud BELHOCINE, directeur de la recherche au Centre de Développement des Technologies Avancées d'Alger, d'avoir accepté de faire partie de mon jury.

J'adresse mes sincères remerciements à Monsieur Djamel ALOUACHE, Maître de conférences à l'Université de Mouloud Mammeri de Tizi-Ouzou, pour avoir accepté de participer au jury.

Je tiens à remercier Monsieur le Professeur Soltane AMEUR, directeur du Laboratoire d'Analyse et de Modélisation des Phénomènes Aléatoires pour m'avoir accueillie dans son laboratoire. Je lui suis également reconnaissante pour le temps conséquent qu'il m'a accordée, ses qualités pédagogiques et scientifiques, et qui m'a fait l'honneur de participer à mon jury.

A tous mes collègues Enseignants/Chercheurs de l'UMMTO et ECAM-EPMI en particulier à Messieurs Noureddine BENSAFI, Rafik ABSI et Samir HAMACI, je vous exprime mes remerciements pour vos encouragements.

Mes plus chaleureux remerciements vont à ma très chère famille et mes amis. Aussi, un merci à toi qui a pris la peine de lire ces quelques lignes et peut être la suite de ce manuscrit.

Sommaire

Introduction	1
Chapitre 1 Pluviométrie et climat méditerranéen	5
1.1. Préambule	5
1.2. Pluviométrie.....	6
1.2.1. Précipitations	6
1.2.2. Principaux systèmes précipitants	7
1.2.3. Instruments de la pluviométrie.....	9
1.2.4. Impacts de la variabilité de la pluviométrie.....	18
1.3. Climat méditerranéen	20
1.3.1. Caractéristiques du climat méditerranéen.....	20
1.3.2. Facteurs influençant la pluviométrie méditerranéenne.....	21
1.4. Discussion.....	24
Chapitre 2 Contexte scientifique de la sécheresse	25
2.1. Préambule	25
2.2. Description de la sécheresse	25
2.3. Caractérisation de la sécheresse	26
2.4. Types de sécheresse.....	27
2.4.1. Sécheresse météorologique.....	28

2.4.2.	Sécheresse agricole	28
2.4.3.	Sécheresse hydrologique.....	28
2.5.	Causes de la sécheresse	29
2.5.1.	Causes météorologiques	29
2.5.2.	Causes humaines.....	29
2.6.	Indices de sécheresse	30
2.6.1.	Indice Standardisé des Précipitations (SPI).....	30
2.6.2.	Indice Standardisé d'Evapotranspiration et de Précipitation (SPEI).....	38
2.6.3.	Pourcentage à la Normale (PN)	39
2.6.4.	Déciles des Précipitations (DP)	40
2.6.5.	China Z Index (CZI)	41
2.6.6.	Indice de Sécheresse de Keetch-Byram (KBDI)	42
2.6.7.	Indice d'Aridité Annuelle de De Martonne	44
2.6.8.	Indice de Sévérité des Sécheresses de Palmer (PDSI).....	45
2.6.9.	Indice de Sécheresse Effectif (EDI).....	48
2.6.10.	Indice de Végétation par Différence Normalisée (NDVI).....	48
2.6.11.	Indice de Condition de la Végétation (VCI).....	50
2.7.	Comparaison des indices de sécheresse.....	52
2.8.	Sécheresse dans le monde.....	53
2.9.	Sécheresse en Algérie	54

2.10.	Impacts de la sécheresse	55
2.10.1.	Impacts environnementaux	55
2.10.2.	Impacts économiques.....	56
2.10.3.	Impacts sociaux.....	56
2.11.	Discussion.....	57
Chapitre 3 Apprentissage automatique et méthodes d'analyse de la sécheresse.....		58
3.1.	Préambule	58
3.2.	Intelligence Artificielle (IA).....	59
3.2.1.	Apprentissage Automatique (Machine Learning – ML).....	60
3.2.2.	Apprentissage profond (Deep Learning – DL).....	66
3.3.	Prévision de la sécheresse.....	67
3.3.1.	Méthodes de prévisions utilisant SPI.....	67
3.3.2.	Méthodes de prévisions utilisant KBDI.....	70
3.3.3.	Méthodes de prévisions utilisant PDI.....	70
3.3.4.	Méthodes de prévisions utilisant SPEI	71
3.3.5.	Méthodes de prévisions utilisant EDI	72
3.3.6.	Méthodes de prévisions utilisant NDVI.....	74
3.3.7.	Méthodes de prévisions utilisant VCI.....	74
3.3.8.	Méthodes de prévisions utilisant des indices combinés.....	75
3.4.	Discussion.....	77

Chapitre 4 Analyse de la sécheresse en utilisant CM et RNA	79
4.1. Préambule	79
4.2. Matériels et méthodes	79
4.2.1. Caractérisation du phénomène sec/humide.....	80
4.2.2. Données utilisées	81
4.2.3. Concepts mathématique des chaînes de Markov et de RNA	84
4.2.4. Apprentissage de RNA et calcul des chaînes de Markov	88
4.3. Résultats.....	92
4.3.1. Prédiction et validation à court terme	92
4.3.2. Prédiction à long terme	97
4.4. Discussion.....	105
Conclusion	106
Références bibliographiques.....	108
Annexes.....	119

Acronymes et abréviations

ANN : Artificial Neural Network.

ARMA : Auto Regressive and Moving Average.

CM : Chaîne de Markov.

CMIP6 : Coupled Multi-model Inter-comparison Project version 6.

CZI : China Z Index.

DP : Déciles de Précipitations.

EDI: Effective Drought Index.

EUMETSAT: European Organization for the exploitation of Meteorological
SATellites.

IA : Intelligence Artificielle.

IR : InfraRed.

KBDI: Keetch Byram Drought Index.

MFG: Meteosat First Generation.

ML: Machine Learning.

MLP: Multi-Layer Perceptron.

MSG: Meteosat Second Generation.

MVIRI: METEOSAT Visible and Infrared Imager.

NDVI: Normalized Difference Vegetation Index.

OMM : Organisation Météorologique Mondiale.

PDI : Palmer Drought Index.

PDSI: Palmer Drought Severity Index.

PN : Pourcentage à la Normale.

RADAR: Radio Detection and Ranging.

RF : Random Forest.

RNA : Réseau Neuronal Artificiel.

SEVIRI: Spinning Enhanced Visible and Infrared Imager.

SPI: Standardized Precipitation Index.

SSP: Scenario Socio-economic Pathways.

SVM : Support Vector Machine.

VCI : Vegetation Condition Index.

VIS : Viewable Image Size.

WV : Water Vapor.

Liste des figures

Figure 1.1. Formation des précipitations [OIEau 2017].	7
Figure 1.2. Types de précipitations.	8
Figure 1.3. Instruments de mesure au sol ; a : pluviomètre ; b : pluviographe à augets basculeurs.	10
Figure 1.4. Radar météorologique.	12
Figure 1.5. Satellites météorologiques à défilement (NOAA, METEOR) et géostationnaires.	13
Figure 1.6. Satellite MSG.	15
Figure 1.7. Région Méditerranéenne.	21
Figure 1.8. Courants en mer Méditerranée.	23
Figure 2.1. Différents types de sécheresse.	27
Figure 2.2. Distribution normale standard avec le SPI ayant une moyenne de zéro et une variance de 1.	35
Figure 2.3. Causes et conséquences des sécheresses. [WMO 2006].	56
Figure 3.1. Illustration de la position de l'Apprentissage Profond et l'Apprentissage Automatique par rapport à l'Intelligence Artificielle.	59
Figure 3.2. Apprentissage Automatique du modèle et son application.	60
Figure 3.3. Processus d'un Apprentissage Automatique supervisé.	61
Figure 3.4. Classification par SVM.	63
Figure 3.5. Schéma d'un arbre de décision.	63

Figure 3.6. Schéma d'une forêt aléatoire.....	64
Figure 3.7. Principe de classification par K-NN.....	65
Figure 3.8. Processus d'un Apprentissage non-supervisé.	65
Figure 4.1. Région d'étude (Nord de l'Algérie).	82
Figure 4.2. Evolution des répartitions des taux de précipitations dans le nord de l'Algérie de 1985 à 2019.....	83
Figure 4.3. Evolution du phénomène sec/humide en fonction du SPI pour un pixel pris dans chaque sous-région.	83
Figure 4.4. Structure interne d'un nœud sommateur (neurone artificiel) ; la somme pondérée des entrées du nœud est calculée, une fonction de transfert non linéaire est appliquée à cette somme. La sortie est ensuite transmise aux autres nœuds (neurones).	86
Figure 4.5. Le réseau neuronal structuré en couches est communément appelé MLP.	86
Figure 4.6. Architecture MLP pour l'apprentissage.....	91
Figure 4.7. Modèle MLP appliqué pour la prédiction à l'instant t.	92
Figure 4.8. Distribution des phénomènes secs/humides pour les deux années 2020 et 2021, (gauche) prédite par MLP, (centre) distribution réelle, (droite) prédite par chaîne de Markov.....	93
Figure 4.9. Niveau de prédiction fausse/correcte des deux méthodes pour les différentes classes.	94
Figure 4.10. Prédications par CM données sous forme de probabilité d'occupation dans la zone d'étude de 2022 à 2050.....	98
Figure 4.11. Variation de la probabilité de distribution de chaque état en fonction de la surface occupée.....	101

Figure 4.12. Résultats de la prédiction obtenus par application des deux méthodes pour les années 2047, 2048, 2049 et 2050..... 102

Figure 4.13. Résultats de précision de prédiction de RNA et CM par rapport aux prévisions de CMIP6 pour les différentes classes..... 104

Liste des tableaux

Tableau 1.1. Canaux de MSG.....	17
Tableau 2.1. Classification de la sécheresse selon SPI.	35
Tableau 2.2. Classification de PN.	39
Tableau 2.3. Classification des déciles de précipitations.	41
Tableau 2.4. Classification KBDI.	43
Tableau 2.5. Classifications des climats selon l'indice De Martonne.....	45
Tableau 2.6. Classification des conditions météorologiques selon PDSI.	46
Tableau 2.7. Classification des degrés du VCI selon Kogan, 2003.	51
Tableau 2.8. Indices de sécheresse.	51
Tableau 4.1. Catégorisation du degré du phénomène sec/humide en fonction des indices standardisés de précipitations.	81
Tableau 4.2. Périodes d'apprentissage ou de calcul de matrices de transitions, de prédiction et de validation.....	88
Tableau 4.3. Matrices de transition de probabilité pour la sous-région1, sous-région 2 et la sous-région 3 respectivement.	90
Tableau 4.4. Aperçu des combinaisons dans un tableau de contingence.	95
Tableau 4.5. Valeurs des paramètres d'évaluation pour les deux méthodes.	96
Tableau 4.6. Surfaces occupées en Km ² par chacun des Etats de 2022 à 2050 prédites par les chaînes de Markov.	99
Tableau 4.7. Surfaces occupées en Km ² par chacun des états de 2022 à 2050 prédites par le MLP.	100

Introduction

La communauté scientifique s'inquiète de plus en plus de la situation climatique mondiale. En effet, partout dans le monde, des phénomènes extrêmes et violents générant des pluies intenses affectent certaines régions, tandis que d'autres régions subissent les conséquences de la sécheresse due au manque de précipitations. La sécheresse est un phénomène écologique dévastateur et le risque d'affecter de plus en plus de régions du monde augmente. Les effets de la sécheresse entraînent des conséquences économiques et environnementales dangereuses, en particulier dans les régions où la demande en eau est élevée et où l'activité agricole est importante. La sécheresse correspond à des situations où les précipitations inférieures à la normale et à la persistance de périodes sèches, mais d'autres indices peuvent également être utilisés pour catégoriser la sécheresse [Mishra et Singh 2010].

Afin de mieux gérer cette situation, l'analyse des séries temporelles et la prévision du comportement de la sécheresse sont d'une grande utilité pour la communauté scientifique. L'alerte précoce et la connaissance de l'évolution de la sécheresse peuvent contribuer à atténuer les conséquences catastrophiques. A cet effet, plusieurs travaux de recherches ont été réalisés pour l'analyse de la sécheresse [e.g. Khan et al. 2020 ; Lazri et al. 2015]. Un grand nombre d'indices de sécheresse, tels que le NDVI (Normalized Difference Vegetation Index), le PDSI (Palmer Drought Severity Index), le VCI (Vegetation Condition Index) et le SPI (Standardized Precipitation Index), ont été utilisés pour caractériser le degré et l'intensité de la sécheresse [Bayissa 2018 ; Lazri et al. 2015 ; Liu et al. 2019 ; Mishra et Singh 2010]. Des travaux basés sur des études statistiques ont été menés pour évaluer la sécheresse en analysant l'occurrence ou la non-occurrence des précipitations [e.g. Hao et al. 2016 ; Mehrotra et Sharma 2005 ; Mehrotra et al. 2006 ; Lazri et al. 2007 ; Yoo et al. 2012]. Il existe des méthodes basées sur l'ARMA (Auto Regressive and Moving Average) [Liu et al. 2019], sur le modèle méta-gaussien [Hao et al. 2016] ou sur les chaînes de Markov [Lazri et al. 2015], ou encore sur l'approche bayésienne [AghaKouchak et Nakhjiri 2012]. D'autres méthodes utilisent l'apprentissage automatique pour l'analyse et la prédiction de la sécheresse, comme la machine à vecteur de support (Support Vector Machine – SVM), le réseau neuronal artificiel (Artificial Neural Network – ANN), la forêt aléatoire (Random Forest – RF), etc. Le lecteur peut aussi consulter les travaux réalisés par Kaur et Sood (2020), Altunkaynak et Jalilzadnezamabad (2021) et Belayneh et al (2014).

Les objectifs de l'étude de la sécheresse dépendent de l'échelle de temps utilisée [Vidal et al. 2010]. Par exemple, dans le cas où les précipitations annuelles sont concentrées sur une courte période, le ruissellement et les inondations seront significatifs et notables et les barrages se rempliront correctement. Il n'y aura donc pas de sécheresse d'un point de vue hydrologique. Cependant, il est probable qu'au niveau agronomique, les cultures pluviales auront souffert soit d'un manque d'eau pendant les périodes sans précipitations, ce qui peut être considéré comme une sécheresse agricole, soit d'un excès d'eau temporaire pendant les précipitations. En revanche, si les pluies sont bien réparties dans le temps, tombant à des moments favorables du cycle végétatif des cultures, même avec des quantités moindres, la sécheresse agricole n'est pas observée et la récolte sera normale, voire bonne. Cependant, le faible ruissellement observé, un volume d'écoulement annuel médiocre et des barrages à moitié vides peuvent indiquer une sécheresse hydrologique. Plusieurs recherches menées pour la prévision et l'analyse de la sécheresse à l'échelle saisonnière, mensuelle ou journalière ont mis en évidence la sécheresse agricole [e.g. Belayneh et al. 2014 ; AghaKouchak 2015 ; Liu et al. 2019 ; Tian et al. 2018]. En fait, l'étude de la variabilité mensuelle ou saisonnière de la sécheresse n'est pas d'un grand intérêt pour les besoins hydrologiques. L'étude de la sécheresse à l'échelle annuelle s'avère bénéfique et utile, et peut indiquer des déficits de ressources en eau pour les besoins hydrologiques.

Néanmoins, certains problèmes peuvent être posés ; il s'agit de la disponibilité des données spatio-temporelles, en particulier pour la mise en œuvre des méthodes basées sur l'apprentissage automatique [Bazrkar et Chu 2021]. Les observations par satellite peuvent apporter des solutions en fournissant des informations à haute résolution spatio-temporelle [AghaKouchak et Nakhjiri 2012 ; Adler et al. 2003]. Par conséquent, l'utilisation de la télédétection à partir de l'imagerie satellitaire peut améliorer l'analyse, la prédiction et la classification des zones terrestres humides et sèches avec une couverture spatiale plus importante [Khan et al. 2020].

Dans ce contexte, afin d'aider l'hydrologue dans la planification de la gestion des ressources en eau, le travail réalisé dans cette thèse permet d'analyser et de prévoir le phénomène sec/humide dans le Nord de l'Algérie en exploitant les informations satellitaires. Le Nord de l'Algérie est une région des latitudes moyennes. Son climat est méditerranéen avec quatre saisons ; ses étés sont chauds et secs, et les hivers sont humides et frais. Ces dernières années, cette région a été touchée par le fléau de la sécheresse et, en raison de sa

situation géographique, elle est susceptible d'être affectée de manière significative. Les ressources en eau exploitées dans cette région proviennent principalement des précipitations enregistrées annuellement. Pour répondre aux problématiques soulevées ci-dessus et en fonction de la région d'étude, l'analyse spatio-temporelle et la prévision de la sécheresse sont réalisées à l'échelle annuelle. Pour mieux gérer les déficits hydriques et mieux établir les solutions correspondantes, nous avons également intégré les situations humides dans l'analyse et la prévision, puisque l'information sur le niveau d'humidité est également essentielle. Pour cette raison, le phénomène sec/humide, qui comprend à la fois des situations humides et sèches, est étudié pour une vision plus globale de la sécheresse. Les informations sur le comportement du phénomène sec/humide permettent de caractériser la sécheresse. Pour l'étude donc de ce phénomène, nous l'avons divisé en plusieurs classes en fonction des valeurs du SPI [McKee et al. 1993, 1995]. Pour calculer les valeurs de SPI, les taux de précipitations sont utilisés indiquant les intensités des situations sèches ou humides [e.g. Moreira et al. 2006, 2008 ; Cancelliere et al. 2007].

Le phénomène sec/humide peut être traité comme un événement stochastique en raison de son caractère aléatoire. Afin d'étayer nos résultats et pour une étude comparative, deux techniques sont donc sélectionnées pour analyser le processus. La première méthode emploie les chaînes de Markov qui est basée sur les principes de la théorie des chaînes de Markov, un concept de la théorie des probabilités et des processus stochastiques. Quant à la deuxième méthode, elle utilise les réseaux de neurones ; qui sont basés sur l'apprentissage automatique.

Les chaînes de Markov sont l'un des plus anciens algorithmes d'analyse des processus aléatoires et sont toujours utilisées car elles sont adaptées aux événements stochastiques [e.g. Mokarram et al. 2021]. Les réseaux neuronaux artificiels, en particulier le perceptron multicouche (Multi Layer Perceptron – MLP) qui utilise l'apprentissage automatique, ont d'abord été introduits pour résoudre des problèmes de classification complexes. Mais en raison de leur propriété d'approximation universelle, ils ont rapidement été utilisés comme modèles de régression non linéaire, puis pour la modélisation et la prédiction de séries temporelles. Actuellement, l'apprentissage automatique est largement utilisé pour l'analyse des données. Il permet de développer, de tester et d'appliquer des algorithmes d'analyse prédictive sur différents types de données afin de prédire leur comportement à court, à moyen ou à long terme.

La méthodologie présentée dans cette thèse consiste donc à étudier le phénomène sec/humide à l'échelle annuelle dans la région du Nord de l'Algérie. Les données utilisées sont des estimations satellitaires. Sur une période allant de 1986 à 2019, nous avons entraîné le modèle MLP et calculé les matrices de transition pour les chaînes de Markov. Ensuite, les performances à court terme des deux modèles sont évaluées pour la période 2020 à 2021. Des prédictions à long terme sont aussi déterminées pour la période de 2022 à 2050.

Pour bien structurer notre thèse, nous avons scindé le travail en quatre chapitres :

Le premier chapitre contient une vue d'ensemble de la pluviométrie ainsi qu'une description des instruments de mesure des précipitations. Le climat méditerranéen avec sa variabilité spatio-temporelle fait aussi l'objet de ce chapitre.

Dans le deuxième chapitre, nous décrivons le phénomène de sécheresse ainsi que son impact dans le monde. Des indices utilisés pour indiquer l'intensité de ce phénomène, leurs calculs, leurs avantages et leurs inconvénients sont aussi présentés.

Dans le troisième chapitre, nous passons en revue une liste de travaux réalisés de par le monde pour l'analyse de la sécheresse. Ces travaux basés sur des modèles empiriques et statistiques ou sur des modèles d'apprentissage automatique emploient un ensemble d'indices pour caractériser la sécheresse.

Dans le dernier chapitre, nous présentons notre étude du phénomène sec/humide réalisée dans la région du Nord de l'Algérie en utilisant le MLP et les chaînes de Markov. Les résultats de prédictions et leurs interprétations seront aussi donnés dans ce chapitre.

Nous terminons notre travail par une conclusion et quelques perspectives de ce travail.

Chapitre 1 Pluviométrie et climat méditerranéen

1.1. Préambule

La région méditerranéenne est le théâtre de nombreux événements météorologiques extrêmes : vents forts, sécheresses, pluies intenses. Ces phénomènes sont parfois responsables de lourds dégâts matériels mais aussi de pertes humaines. Un changement soudain dans un ou plusieurs paramètres atmosphériques tels que la température, les précipitations, l'humidité, etc ; aura un impact direct sur la routine quotidienne des êtres vivants. Une augmentation de la température pendant une longue durée va favoriser les pertes d'eau par évapotranspiration et si ce phénomène dure plus longtemps il va provoquer la sécheresse. Aussi, des précipitations intenses et inhabituelles survenant dans une région sur une courte période peuvent entraîner des inondations.

Le climat méditerranéen est largement connu et suscite un grand intérêt en raison de sa renommée et de son caractère captivant parmi les différents types de climats présents sur notre planète [Lionello et al. 2006]. Il tire son nom de la région méditerranéenne, où il prédomine, mais il est également présent dans d'autres parties du monde, comme la Californie, le Chili central et certaines régions de l'Australie et de l'Afrique du Sud. Ce climat se caractérise par des étés chauds et secs et des hivers doux et humides. La pluviométrie est un facteur clé de ce climat, car les précipitations sont souvent limitées à une période de l'année et peuvent varier considérablement d'une année à une autre.

En Algérie, les ressources en eau exploitées viennent essentiellement des précipitations. Cependant, la rareté croissante et l'utilisation inefficace des réserves d'eau douce menacent notre avenir. Autrefois considérée comme un don inépuisable et gratuit du ciel, l'eau est confrontée à de nouveaux défis. La variation saisonnière des précipitations en méditerranée, caractérisée par des périodes de fortes pluies et de longues sécheresses, a un impact majeur sur les écosystèmes, l'agriculture, la gestion des ressources en eau et bien d'autres aspects de la vie dans ces régions.

Dans ce chapitre, nous décrivons la pluviométrie et ses spécificités dans la région méditerranéenne. En effet, nous définissons dans un premier temps la pluviométrie ainsi que les principaux systèmes précipitants qui surviennent dans cette région, et nous présentons

les instruments utilisés pour la mesure et l'observation des précipitations. Puis, dans un second temps, nous décrivons le climat méditerranéen.

1.2. Pluviométrie

La pluviométrie est la mesure quantitative des précipitations, généralement exprimée en millimètres d'eau tombée sur une surface donnée pendant une période spécifique. C'est une mesure importante pour comprendre les variations des précipitations sur une région donnée au fil du temps, ce qui est essentiel pour la gestion de l'eau, l'agriculture, la météorologie et d'autres domaines liés à l'environnement.

1.2.1. Précipitations

Les précipitations représentent le facteur le plus important du climat ; elles constituent la principale entrée des systèmes hydrologiques continentaux qui sont les bassins versants. Ce sont toutes les formes d'eau qui tombent du ciel sur la surface de la Terre tels que bruine, pluie, neige, etc.

Le processus de formation des précipitations illustré dans la **Figure 1.1** , consiste en deux phases qui sont :

- **L'évaporation** : le processus par lequel l'eau présente dans diverses sources telles que le sol, les océans, les lacs, les fleuves et les rivières, etc ; se transforme en vapeur d'eau sous l'effet du rayonnement solaire. La vapeur d'eau peut-être due à un réchauffement des cours d'eau ou une transpiration des plantes (évapotranspiration). Cette vapeur s'élève vers la première couche de l'atmosphère appelée troposphère, sous forme de gouttelettes d'eau. En effet, l'air chaud, plus léger que l'air froid, monte en altitude. En montant en altitude il se refroidit. Les gouttelettes d'eau se rassemblent pour former des nuages, comprenant des gouttes d'eau ou des cristaux de glace.
- **La condensation** : lorsque ces nuages rencontrent une couche d'air plus froide, les gouttelettes se condensent sous l'effet de refroidissement et forment alors des gouttes plus grosses, donc plus lourdes, leurs poids ne leur permettent plus de flotter, elles chutent vers la surface de la Terre, sous différentes formes appelées hydrométéores.




Figure 1.1. Formation des précipitations [OIEau 2017].

Le suivi des précipitations est évalué en termes de hauteur d'eau tombée au sol par unité de surface, mesurée en millimètres de précipitation par mètre carré. En supposant que les précipitations sont uniformément réparties sur la surface, chaque millimètre de pluie correspond à un litre d'eau par mètre carré.

Sur le plan de la prévention des inondations et des sécheresses, le suivi des précipitations joue un rôle vital. À long terme, la collecte de données permet une meilleure compréhension des phénomènes météorologiques et renforce les capacités de prédiction des précipitations. Cette accumulation d'informations est fondamentale pour améliorer la gestion des risques liés à l'eau et pour anticiper les événements météorologiques extrêmes.

1.2.2. Principaux systèmes précipitants

Les systèmes précipitants résultent de l'ascendance d'une masse d'air chaud et humide. On peut distinguer trois types de mécanismes qui déclenchent ces mouvements verticaux, comme représenté dans la **Figure 1.2**.

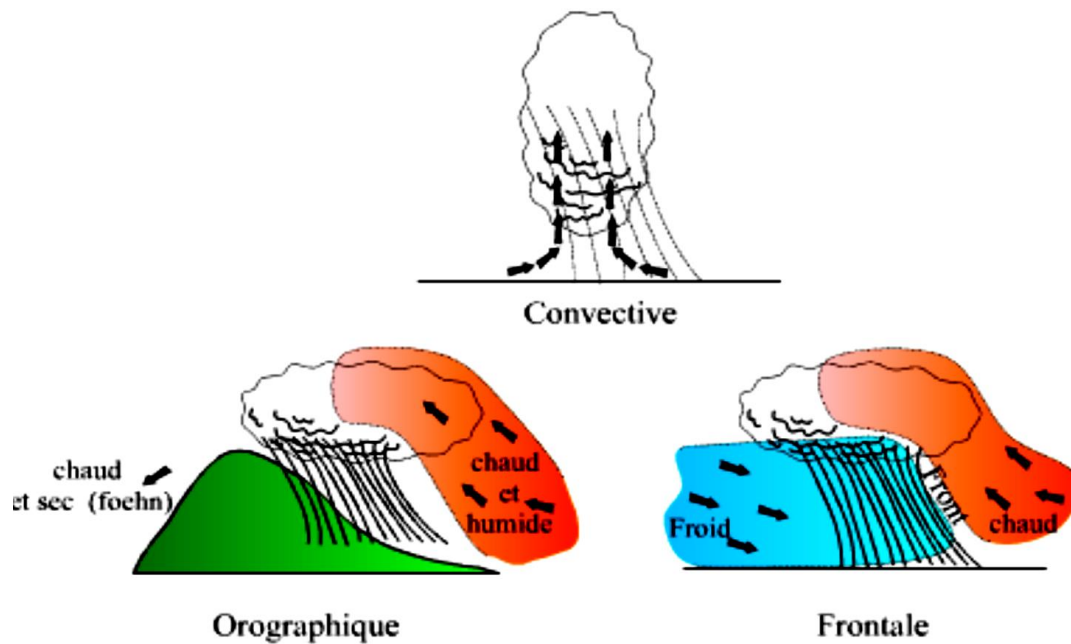


Figure 1.2. Types de précipitations.

1.2.2.1. Systèmes précipitants convectifs

Les précipitations orageuses de courte durée mais de forte intensité sont provoquées par la convection thermique résultant d'une ascendance rapide de masses d'air réchauffées en contact avec le sol. Cette ascendance peut être initiée lorsque la température de l'air à proximité du sol est supérieure d'au moins 10 % à celle des couches atmosphériques directement supérieures. Les cumulus et cumulonimbus associés à ces précipitations sont localisés et leur caractère très localisé entraîne une grande variabilité spatiale. Dans les climats tempérés, ces précipitations surviennent principalement en été et sont responsables de dégâts locaux tels que les coulées de boue, les crues des torrents, les inondations sectorielles et la grêle.

1.2.2.2. Systèmes précipitants orographiques

Ces précipitations sont limitées à des zones très spécifiques en raison de la présence d'une barrière topographique. Lorsqu'une masse d'air en mouvement rencontre une zone montagneuse, elle est compressée et forcée à s'élever dans la zone au vent, tandis que la zone sous le vent subit une détente (effet de foehn). Cette ascendance orographique conduit à la condensation et à la formation de nuages et de précipitations. Ces nuages sont appelés nuages orographiques. L'angle de la pente de la montagne affecte la vitesse à laquelle les molécules

de vapeur d'eau s'élèvent, ce qui influe sur l'intensité des précipitations. En général, ces précipitations se caractérisent par des intensités et des fréquences relativement constantes.

1.2.2.3. Systèmes précipitants cycloniques ou frontaux

Les précipitations se forment à proximité des frontières où des masses d'air de températures, gradients thermiques verticaux, humidités et vitesses de déplacement différents se rencontrent. Ces frontières sont appelées fronts et sont souvent associées à des dépressions météorologiques. Les nuages et les précipitations se produisent généralement à l'avant des fronts chauds (où l'air chaud rencontre l'air froid) et à l'arrière des fronts froids (où l'air froid prend la place de l'air chaud). Les précipitations associées aux fronts chauds sont souvent plus longues et étendues, mais moins intenses, tandis que les précipitations associées aux fronts froids sont plus brèves, moins étendues mais plus intenses. Les précipitations liées aux fronts chauds peuvent couvrir une zone de 300 kilomètres, tandis que celles liées aux fronts froids dépassent rarement 100 à 200 kilomètres. Billaut et al (1956) ont observé que ces phénomènes météorologiques se produisent près des discontinuités météorologiques associées aux dépressions.

1.2.3. Instruments de la pluviométrie

Les météorologues ont à leur disposition deux types d'instruments pour mesurer les précipitations : d'une part, les instruments de mesure au sol, tels que les pluviomètres et les pluviographes à enregistrement mécanographique ou numérique, et d'autre part, les instruments de mesure à distance, comme les satellites météorologiques pour la télédétection passive et les radars météorologiques pour la télédétection active.

1.2.3.1. Instruments de mesure au sol

Les instruments de mesure au sol des précipitations sont des dispositifs spécialement conçus pour collecter et mesurer les précipitations qui tombent directement sur le sol. Ces instruments sont installés à des emplacements fixes pour surveiller en continu les conditions météorologiques.

Les principaux instruments de mesures des précipitations sont le pluviomètre et le pluviographe. En effet, le mode de lecture des mesures est direct pour les pluviomètres et automatique pour les pluviographes (**Figure 1.3**).



a

b

Figure 1.3. Instruments de mesure au sol ; a : pluviomètre ; b : pluviographe à augets basculeurs.

a. Pluviomètre

Un pluviomètre est un outil de mesure privilégié pour évaluer les quantités de précipitations qui tombent du ciel et atteignent le sol, et il est largement utilisé à cette fin. Il consiste en un récipient cylindrique qui mesure la hauteur des précipitations tombées sur une surface donnée. Il permet de déterminer la quantité totale de pluie tombée entre deux relevés enregistrés à des moments différents. Pour obtenir la quantité de « pluie journalière », la hauteur de pluie relevée à un moment donné est attribuée au jour précédent, si la station pluviométrique est difficile d'accès ou éloignée, un pluviomètre totalisateur est recommandé car il mesure la quantité de pluie cumulée sur une longue période. En cas de neige ou de grêle, ces précipitations doivent être fondues avant de mesurer la quantité d'eau recueillie, qui est ensuite mesurée à l'aide d'une éprouvette graduée.

b. Pluviographe

Un pluviographe est un instrument de mesure automatisé conçu pour enregistrer de manière automatique la quantité de précipitations. Contrairement au pluviomètre qui nécessite une intervention humaine pour la mesure, le pluviographe est équipé d'un enregistreur qui permet d'obtenir une mesure en continu de la pluviométrie.

Le pluviographe fonctionne généralement en combinant un pluviomètre a au moins un enregistreur. Le pluviomètre recueille les précipitations dans un réceptacle gradué, tandis que l'enregistreur enregistre les variations de la hauteur d'eau dans le réceptacle à des

intervalles réguliers (par exemple toutes les 15 minutes). Les données enregistrées peuvent ensuite être utilisées pour calculer la quantité de précipitations tombées pendant une période donnée.

Il existe différents types de pluviographes, qui se distinguent principalement par leur méthode de mesure et leur technologie d'enregistrement notamment les pluviographes à augets basculeurs qui consistent en un entonnoir qui collecte et canalise les précipitations dans un petit récipient en forme de balançoire. Après la chute d'une quantité prédéfinie de précipitations, le levier bascule, déversant l'eau collectée et retranscrit sur le pluviogramme ou en actionnant un commutateur qui est ensuite enregistré électroniquement ou transmis à une station de collecte à distance. Ainsi que les pluviographes à siphon ; les pluviographes optiques, et les pluviographes acoustiques, qui ont la même fonction que le pluviographe à auget basculeur, mais différent selon la technologie utilisée pour leur élaboration.

1.2.3.2. Instruments de mesure à distance

a. Radar météorologique

Le RADAR (Radio Detection and Ranging) signifie détection par ondes radio et mesure de distance. Il fonctionne en émettant des ondes électromagnétiques qui se propagent dans l'atmosphère à la vitesse de la lumière. Lorsque ces ondes rencontrent un objet, une partie d'entre elles est renvoyée et captée par l'antenne radar, créant ainsi un écho.

Durant la seconde guerre mondiale, le radar a fait son apparition en aéronautique. Les images radar révélaient des retours d'écho provenant de particules de précipitations telles que la pluie, la neige ou la grêle. À l'époque, ces échos étaient considérés comme des interférences indésirables dans l'aviation. Cependant, les météorologistes ont rapidement réalisé leur valeur en tant que source précieuse d'informations. C'est ainsi que le radar a commencé à être utilisé dans le domaine de la météorologie. Depuis la seconde guerre mondiale, les systèmes radar se sont considérablement améliorés et les radars météorologiques jouent désormais un rôle essentiel dans l'observation de l'atmosphère. Depuis les années 1950, les différents services de météorologie à travers le monde ont construit des radars météorologiques.

Un radar météorologique, sonde un volume de l'atmosphère qui est rempli d'une multitude des hydrométéores (pluie, neige, grêle, ...). En plus de détecter la localisation des

précipitations, le radar doit également estimer leur intensité, la vitesse à laquelle elles se déplacent, ainsi que leurs mouvements à l'intérieur des nuages à partir du signal de retour. Un exemple de radar météorologique est illustré dans la **Figure 1.4**.



Figure 1.4. Radar météorologique.

La mesure de rétrodiffusion radar est exprimée par l'équation radar. Cette équation décrit la relation entre la puissance reçue (P_r) de l'onde électromagnétique reçue (\vec{E}^r) et la puissance émise (P_e) pour une seule cible sous la forme de l'onde émise (\vec{E}^e) et peut s'écrire :

$$P_r = P_e \frac{G^2 \lambda^2 \sigma}{(4\pi)^3 R^4} \quad (1.1)$$

Avec

G : Gain de l'antenne reçue,

λ : Longueur d'onde,

R : Distance entre la cible et radar,

σ : Surface équivalente Radar, qui représente le rapport moyen entre l'énergie réémise par la cible dans la direction du radar et la densité d'énergie qu'elle reçoit. Elle est donnée par la formule (1.2) :

$$\sigma = 4\pi R^2 \frac{|\vec{E}^r|^2}{|\vec{E}^e|^2} = 4\pi |S|^2 \quad (1.2)$$

$|\vec{E}^e|^2$ et $|\vec{E}^r|^2$ représentent l'intensité de l'onde reçue et de l'onde émise

$|S|^2$ L'amplitude de diffusion complexe de l'objet

b. Satellites météorologiques

Les satellites météorologiques sont des satellites artificiels envoyés dans l'espace pour collecter des données utiles aux prévisions météorologiques. Peu de pays disposent d'un réseau satellitaire capable de couvrir l'ensemble du globe. De nos jours, il existe deux familles de satellites météo : les satellites géostationnaires et les satellites défilants (**Figure 1.5**).




Figure 1.5. Satellites météorologiques à défilement (NOAA, METEOR) et géostationnaires.

Les satellites météorologiques géostationnaires sont maintenus par EUMETSAT (Meteosat), les Etats-Unis (GOES), le Japon (Himawari), la Corée du Sud (GEO-KOMPSAT), la Chine (FY-2, FY-4), la Russie (Elektro-L) et l'Inde (INSAT). Ils sont mis en orbite autour de la Terre dans le plan de l'équateur, à une altitude de 35 800 km. Ils se déplacent à la même vitesse que la rotation de la Terre, ce qui leur permet de rester en permanence au-dessus du même point à la surface de la planète. Ces satellites capturent des

images à intervalles réguliers, ce qui permet de surveiller en continu différents paramètres tels que les formations nuageuses sur une vaste région de la Terre. Ces données sont utiles pour les prévisions météorologiques.

En revanche, les satellites météorologiques à orbite polaire (défilants) sont maintenus par EUMETSAT (Metop), les Etats-Unis (NOAA), la Russie (Meteor) et la Chine (Fengyun-3). Ils sont positionnés beaucoup plus bas, à une altitude de moins de 1000 km, et passent près des pôles terrestres. Ils accomplissent une orbite autour de la Terre en environ deux heures, en suivant une trajectoire perpendiculaire à l'axe entre la Terre et le Soleil. Cette configuration garantit qu'ils survolent chaque point de la surface terrestre à la même heure solaire. Ces satellites en orbite polaire fournissent des informations complémentaires à celles obtenues à partir des satellites géostationnaires.

Les États-Unis ont lancé le premier satellite météorologique, nommé Tiros 1, en 1960. Les images de l'atmosphère qu'il fournissait étaient peu utilisables. Mais, depuis cette date, la technique a beaucoup progressé.

D'autres satellites ont mis en orbite, beaucoup plus sophistiqués que les premières générations. La série des satellites à laquelle nous nous intéressons dans ce travail en raison de sa couverture de la région méditerranéenne, et aussi l'Europe et l'Afrique sont les satellites Météosat qui englobent jusqu'à présent trois générations. Dans les premières générations, placées en orbite entre 1977 et 1997, les satellites de première génération (Meteosat First Generation – MFG) permettent d'avoir une image des conditions météo mondiale toutes les demi-heures dans trois canaux spectraux Visible (VIS), Infrarouge (IR) et Vapeur d'eau (WV) grâce au capteur METEOSAT Visible and InfraRed Imager (MVIRI). Le MVIRI tourne avec une vitesse de rotation de 100 tours par minute autour de son axe principal.

➤ **Satellites METEOSAT Seconde Génération (MSG)**

Les satellites MSG, dont le premier a été lancé en août 2002, sont conçus pour considérablement améliorer les services fournis par la flotte initiale des satellites Météosat. Ils apportent une information plus complète, plus précise et plus fréquente que leurs prédécesseurs. Un exemple de ces satellites est présenté dans la **Figure 1.6**.




Figure 1.6. Satellite MSG.

Les satellites MSG diffusent des informations et des images plus précises et de la qualité améliorée destinée aux prévisions météorologiques ainsi qu'à d'autres applications telles que l'hydrologie, l'agriculture et les études environnementales et climatiques. Les données collectées sont utilisées quotidiennement dans le cadre des études sur les changements climatiques, et se sont avérées d'une importance vitale lors de situations météorologiques dangereuses, permettant ainsi de réduire les pertes de vie humaine et les dégâts matériels.

Ces satellites permettent de doubler le rythme d'acquisition des données : couverture de la Terre toutes les 15 minutes. Ils sont définis par un ensemble de caractéristiques comme suit :

- Altitude : 35800 km
- Résolution : 1 km pour le canal visible haute résolution (HRV), 3 km pour les autres canaux
- 1 image toutes les 15 mn
- 12 canaux d'observation : 4 visibles, 8 infra rouges

Meteosat couvre l'Europe, l'Afrique, le Moyen-Orient, l'océan Atlantique, une partie de l'est de l'Amérique du Sud et ainsi qu'une partie de l'ouest de l'océan Indien.

➤ **Radiomètre-imageur SEVIRI**

Les capteurs Météosat de la première génération (MFG) étaient dotés de seulement trois canaux spectraux et transmettaient des images du globe toutes les trente minutes, à différence du SEVIRI qui envoie des images toutes les quinze minutes. L'instrument principal du satellite MSG est le radiomètre imageur SEVIRI, qui est constitué de 12 canaux spectraux, il transmet des images tous les quart d'heure de tout le disque terrestre à une résolution de 3*3 km² dans tous les canaux à l'exception du canal HRV où il transmet que la moitié du disque avec une résolution de 1*1 Km². Quatre des douze canaux du radiomètre imageur SEVIRI sont dédiés à la mesure du rayonnement visible, essentiel pour la détection des phénomènes météorologiques dangereux et les huit autres dans la mesure du rayonnement infrarouge dans des longueurs d'ondes différentes. La résolution spatiale est également améliorée, puisqu'elle est de 3 km pour les bandes multi spectrales de MSG contre 5 km pour la première génération et de 1 km pour le canal visible haute résolution HRV contre 2,5 km pour MFG. Grâce à ses caractéristiques, telles que sa résolution temporelle, sa résolution spectrale et sa résolution spatiale, cet instrument permettra aux météorologistes de décrire avec une précision accrue des processus atmosphériques et de déceler plus aisément les phénomènes localisés à évolution rapide ou violente, tels que les orages, les tempêtes de neige ou le brouillard.

Les informations concernant les 12 bandes spectrales de MSG ainsi que leurs principaux usages sont résumées dans le **Tableau 1.1**.

Tableau 1.1. Canaux de MSG.

Nom du canal	Bande spectrale (μm)	Résolution	Utilisation
HRV	0,50-0,90	1 Km	Détection et suivi des masses nuageuses, étude des terres émergées
VIS 0,6	0,56-0,71	3 Km	Détection des nuages, identification des structures, suivi des nuages, observation des aérosols, suivi de la végétation.
VIS 0,8	0,74-0,88	3 Km	
NIR 1,6	1,50-1,78	3 Km	Différenciation entre neige et nuage, nuage d'eau liquide et nuages de glace, information sur les aérosols.
IR 3,9	3,48-4,36	3 Km	Détection des nuages bas de nuit, des feux de jour.
IR 6,2 (WV)	5,35-7,15	3 Km	Vapeur d'eau de moyenne et haute troposphère, suivi de la dynamique atmosphérique, hauteur des nuages semi-transparents.
IR 7,3 (WV)	6,85-7,85	3 Km	
IR 8,7	8,30-9,10	3 Km	Informations quantitatives sur les cirrus fins, distinction entre les nuages de glace et d'eau liquide.
IR 9,7	9,38-9,94	3 Km	Radiance de l'ozone pour assimilation en prévision numérique, évolution du champ total d'ozone
IR 10,8	9,80-11,80	3 Km	Mesure de la température de surface de la terre et de la mer, détection des cirrus et déduction des quantités d'eau précipitants au-dessus de la mer.
IR 12,8	11,00-13,00	3 Km	
IR 13,4	12,40-14,40	3 Km	Amélioration de la détermination du facteur de transmission des cirrus, information sur la température de la basse troposphère dépourvue de nuages pour les évaluations d'instabilité.

1.2.4. Impacts de la variabilité de la pluviométrie

D'après les études menées par le Groupe d'experts intergouvernemental sur l'évolution du climat, la variabilité climatique est un phénomène mondial qui affecte de nombreux pays dans le monde [GIEC 2013]. Ces spécialistes ont clairement démontré que le réchauffement planétaire est directement imputable à des influences humaines. Une des conséquences de ce phénomène est le changement du régime des précipitations. Dans les régions continentales de moyenne latitude de l'hémisphère Nord et dans l'Est de l'Amérique du Sud, une augmentation des précipitations est observée, tandis qu'au Sahel, en Méditerranée, en Afrique Australe et dans une partie de l'Asie du Sud une diminution des précipitations est enregistrée.

À l'instar des pays frappés par la variabilité climatique mondiale, l'Algérie a connu, dans la deuxième moitié du 20^{ème} siècle, une baisse considérable des précipitations dans plusieurs régions du Nord. Étant donné que la recharge des nappes d'eau dépend principalement des précipitations, toute modification du régime de précipitation est susceptible d'avoir des répercussions sur la disponibilité des ressources en eau souterraine. La forte variation du régime pluviométrique au Nord Algérien, peut être expliquée par deux facteurs déterminants : climatique et géographique. D'une part, la circulation atmosphérique générale et précisément l'oscillation Nord Atlantique qui influence le climat ; dont sa phase positive a provoqué les sécheresses qu'a connu le pays à partir de la moitié des années 70. D'autre part, le relief qui joue un rôle important dans la répartition des précipitations, du fait qu'il varie considérablement d'Ouest en Est. C'est ainsi, que les différentes régions de la zone d'étude sont touchées par des degrés différents de sévérité de la sécheresse.

Les précipitations sont un élément essentiel pour le développement durable. Ces dernières années, les taux commencent à se raréfier notamment dans la région méditerranéenne. Ceci conduit à des situations de sécheresse qui impacte sérieusement l'économie d'un pays. En revanche, dans certaines régions, les intensités élevées génèrent des inondations, des érosions des sols, etc. Nous résumons dans ce qui suit certaines situations qui peuvent être engendrées par cette variabilité à l'échelle mondiale sur le plan environnemental et sur le plan agriculture.

1.2.4.1. Sur le plan environnemental

- ❖ **Inondations** : des pluies abondantes peuvent provoquer des inondations, endommageant les infrastructures, les habitats naturels et les écosystèmes. Les inondations peuvent également causer des pertes humaines et économiques considérable.
- ❖ **Erosion des sols** : des précipitations excessives et intenses peuvent provoquer l'érosion des sols en emportant la couche supérieure fertile. Cela entraîne une diminution de la productivité des sols et participe à la pollution des cours d'eau, des zones humides et des lacs adjacents
- ❖ **Modification des écosystèmes** : les changements dans les niveaux de précipitations peuvent affecter les écosystèmes en modifiant les habitats naturels, en favorisant la croissance de certaines espèces végétales au détriment d'autres, et en perturbant les cycles de reproduction et de migration des animaux.
- ❖ **Sécheresses** : une faible pluviométrie sur une longue période peut conduire à des sécheresses. Cela peut provoquer la diminution des ressources en eau, la dégradation des terres et des écosystèmes, ainsi que des problèmes d'approvisionnement en eau potable pour les populations humaines et animales.

1.2.4.2. Sur le plan agriculture

- ❖ **Production agricole** : les variations dans les niveaux de précipitations peuvent entraîner des rendements agricoles irréguliers d'une année à l'autre. Les périodes de sécheresse peuvent réduire les rendements, tandis que des pluies excessives peuvent entraîner des inondations, nuisant aux cultures.
- ❖ **Qualité des cultures** : les précipitations sont essentielles pour la croissance des cultures, tandis qu'un excès de pluie peut favoriser le développement de maladies fongiques et bactériennes dans les cultures, réduisant ainsi la qualité des produits agricoles.
- ❖ **Irrigation** : dans les régions où l'agriculture dépend principalement de l'irrigation, une pluviométrie insuffisante peut entraîner des problèmes d'approvisionnement en eau pour l'irrigation, ce qui nuit à la croissance des cultures.
- ❖ **Variabilité des cultures** : les variations imprévisibles de la pluviométrie peuvent rendre la planification agricole plus difficile, car les agriculteurs doivent s'adapter rapidement aux changements de conditions météorologiques.

1.3. Climat méditerranéen

Le climat désigne la représentation statistique des conditions météorologiques sur une période étendue dans un lieu spécifique. Cette représentation repose sur des moyennes et des variations de paramètres tels que la température, les précipitations, la durée d'ensoleillement, ainsi que des données sur les vents et leur direction, qui aident à déterminer les conditions prédominantes. Il existe différents types de climat dans le monde notamment le climat tempéré, tropical, désertique, etc. Chacun caractérisé par des conditions météorologiques spécifiques.

Le climat méditerranéen s'insère dans le groupe des climats dits tempérés, souvent associé aux régions côtières autour du bassin méditerranéen, offre un exemple fascinant de variations climatiques spécifiques et d'adaptations uniques aux conditions environnementales.

1.3.1. Caractéristiques du climat méditerranéen

La région méditerranéenne, localisée entre les latitudes 30° et 45° illustré dans la **Figure 1.7**, a été habitée depuis l'antiquité et cette occupation humaine a grandement influencé les paysages et les espaces naturels de la région. En raison de ces propriétés géographiques, le climat de la région présente une complexité spatiotemporelle très prononcée [Lionello et al. 2006]. Les ressources physiques disponibles dans cette zone sont liées aux caractéristiques de ses principaux éléments naturels, notamment le climat, le relief, le sol et les ressources en eau.

Le climat méditerranéen est avant tout caractérisé par une sécheresse et une chaleur estivales, et secondairement par la relative douceur des températures hivernales, Ce climat est le résultat de l'influence à la fois du climat subtropical et des systèmes de moyennes latitudes [Trigo et al. 2006]. Les températures froides et l'humidité sont apportées par les cyclones du front polaire, tandis que les pressions tropicales font remonter de l'air chaud et sec. Les précipitations des systèmes méso-échelle se déplacent généralement de l'Ouest en Est et du Nord au Sud dans la région méditerranéenne. Ces précipitations peuvent être associées à des perturbations cycloniques méditerranéennes qui résultent d'interactions entre la circulation atmosphérique à grande échelle, l'orographie et les différences de température entre la Terre et la mer, selon Mehta et Yang (2008).

L'humidité qui caractérise le climat méditerranéen est due essentiellement à la vapeur d'eau qui provient de la mer, mais aussi de la transpiration des végétaux (forêt bien développés). En se déplaçant vers les hautes plaines, l'humidité diminue tandis que l'ensoleillement augmente, favorisant ainsi l'évapotranspiration et contribuant à un climat semi-aride. En allant plus au Sud, l'ensoleillement devient très intense et les précipitations sont rares, entraînant une humidité très faible et une végétation presque absente, à l'exception de certaines espèces adaptées à ce climat désertique.



Figure 1.7. Région Méditerranéenne.

1.3.2. Facteurs influençant la pluviométrie méditerranéenne

La pluviométrie méditerranéenne, est influencée par plusieurs facteurs. On peut distinguer trois facteurs principaux : les systèmes météorologiques, les courants marins et l'influence des reliefs et des masses d'air.

1.3.2.1. Systèmes météorologiques

Les systèmes météorologiques, tels que les dépressions atmosphériques et les anticyclones, ont une grande importance dans la distribution des précipitations en Méditerranée.

Les dépressions atmosphériques apportent souvent des pluies abondantes. En Méditerranée, ces dépressions se forment lorsque de l'air chaud et humide provenant de la mer rencontre de l'air plus froid venant de l'intérieur des terres. Ces conditions favorisent la condensation de la vapeur d'eau et la formation de nuages, ce qui entraîne des précipitations. En revanche, les anticyclones sont associés à des conditions plus sèches. En Méditerranée, les anticyclones se forment généralement en hiver lorsque de l'air froid et sec se déplace depuis l'Est vers la région. Ces anticyclones dominants peuvent entraîner des périodes prolongées de temps sec et réduire les précipitations.

Les vents jouent également un rôle dans l'influence des systèmes météorologiques sur la pluviométrie méditerranéenne. Ils peuvent transporter l'humidité sur de longues distances depuis les zones maritimes ou les régions tropicales, jusqu'à la Méditerranée, contribuant ainsi à la formation de nuages et de précipitations. Les régimes de vents, tels que les vents de secteur Sud, peuvent également influencer la quantité et la répartition des précipitations le long des côtes méditerranéennes. Les mouvements et les interactions de ces systèmes météorologiques influencent donc la quantité et la répartition des précipitations dans la région méditerranéenne.

1.3.2.2. Courants marins

Les courants marins, tels que le courant méditerranéen, jouent un rôle crucial dans le climat méditerranéen en raison de leur influence sur les températures de surface de la mer et sur les cycles de précipitations le long des côtes. Le courant méditerranéen transporte de l'eau chaude depuis l'Est de l'océan Atlantique vers la mer Méditerranée, contribuant ainsi à maintenir des températures élevées dans la région pendant les mois d'été.

Lorsque l'eau chaude du courant méditerranéen atteint les côtes méditerranéennes, elle réchauffe l'air au-dessus de la mer, créant ainsi une source d'énergie pour les systèmes météorologiques. Cette chaleur de l'eau de mer peut conduire à la formation de dépressions atmosphériques, qui peuvent ensuite entraîner des précipitations le long des côtes.

Cependant, l'influence des courants marins sur les cycles de précipitations méditerranéens est complexe et dépend également d'autres facteurs, tels que la topographie de la région et la présence de caractéristiques géographiques telles que les chaînes de montagnes.

En outre, les courants marins peuvent également affecter la répartition des précipitations saisonnières le long des côtes méditerranéennes. Par exemple, pendant les mois d'hiver, lorsque le courant méditerranéen transporte de l'eau plus froide depuis le Nord, il peut influencer les systèmes météorologiques et favoriser des précipitations plus importantes dans certaines régions (**Figure 1.8**).

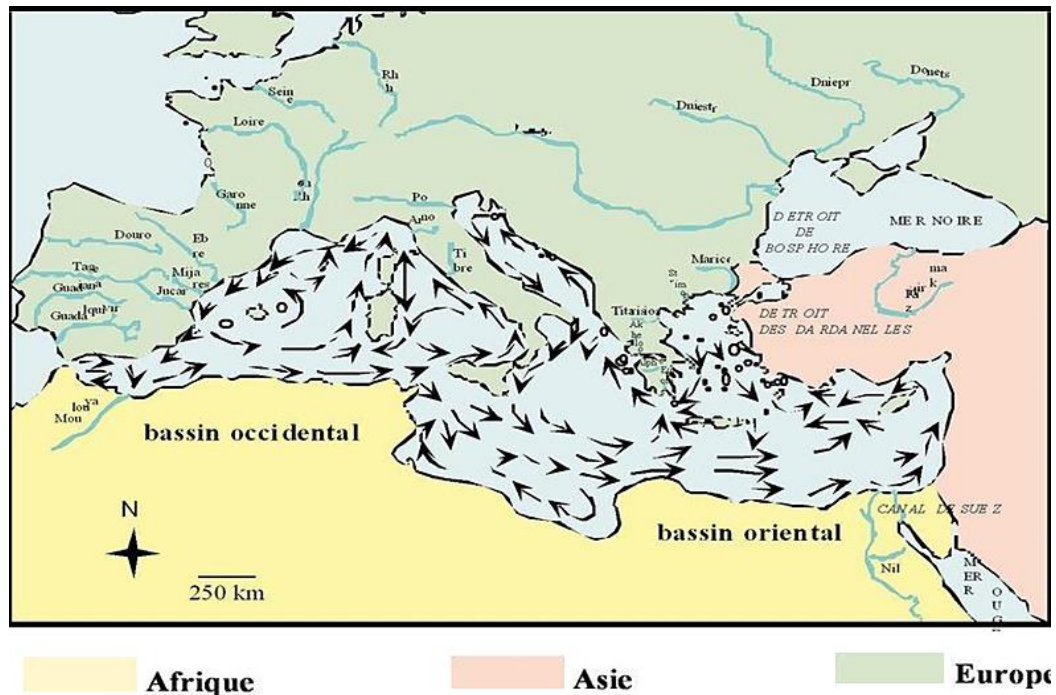


Figure 1.8. Courants en mer Méditerranée.

1.3.2.3. Influence des reliefs et masses d'air

Les reliefs, tels que les montagnes et les chaînes de collines, peuvent avoir un impact significatif sur la pluviométrie méditerranéenne. Lorsque l'air s'élève le long des pentes d'une montagne, il se refroidit en raison de l'expansion de l'air et de la diminution de la pression atmosphérique. Cette diminution de la température peut entraîner la condensation de la vapeur d'eau contenue dans l'air, formant ainsi des nuages et des précipitations.

L'effet de l'ascendance orographique peut créer des régions avec des précipitations plus abondantes du côté vent d'un relief. Lorsque l'air humide monte et se refroidit, il libère son humidité sous forme de pluie ou de neige. Par conséquent, les versants exposés au vent peuvent recevoir des précipitations plus importantes. Cependant, une fois que l'air redescend de l'autre côté de la montagne, il se réchauffe à nouveau en descendant, ce qui peut entraîner

une diminution des précipitations sur le côté sous le vent. Cet effet est connu sous le nom d'effet de foehn, et il peut entraîner des conditions plus sèches sur le versant sous le vent d'une montagne.

Outre l'ascendance orographique, les masses d'air qui se déplacent sur de longues distances peuvent également influencer la pluviométrie méditerranéenne. Par exemple, lorsque des masses d'air provenant des régions tropicales se déplacent vers la région méditerranéenne, elles peuvent transporter avec elles de l'humidité. Lorsque ces masses d'air rencontrent des reliefs, elles peuvent libérer leur humidité sous forme de précipitations. Cela peut contribuer à l'augmentation des précipitations dans les régions méditerranéennes.

1.4. Discussion

Dans ce chapitre, nous venons de voir que la pluviométrie est un élément clé pour la compréhension du climat méditerranéen. En définissant les différents systèmes précipitant et leur impact sur l'environnement et l'agriculture, nous pouvons mieux anticiper les variations climatiques dans cette région unique du monde. La mesure précise de la pluviométrie reste essentielle pour prévoir et atténuer les conséquences des changements climatiques dans les régions méditerranéennes. Ainsi, comme nous venons de le voir, la rareté ou l'abondance des précipitations engendrent des situations désastreuses. Cependant, contrairement à d'autres régions qui connaissent des précipitations régulières, les situations de sécheresse se multiplient dans la région méditerranéenne ces dernières années. Par conséquent, il est très important de prendre au sérieux ce phénomène. L'analyse et la prédiction de la sécheresse peuvent conduire à mieux appréhender ce phénomène pour faire face. Dans ce contexte, le prochain chapitre contiendra une description détaillée sur le phénomène de la sécheresse

Chapitre 2 Contexte scientifique de la sécheresse

2.1. Préambule

La sécheresse est un phénomène rampant, ce qui rend difficile la prédiction précise de son début ou de sa fin [Gillette 1950]. Elle se manifeste par une réduction importante et prolongée des précipitations, entraînant une véritable pénurie d'eau qui affecte profondément les écosystèmes, les communautés humaines et les activités économiques. À travers les âges, la sécheresse a engendré des conséquences dévastatrices, provoquant des crises alimentaires, des déplacements massifs de population et des conflits.

En fournissant des connaissances approfondies et des outils d'évaluation, l'analyse de la sécheresse offre la possibilité de mettre en place des stratégies résilientes et durables, permettant ainsi de préserver notre environnement et de protéger les communautés vulnérables face à ce défi. Dans ce contexte, une sélection précise d'indices d'identification de la sécheresse, peuvent fournir une description synthétique et objective des conditions de sécheresse, permettant ainsi une meilleure appréhension.

Dans ce chapitre, nous décrivons le phénomène de sécheresse dans ses différents aspects tout en donnant la particularité du phénomène en Algérie. Nous évoquons ainsi ses caractéristiques, ses différents types, sa situation dans le monde et les indices permettant d'évaluer son intensité. Nous terminons le chapitre par l'énumération de certains de ses impacts.

2.2. Description de la sécheresse

La sécheresse est l'un des risques naturels les plus meurtriers. Pourtant, une définition universelle de ce terme s'est avérée difficile à trouver. Il existe différentes définitions couramment utilisées pour décrire ce phénomène climatique redoutable. Selon l'Organisation Météorologique Mondiale [WMO 1992], la sécheresse est caractérisée par un manque prolongé et persistant de précipitations. D'autre part, selon Palmer (1965), la sécheresse se réfère à une importante divergence par rapport aux conditions hydrologiques normales d'une région. La sécheresse touche plusieurs pays dans le monde et l'Algérie en fait partie. Elle est une anomalie climatologique transitoire dans laquelle la disponibilité de

l'eau est inférieure à celle d'une zone géographique habituelle. L'eau ne suffit pas pour répondre aux besoins des plantes, des animaux et des humains qui y vivent.

Les sécheresses font partie des plus grande menaces pour le développement durable, tant dans les pays en développement que dans les pays développés. Par rapport aux deux décennies précédentes, le nombre et la durée des sécheresses ont augmenté de 29% depuis 2000, [UNCCD 2022]. Cette tendance est particulièrement préoccupante alors que plus de 2,3 milliards de personnes sont confrontées au stress hydrique, constituant ainsi un problème majeur. Elle compromet les moyens de subsistance des populations concernées, augmente le risque de maladie et de décès, et contribue aux mouvements migratoires massifs.

2.3. Caractérisation de la sécheresse

Les sécheresses sont caractérisées par trois éléments distinctifs : leur intensité, leur durée et leur étendue spatiale.

L'intensité se réfère à l'importance du déficit de précipitations et à la gravité des conséquences qui en découlent. Elle est généralement évaluée en comparant les valeurs observées à la normale d'un paramètre climatique tel que la quantité de précipitations, à l'aide d'indicateurs comme le niveau des réservoirs ou des indices comme l'indice de précipitation standardisé.

La durée constitue le deuxième aspect crucial des sécheresses : bien qu'elles puissent se développer rapidement dans certains climats, elles nécessitent généralement au moins deux à trois mois pour s'établir pleinement, et peuvent ensuite persister pendant plusieurs mois voire années. L'ampleur des effets de la sécheresse est étroitement liée au moment où commence le déficit de précipitations, à son intensité et à sa durée. Par exemple, un hiver sec peut avoir des conséquences limitées dans les climats tempérés à moyennes latitudes, en raison de la faible demande en eau pendant cette période de l'année. L'étude des données paléoclimatologies, telles que les anneaux de croissance des arbres ou les sédiments lacustres, peut offrir une meilleure compréhension de la fréquence, de la durée et de l'étendue spatiale des épisodes de sécheresse, fournissant ainsi aux planificateurs des informations importantes sur les périodes précédant les relevés instrumentaux.

Les sécheresses présentent également des variations spatiales. Les zones affectées par une sécheresse intense évoluent progressivement, avec des épices d'intensité maximale se déplaçant d'une saison à l'autre ou d'une année à l'autre, surtout dans le cas des sécheresses prolongées. Dans les pays de grande superficie tels que le Brésil, la Chine, l'Inde, les États-Unis et l'Australie, la sécheresse touche rarement, voire jamais, l'intégralité du territoire. Par exemple, lors de la pire sécheresse qu'ont connue les États-Unis pendant plusieurs années en 1934, seulement 65 % du territoire américain a été touché par une sécheresse intense ou extrême, ce qui représente l'étendue spatiale maximale de la sécheresse dans le pays sur la période allant de 1895 à 2005.

2.4. Types de sécheresse

Le manque de précipitations n'est pas le seul facteur déterminant pour évaluer la sécheresse des sols. En effet, il existe trois types principaux de sécheresse qui sont généralement reconnus : la sécheresse météorologique, la sécheresse hydrologique et la sécheresse agricole (voir **Figure 2.1**). Il existe également le type de sécheresse socio-économique qui survient habituellement après les autres types de sécheresse lorsque les réserves en eau diminuent et que la demande augmente.




Figure 2.1. Différents types de sécheresse.

2.4.1. Sécheresse météorologique

La sécheresse météorologique est le type de sécheresse le plus évident, se manifestant par une pluviométrie insuffisante sur une durée prolongée par rapport aux normales attendues. Elle peut être observée à différentes échelles, qu'elles soient locales, régionales ou nationales. Les signes caractéristiques de cette sécheresse incluent des sols secs, une diminution des débits des cours d'eau et des niveaux d'eau des lacs et réservoirs, ainsi que des pénuries d'eau pour l'irrigation, l'approvisionnement en eau potable et d'autres utilisations humaines. Les régions méditerranéennes, telles que le Sud de l'Europe, le Nord de l'Afrique et certaines parties du Moyen-Orient, sont souvent confrontées à ce type de sécheresse météorologique.

2.4.2. Sécheresse agricole

La sécheresse agricole dite aussi sécheresse édaphique est un phénomène préoccupant qui se produit lorsque les sols manquent d'eau, entraînant des conséquences néfastes sur le développement de la végétation cultivée. La hauteur de précipitation ne présente pas une corrélation directe avec l'infiltration des eaux dans le sol. Le taux d'infiltration dépend de plusieurs facteurs, tels que les conditions d'humidité antérieures, la pente du terrain, la composition du sol et l'intensité des précipitations. Les caractéristiques des sols peuvent également varier, certains ayant une capacité de rétention d'eau plus faible, ce qui les rend plus sensibles à la sécheresse agricole.

2.4.3. Sécheresse hydrologique

La sécheresse hydrologique se produit lorsque les réserves en eau, telles que les nappes souterraines, les cours d'eau et les lacs, diminuent en dessous de la moyenne et atteignent des niveaux anormalement bas. Les sécheresses météorologiques sont souvent causées par des changements climatiques, tels que des variations naturelles des régimes de précipitations ou des phénomènes comme El Niño. Si la pluie est insuffisante pendant une période prolongée, les nappes souterraines peuvent se tarir, les cours d'eau peuvent s'assécher et les lacs peuvent perdre une partie de leur volume.

D'autre part, la surexploitation des ressources en eau peut également contribuer à la sécheresse hydrologique. Lorsque l'eau est prélevée en quantités supérieures à ce qui peut être naturellement régénéré, les réserves d'eau diminuent progressivement. Cela se produit souvent en raison de l'augmentation de la demande en eau pour l'agriculture, l'industrie et

les besoins domestiques. L'absence de mesures de gestion appropriées de l'eau, telles que la régulation des prélèvements ou l'adoption de techniques d'irrigation efficaces, peut aggraver la surexploitation et entraîner une sécheresse hydrologique.

2.5. Causes de la sécheresse

Les sécheresses peuvent être déclenchées par des causes naturelles telles que les conditions météorologiques. Mais elles sont de plus en plus souvent dues à l'activité humaine. Les deux principales causes de la sécheresse sont résumées comme suit :

2.5.1. Causes météorologiques

Des facteurs météorologiques peuvent faire en sorte qu'une région reçoive moins de précipitations que la moyenne. Des changements dans la circulation atmosphérique mondiale peuvent signifier qu'il ne pleut pas beaucoup dans une région. Par exemple, la sécheresse en Australie dans les années 2000 a été aggravée par des changements dans les courants atmosphériques et océaniques dans l'océan pacifique. Des changements dans la circulation atmosphérique peuvent également affecter les régimes de précipitations : dans le passé, les pluies de mousson en Inde ne sont pas apparues au moment prévu. Des systèmes de haute pression peuvent bloquer des systèmes de basse pression qui apportent des précipitations au Royaume-Uni. Cela peut conduire à des conditions de sécheresse.

2.5.2. Causes humaines

La déforestation réduit la quantité d'eau stockée dans le sol. La terre s'assèche donc plus rapidement que si elle était couverte de végétation. En outre, les arbres libèrent de l'humidité dans l'atmosphère par leurs feuilles, un processus connu sous le nom de transpiration. L'élimination des arbres et de la végétation réduit la quantité d'humidité dans l'atmosphère, ce qui assèche la zone. La construction de barrages et de réservoirs réduit le débit de l'eau en aval. Cela peut entraîner une sécheresse dans d'autres zones : il existe plusieurs endroits dans le monde où cela pourrait entraîner des conflits à l'avenir, notamment le long du fleuve Nil.

L'agriculture intensive épuise les réserves d'eau car de grandes quantités d'eau sont nécessaires pour l'irrigation. En outre, le bétail a également une demande considérable d'eau pour l'abreuvement.

Les émissions de gaz à effet de serre dans l'atmosphère sont augmentées par les actions humaines, entraînant une augmentation continue des températures moyennes de la planète. Par conséquent, les niveaux d'évaporation et d'évapotranspiration ont augmenté et les températures plus élevées ont provoqué des incendies de forêt et prolongé les périodes de sécheresse.

2.6. Indices de sécheresse

Les indices de sécheresse sont l'un des moyens permettant de surveiller et d'étudier la sécheresse. Ces indices sont généralement des représentations numériques de la gravité des sécheresses, calculées à partir de données climatiques ou hydrométéorologiques. Ils évaluent l'état qualitatif d'une sécheresse en un lieu spécifique sur une période donnée, à différentes échelles de temps [OMM 2012].

Au fil des ans, de nombreux indices de sécheresse ont été conçus et utilisés par les météorologues et les climatologues du monde entier [Mishra et Singh 2010]. Plus de 100 indices de sécheresse ont été créés pour identifier et décrire la sécheresse. Un certain nombre d'indices sont fréquemment utilisés pour représenter différents types de sécheresse, y compris SPI, PDSI, SPEI et autres.

2.6.1. Indice Standardisé des Précipitations (SPI)

Le SPI, développé par McKee et al. (1993) est un indice puissant, flexible et facile à calculer, il se base uniquement sur les données de précipitations. Le SPI a été conçu pour évaluer le déficit de précipitations sur différentes échelles de temps. Ces échelles de temps expliquent les impacts de la sécheresse sur la disponibilité des différents types de ressources en eau. McKee et al. (1993) ont calculé l'indice SPI pour des laps de temps de 3, 6, 12, 24 et 48 mois. Les courtes échelles de temps du SPI réagissent rapidement aux anomalies de précipitations, tandis que les échelles de temps plus longues reflètent l'impact sur les ressources en eau souterraine, les débits des cours d'eau et les niveaux des réservoirs.

Le SPI d'un lieu donné pour une période choisie à partir des relevés à long terme des précipitations, est calculé en ajustant une fonction de densité de probabilité appropriée à la distribution de fréquence des précipitations additionnée sur l'échelle de temps considérée. Ceci est effectué séparément pour chaque échelle de temps et pour chaque lieu géographique [Angelidis et al. 2012]. La série de données de longue durée est ajustée à une distribution de

probabilité que l'on transforme ensuite en une distribution normale pour que l'indice SPI moyen du lieu considéré et pour le laps de temps étudié soit égal à zéro. Les valeurs positives de l'indice SPI indiquent des précipitations supérieures à la médiane et les valeurs négatives indiquent des précipitations inférieures à celle-ci. L'indice SPI indique le début d'une sécheresse lorsque sa valeur est inférieure ou égale à -1 et qu'une sécheresse se termine quand sa valeur devient positive [OMM 2012].

- **Méthodes de calculs**

➤ **La distribution Gamma :** Pour calculer le SPI, il est nécessaire d'ajuster une fonction de densité de probabilité Gamma à une série temporelle des précipitations, dont la fonction de densité de probabilité est donnée de la façon suivante [Angelidis et al. 2012]:

$$g(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-\frac{x}{\beta}} \quad (2.1)$$

Avec :

$\alpha > 0$ paramètre de forme,

$\beta > 0$ paramètre d'échelle,

$\Gamma(\alpha)$ fonction Gamma définie par :

$$\Gamma(\alpha) = \int_0^{\infty} x^{\alpha-1} e^{-x} dx \quad (2.2)$$

L'ajustement de la distribution aux données requiert l'estimation de α et β . En servant de l'approximation de Thom (1958), ces paramètres peuvent être estimés comme suit :

$$\alpha = \frac{1}{4A} \left(1 + \sqrt{1 + \frac{4A}{3}} \right) \quad (2.3)$$

Avec

$$A = \ln(\bar{x}) - \frac{\sum \ln(x)}{n} \quad (2.4)$$

Et

$$\beta = \frac{\bar{x}}{\alpha} \quad (2.5)$$

Avec

\bar{x} : Valeur moyenne de la quantité des précipitations,

n : Numéro de mesure des précipitations,

x : Quantité de précipitations dans une séquence de données.

L'intégration de la fonction de densité de probabilité par rapport à x donne l'expression $G(x)$ pour la probabilité cumulée donné ci-après :

$$G(x) = \int_0^x g(x)dx = \frac{1}{\beta^\alpha \Gamma(\alpha)} \int_0^x x^{\alpha-1} e^{-\frac{x}{\beta}} dx \quad (2.6)$$

En substituant $t = x / \beta$, l'équation (2.6) est réduite à :

$$G(x) = \frac{1}{\Gamma(\alpha)} \int_0^{x/\beta} t^{\alpha-1} e^{-t} dt \quad (2.7)$$

Il est possible d'avoir plusieurs valeurs zéro dans un échantillon. Afin de prendre en compte la probabilité de valeur zéro, étant donné que la distribution Gamma n'est pas définie pour $x=0$, la fonction de probabilité cumulée pour la distribution Gamma est modifiée comme suit :

$$H(x) = q + (1 - q)G(x) \quad (2.8)$$

Où :

q est la probabilité d'une précipitation nulle, calculée à l'aide de l'équation suivante :

$$q = \frac{m}{n} \quad (2.9)$$

m : Nombre indiquant combien de fois la précipitation a été nulle dans une séquence temporelle de données.

n : Nombre d'observations des précipitations dans une séquence de données.

Enfin, la distribution de probabilité cumulée est transformée en distribution normale pour donner le SPI. Après la conversion approximative fournie par Abramowitz et Stegun (1965), il en résulte que :

$$z = SPI = - \left(t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right) \text{ et } t = \sqrt{\ln\left(\frac{1}{H(x)^2}\right)} \quad (2.10)$$

Pour $0 < H(x) < 0.5$

$$z = SPI = + \left(t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right) \text{ et } t = \sqrt{\ln\left(\frac{1}{(1.0 - H(x))^2}\right)} \quad (2.11)$$

Pour $0.5 < H(x) < 1$

Et :

Les paramètres $c_0=2.515517$, $c_1=0.802853$, $c_2=0.010328$ sont des coefficients utilisés dans une formule d'approximation pour calculer les quantiles de la distribution normale standard.

Les paramètres $d_1 = 1.432788$, $d_2 = 0.189269$, $d_3 = 0.001308$ sont souvent utilisés dans divers contextes mathématiques ou statistiques pour des approximations ou des calculs spécifiques, bien que leur utilisation précise dépende du domaine particulier.

- **La distribution log-normale :** Comme pour la distribution Gamma, la distribution log-normale est asymétriquement positive et non négative. Elle a l'avantage de la simplicité puisqu'il ne s'agit que d'une transformation logarithmique des données c'est-à-dire $Y = \ln(x)$ (pour $x > 0$), en supposant que les données transformées résultantes sont décrites par une distribution gaussienne. En ajustant la distribution log-normale à la moyenne de l'échantillon et à la variance des données transformées logarithmiques μ_y et σ_y^2 , le SPI devient sous forme de l'équation (2.12) [Angelidis et al. 2012] :

$$z = SPI = \frac{\ln(x) - \mu_y}{\sigma_y} \quad (2.12)$$

Avec:

x : Valeur de précipitation observée sur une période spécifique.

μ_y : Moyenne historique des précipitations sur la même période que x .

σ_y : Écart-type des précipitations historiques sur la même période que x .

- **La distribution normale :** La distribution Gamma ne tend pas vers la normale lorsque le paramètre de forme α tend vers l'infini. Il est possible d'utiliser la distribution de probabilité normale au lieu de gamma, ce qui est plus facile à calculer et peut-être plus précis du fait d'un meilleur ajustement aux données. Dans ce cas, l'indice SPI devient [Angelidis et al. 2012]:

$$z = SPI = \frac{x - \mu}{\sigma} \quad (2.13)$$

x : Précipitation totale d'une période (mm),

μ : Précipitation moyenne historique de la période (mm),

δ : Écart-type historique des précipitations de la période (mm).

La **Figure 2.2** montre que pendant la période de base pour laquelle les paramètres gamma sont estimés, le SPI aura une distribution normale standard avec une valeur attendue de zéro et une variance de 1.

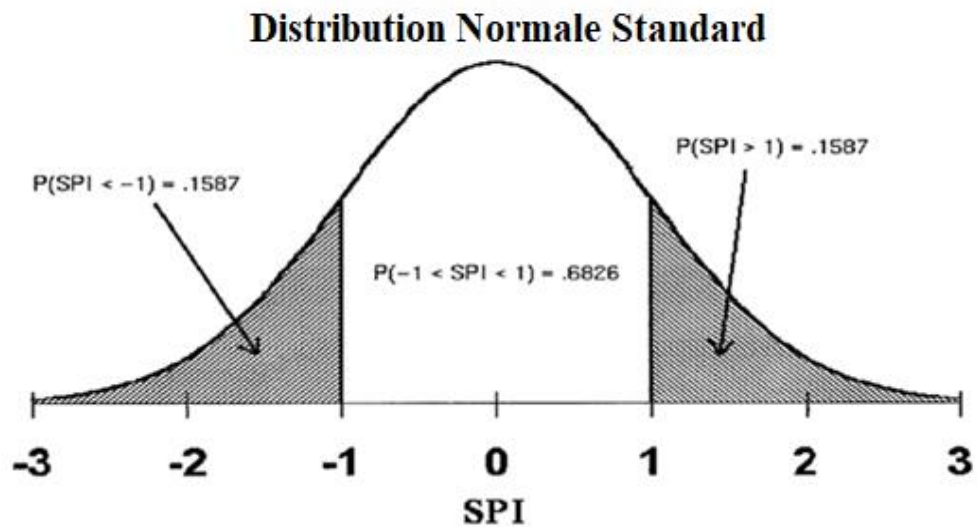


Figure 2.2. Distribution normale standard avec le SPI ayant une moyenne de zéro et une variance de 1.

Le SPI est standardisé en fonction de l'emplacement d'une station car il tient compte de la distribution en fréquence des précipitations ainsi que de la variation associée à la station. De plus, est temporellement normalisé ce qui signifie qu'il peut être calculé à n'importe quel moment. Le SPI représente une probabilité cumulée par rapport à une période de base pour laquelle les paramètres gamma ont été estimés.

McKee (1993) utilise la classification indiquée dans le **Tableau 2.1** afin de définir l'intensité des sécheresses à l'aide du SPI.

Tableau 2.1. Classification de la sécheresse selon SPI.

Valeurs SPI	Classification SPI
$SPI \geq 2$	Humidité extrême
$1,5 \leq SPI < 2$	Humidité sévère
$1 \leq SPI < 1,5$	Humidité modérée
$-1 \leq SPI < 1$	Normal
$-1,5 < SPI \leq -1$	Sécheresse modérée
$-2 < SPI \leq -1,5$	Sécheresse sévère
$SPI \leq -2$	Sécheresse extrême

Pour calculer l'indice SPI, il faut disposer idéalement de relevés mensuels s'étalant sur au moins 20 à 30 ans, mais de préférence sur 50 à 60 ans, voire plus, ce qui constitue la période optimale [Guttman 1994].

- **Avantages de SPI**

L'indice SPI offre une grande flexibilité d'utilisation, car il peut être calculé sur différentes échelles de temps. De plus, l'indice SPI offre une combinaison de rapidité de détection, de cohérence spatiale, ce qui permet des comparaisons entre des zones différentes soumises à des climats variés. Son caractère probabiliste le place dans un contexte historique, ce qui le rend adapté à la prise de décision en matière de gestion des sécheresses.

- **Inconvénients de SPI**

L'indice SPI se base exclusivement sur les relevés de précipitations. Cela signifie qu'il ne prend pas en compte le bilan hydrique du sol, ce qui limite sa capacité à calculer le rapport évapotranspiration/évapotranspiration potentielle (ET/ETP). Cette limitation peut avoir un impact sur l'évaluation précise des conditions de sécheresse, car le rapport ET/ETP est un indicateur clé de l'utilisation de l'eau par les plantes et de la disponibilité d'eau dans le sol. Par conséquent, il est important de prendre en considération cette limitation lorsque l'indice SPI est utilisé dans le contexte de l'évaluation globale de la sécheresse et de la gestion des ressources en eau.

- **Valeurs SPI pour une période plus ou moins longues**

- **SPI sur 1 mois** : une carte illustrant l'indice SPI calculé sur une période d'un mois présente une forte similitude avec une carte représentant le pourcentage des précipitations par rapport à la normale sur une période de 30 jours. L'indice SPI sur un mois, qui se termine fin novembre, compare le total mensuel des précipitations en novembre de l'année examinée aux totaux mensuels des précipitations en novembre de toutes les années pour lesquelles on dispose de relevés. Les conditions à court terme sont représentées par l'indice SPI sur un mois. Les applications sont liées aux sécheresses météorologiques et à l'humidité du sol à court terme. Si l'on ne tient pas compte des conditions climatiques du lieu, il est possible de mal interpréter l'indice SPI sur 1 mois. Il est possible d'obtenir des valeurs importantes négatives ou positives dans

des régions où il est normal que les pluies soient faibles au cours d'un mois donné, alors que l'écart par rapport à la moyenne est relativement faible [OMM 2012].

- **SPI sur 3 mois :** l'indice SPI sur trois mois compare les précipitations totales pour la période de trois mois examinée aux précipitations totales pour la même période de trois mois de toutes les années pour lesquelles on dispose de relevés. L'indice SPI sur 3 mois fournit une estimation des précipitations sur une saison et une indication des conditions d'humidité à courte et moyenne échéance. Il est crucial de comparer l'indice SPI sur 3 mois à des périodes plus longues. Il est envisageable que des conditions assez normales, voire humides, se manifestent pendant trois mois pendant une sécheresse prolongée. Tout comme l'indice SPI sur un mois, l'indice SPI sur trois mois peut donner l'impression de confusion dans les régions où le climat est généralement sec pendant la période de trois mois examinée. Les cumuls des précipitations ne dépassant que légèrement la moyenne, peuvent être liés à des valeurs importantes négatives ou positives de l'indice SPI [OMM 2012].
- **SPI sur 6 mois :** l'indice SPI sur 6 mois, compare les précipitations sur la période de six mois considérée aux précipitations totales pour cette même période (6 mois) de toutes les années pour lesquelles des relevés sont disponibles. L'indice SPI sur cette échelle de temps fournit une indication sur les tendances des précipitations sur une saison et jusqu'à la moyenne échéance, et on considère qu'il présente encore davantage de sensibilité aux conditions pour cette échéance de temps que l'indice de sévérité de sécheresse de Palmer. Un indice SPI de six mois peut être très utile pour identifier les précipitations pendant les saisons particulières [OMM 2012].
- **SPI sur 9 mois :** les régimes de précipitations inter-saisonniers à moyenne échéance sont indiqués par l'indice SPI sur 9 mois. Des conditions de sécheresse nécessitent généralement au moins une saison. Un indice SPI qui a été établi sur 9 mois et à des valeurs inférieures à **-1,5** est généralement un bon indicateur des conditions sèches qui ont un impact significatif sur l'agriculture et qui pourrait également affecter d'autres secteurs [OMM 2012].
- **SPI sur 12 mois à 24 mois :** l'indice SPI sur 12 mois établit la comparaison entre les précipitations sur une période de douze mois consécutifs et celles enregistrées sur la

même série de 12 mois consécutifs de toutes les années pour lesquelles on dispose de relevés. Étant donné que ces échelles de temps constituent le cumul de périodes plus courtes pouvant se situer au-dessus ou au-dessous de la normale, les valeurs des indices SPI établis pour une période relativement longue tendent à graviter autour de zéro, à moins qu'une tendance humide ou sèche bien distincte ne se soit installée. Les indices SPI pour ces échelles de temps sont généralement liés au débit des cours d'eau, au niveau des réservoirs et au niveau des eaux souterraines à relativement long terme [OMM 2012].

2.6.2. Indice Standardisé d'Évapotranspiration et de Précipitation (SPEI)

SPEI est une extension de l'indice SPI, conçu pour prendre en compte à la fois les précipitations et l'évapotranspiration potentielle (ETP) dans la détermination de la sécheresse. Il peut être calculé sur une plage d'échelles de temps allant de 1 à 48 mois. La polyvalence de l'indice est la même que celle du SPI, il peut être utilisé pour détecter et suivre les conditions liées à une variété d'impacts.

Le SPEI est basée sur un bilan hydrique climatique qui est déterminé par la différence entre précipitations (P) et évapotranspiration potentielle (ETP) pour le mois i . Cette relation est représentée par l'équation (2.14).

$$D_i = P_i - ETP_i \quad (2.14)$$

D_i fournit une mesure simple de l'excédent ou du déficit en eau pour le mois analysé.

L'ETP est calculé suivant l'équation de Thornthwaite 1948.

- **Avantages de SPEI**

Le principal avantage de SPEI est son caractère quasi temps réel. Cette caractéristique convient le mieux à la surveillance de la sécheresse et à l'alerte rapide. En prenant en compte les données de température en complément des précipitations, l'indice intègre l'effet de ce paramètre sur les conditions de sécheresse. Il est applicable à tous les régimes climatiques et les résultats peuvent être comparés car ils sont normalisés.

- **Inconvénients de SPEI**

La nécessité d'avoir des ensembles de données complets sur les températures et les précipitations peut limiter l'utilisation de l'indice si les séries de données disponibles présentent des lacunes. Étant donné que l'indice est calculé sur une base mensuelle, il pourrait ne pas détecter suffisamment tôt les sécheresses qui se développent rapidement.

2.6.3. Pourcentage à la Normale (PN)

PN est un indice simple utilisé au niveau local ou régional pour des périodes allant d'un mois à quelques mois, voire une année [Zargar et al. 2013]. Il permet d'évaluer l'écart des précipitations d'une période donnée par rapport à la normale historique de cette période. La normale est généralement définie comme la moyenne des précipitations totales sur une période d'environ 30 ans, calculée à partir des données disponibles.

Une condition nécessaire à l'application de cette méthode est la normalité de la distribution des données de précipitation. Le **Tableau 2.2** représente la classification de pourcentage à la normale.

Tableau 2.2. Classification de PN.

Valeurs PN	Classification PN
< 40	Extrêmement sec
40 à 55	Sécheresse sévère
55 à 70	Sécheresse modérée
70 à 80	Sécheresse faible
80 à 100	Normal

La formule mathématique de PN est donnée comme suit :

$$PN = \left(\frac{P}{P_m} \right) * 100\% \quad (2.15)$$

P : Précipitation totale d'une période (mm),

P_m : Précipitation moyenne historique d'une période (mm).

- **Avantages de PN**

Une méthode largement utilisée, qui est à la fois rapide et simple, et qui fait appel à des concepts mathématiques élémentaires.

- **Inconvénients de PN**

Dans les régions hétérogènes ou lorsqu'on considère différentes saisons, les précipitations peuvent varier considérablement dans l'espace et dans le temps, ce qui rend leur interprétation plus complexe. La grande variabilité spatiale et temporelle des précipitations peut rendre difficile la généralisation des données et nécessite une analyse plus approfondie pour comprendre les schémas et les tendances spécifiques à chaque région ou saison.

2.6.4. Déciles des Précipitations (DP)

La méthode DP a été développée par Gibbs et Maher (1967) pour surmonter les limites de l'utilisation du pourcentage à la normale. Cette approche permet de déterminer la fréquence d'un événement en divisant la distribution des fréquences des événements en 10 parties, chacune représentant 10% de la distribution. Ainsi, le cinquième décile correspond à la médiane de la distribution, tandis que le dixième décile représente le volume maximal de précipitation enregistré sur une région et pendant une période donnée.

Il s'agit d'une méthode homogène de classification des sécheresses qui peut être appliquée à différentes échelles, allant du local au continental, sur des périodes allant d'un mois à un an. Cette méthode repose sur une formule simple qui ne nécessite qu'une seule donnée : les précipitations. Elle présente moins d'hypothèses que les méthodes plus complexes. Cependant, il est essentiel de disposer de données climatiques couvrant une longue période (au moins 30 ans) pour calculer les déciles de manière précise et significative. Tout comme pour le PN (précipitation normale), la précision et la représentativité spatiale des déciles dépendent étroitement de la densité du réseau de stations météorologiques utilisé [Beaudin 2006]. La classification des déciles de précipitations est représentée dans le **Tableau 2.3**.

Tableau 2.3. Classification des déciles de précipitations.

Valeurs DP	Classification DP
1	Sécheresse extrême
2	Sécheresse sévère
3	Sécheresse modérée
4	Sécheresse faible
≥ 5	Normal ou humide

La formule mathématique de DP est définie comme suit :

$$DP = \% \text{ des fréquences cumulatives } / 10 \quad (2.16)$$

- **Avantages de DP**

Cette méthode est simple et polyvalente car elle se concentre sur une seule variable lors de l'analyse. Elle peut être adaptée à de nombreuses situations. En utilisant des seuils précisément définis, elle permet de placer les données récentes dans un contexte historique afin d'évaluer le degré de sécheresse. Cette méthode est pertinente aussi bien dans des conditions d'humidité que de sécheresse, ce qui la rend très utile pour évaluer les conditions hydrologiques d'une région donnée.

- **Inconvénients de DP**

Tout comme d'autres indices basés uniquement sur les précipitations, cette méthode ne tient pas compte de l'influence des températures et d'autres variables sur l'évolution de la sécheresse. Son efficacité est renforcée lorsqu'elle est appliquée à une longue série de relevés, car cela permet d'inclure un grand nombre de périodes sèches et humides dans la distribution des données.

2.6.5. China Z Index (CZI)

Créé en Chine, cet indice CZI se base sur le SPI et facilite son calcul. Il permet d'utiliser un score Z statistique pour repérer et surveiller les périodes de sécheresse. Le Centre climatologique national chinois a utilisé pour la première fois cet indice en 1995. Il est

semblable au SPI dans la mesure, où les précipitations sont utilisées pour déterminer si les conditions sont sèches ou humides [Guttman 1994].

$$CZI = \frac{6}{C_{si}} \left(\frac{C_{si}}{2} \varphi_{ij} + 1 \right)^{1/3} - \frac{6}{C_{si}} + \frac{C_{si}}{6} \quad (2.17)$$

Avec

i : l'échelle de temps considérée, qui peut être égale à 1, 2, 3, . . . , 72 mois,

j : est le mois en cours.

$$C_{si} = \frac{\sum_{j=1}^n (x_{ij} - \bar{x}_1)}{n * \sigma_i^3} \quad (2.18)$$

Avec

C_{si} : coefficient d'asymétrie,

n : le nombre total des mois dans l'enregistrement.

- **Avantages de CZI**

Les calculs sont faciles à effectuer et peuvent être réalisés sur différents intervalles de temps. L'indice est applicable à la fois aux périodes de sécheresse et aux périodes d'humidité, et il est similaire au SPI en ce sens qu'il peut gérer des lacunes dans les données.

- **Inconvénients de CZI**

Les scores Z ne nécessitent pas d'ajustement pour être adaptés à des distributions gamma, ce qui pourrait entraîner une moins bonne représentation des échelles temporelles réduites par rapport au SPI.

2.6.6. Indice de Sécheresse de Keetch-Byram (KBDI)

L'indice KBDI développé par Keetch et Byram (1968) aux Etats-Unis, qui combine à la fois le phénomène de sécheresse et celui des feux de forêts. Il est utilisé pour mesurer le niveau du risque de la sécheresse et celui du risque météorologique des incendies de forêts en fonction de la température journalière maximale et le cumul annuel de précipitations.

Il mesure en outre, la quantité d'humidité manquante dans le sol stress hydrique ou plutôt le degré de séchage au sol grâce à l'évapotranspiration en se basant sur une formule cumulative et des paramètres météorologiques tels que la température maximale, les précipitations quotidiennes et normales. La classification KBDI est donnée dans le **Tableau 2.4**.

Tableau 2.4. Classification KBDI.

Valeurs KBDI	Niveaux de risque
< 99	Très lent
100-199	Faible
200-399	Modéré
300-499	Haut
400-599	Très haut
+600	Extrême

La formule mathématique de KBDI est :

$$dQ = \frac{[203,2 - Q][0,968 \exp(0,0875T + 1,5552) - 8,3]dt * 10^{-3}}{1 + 10,88 \exp(-0,001736 P)} [mm] \quad (2.19)$$

Avec :

dQ : Facteur de sécheresse en (mm),

Q : Déficit en humidité du sol (mm),

T : Température maximale journalière (° C),

P : Précipitation moyenne annuelle (mm),

dt : Temps depuis lequel le sol perd son humidité (d).

Son calcul débute à partir d'une journée où le sol est saturé en eau. Il est donc parfois nécessaire de revoir l'historique des conditions climatiques pour trouver le dernier jour où le sol était à saturation. De plus, afin de calculer les facteurs de sécheresse du KBDI, une série temporelle des valeurs de précipitation doit être disponible pour une longue période. Plusieurs tableaux de facteurs de sécheresse sont créés en fonction de la valeur moyenne des

précipitations locales. Ces facteurs, en combinaison avec les valeurs journalières de précipitation et de température forment les intrants au calcul du KBDI. Les facteurs de sécheresse du KBDI sont calculés à partir de données en mesures anglaises. Toutefois, une adaptation pour le système international est disponible dans la publication d'Alexander (1990).

- **Avantages de KBDI**

La méthode de l'indice permet d'évaluer la quantité d'humidité déficitaire dans une zone donnée, et il est possible d'ajuster l'échelle pour obtenir des informations précises sur les conditions dans une zone spécifique. Les calculs sont simples et l'approche est conviviale, ce qui facilite son utilisation.

- **Inconvénients de KBDI**

La méthode de l'indice présuppose l'existence d'une limite à la disponibilité de l'humidité et que certaines conditions climatiques doivent être réunies pour que la sécheresse se développe, bien que cela ne soit pas nécessairement vrai dans tous les endroits.

2.6.7. Indice d'Aridité Annuelle de De Martonne

L'aridité est un phénomène climatique qui survient lorsque les précipitations annuelles sont insuffisantes et ne parviennent pas à compenser l'évapotranspiration potentielle (ETP).

L'indice d'aridité annuelle est une mesure utilisée pour évaluer le niveau d'aridité d'une région ou d'un climat. Il est basé sur une formule qui prend en compte les précipitations annuelles moyennes et la température moyenne annuelle d'une région donnée. Cependant, il est important de noter que cet indice est une mesure simplifiée qui ne tient pas compte de nombreux autres facteurs climatiques importants tels que l'ETP, la distribution saisonnière des précipitations et l'humidité du sol.

Cet indice fournit une indication générale de l'aridité d'un lieu. Plus l'indice est élevé, plus le climat est humide. En revanche, plus l'indice est bas, plus le climat est sec. Une classification des climats selon De Martonne est donnée dans le **Tableau 2.5**.

Tableau 2.5. Classifications des climats selon l'indice De Martonne.

Indice d'aridité	Type de climat
$0 < I < 5$	Hyper aride
$5 < I < 10$	Aride
$10 < I < 20$	Semi-aride
$20 < I < 30$	Semi-humide
$30 < I < 55$	humide

La formule mathématique est la suivante :

$$I_M = P T + 10 \quad (2.20)$$

Avec :

I_M : Indice d'aridité annuelle,

P : Le total annuel des pluies en (mm),

T : La moyenne thermique annuelle en ($^{\circ}$ C).

Les moyennes thermométriques ont été augmentées de 10 afin d'éviter d'obtenir des valeurs négatives pour l'indice.

- **Avantages de De Martonne**

La méthode repose sur des calculs simples qui impliquent seulement deux paramètres. De plus, elle est flexible car l'analyse peut être effectuée sur plusieurs intervalles de temps.

- **Inconvénients de De Martonne**

L'indice ne prend pas en compte la persistance des conditions de sécheresse d'une année à l'autre, et il peut avoir une réactivité lente dans certains climats

2.6.8. Indice de Sévérité des Sécheresses de Palmer (PDSI)

Développé par Wayne Palmer (1965), l'indice PDSI utilise des données de précipitations, de températures et de la teneur du sol en eau pour mesurer la sécheresse. Il

est fondé sur un modèle de l'offre et de la demande de l'eau. L'indice couvre les sécheresses hydrologiques, météorologiques et agricoles. Le **Tableau 2.6** présente la classification des conditions météorologiques selon PDSI.

Tableau 2.6. Classification des conditions météorologiques selon PDSI.

Valeurs PDSI	Classification PDSI
$\geq 4,00$	Extrêmement humide
3,00 à 3,99	Très humide
2,00 à 2,99	Modérément humide
A 1,99	Légèrement humide
0,50 à 0,99	Episode humide naissant
0,49 à -0,49	Presque normale
-0,50 à -0,99	sécheresse naissante
-1,00 à -1,99	Légère sécheresse
-2,00 à -2,99	sécheresse modérée
-3,00 à -3,99	sécheresse sévère
$\leq 4,00$	sécheresse extrême

La formule mathématique de PDSI est donnée comme suit :

$$PDSI = X(i) = 0.897X(i - 1) + Z(i)/3 \quad (2.21)$$

Où

$X(i-1)$: PDSI de la période précédente

$Z(i)$: Indice de l'anomalie en humidité

i : Mois de l'année

$$Z(i) = K(P - P_c) \quad (2.22)$$

Où

K : Facteur de poids,

P : Précipitations actuelle (mm),

P_c : Précipitations CAFEC 'Climatically Appropriate for Existing Conditions' Approprié pour les conditions climatiques existantes (mm).

$$P_c = \alpha_j PE + \beta_j PR + \gamma_j PRO - \delta_j PL \quad (2.23)$$

$\alpha_j, \beta_j, \gamma_j, \delta_j$: Coefficients climatique,

j : Mois de l'année,

PE : Evapotranspiration potentielle,

PR : Recharge du sol potentielle,

PRO : Ruissellement potentiel (mm),

PL : Perte potentielle dans le sol (mm).

- **Avantages de PDSI**

L'indice est largement utilisé à travers le monde et son programme ainsi que les valeurs de sortie sont facilement accessibles. Il existe de nombreux articles scientifiques dédiés à cet indice. L'intégration de données sur le sol et le calcul du bilan hydrique global le rendent robuste pour détecter la sécheresse.

- **Inconvénients de PDSI**

La nécessité d'une série complète de données peut poser des problèmes lors de l'utilisation de l'indice. De plus, en raison de son échelle temporelle d'environ neuf mois, il peut y avoir un retard dans la détection des conditions de sécheresse en raison de la simplification du facteur d'humidité du sol dans les calculs. Ce retard peut s'étendre sur plusieurs mois, ce qui limite la capacité de détecter rapidement une sécheresse émergente. L'aspect saisonnier peut également poser problème, car l'indice ne prend pas bien en compte les précipitations solides et les sols gelés.

2.6.9. Indice de Sécheresse Effectif (EDI)

Byun et Donald A. Wilhite (1999) ont développé l'indice de sécheresse effectif (EDI) pour surveiller les périodes de sécheresse. Contrairement à d'autres indices, l'EDI fournit des informations détaillées sur la durée et la gravité des déficits pluviométriques ainsi que sur le début et la fin des périodes de sécheresse. Les auteurs ont introduit un nouveau concept, la précipitation effective (EP), qui mesure l'épuisement quotidien des ressources en eau nécessaires à la base de l'EDI. Initialement calculé avec des données quotidiennes, l'algorithme de l'EDI a été modifié pour fonctionner avec des données mensuelles [Djellouli et al. 2016]. Les précipitations effectives sont définies en utilisant une fonction de réduction en fonction du temps, qui prend en compte les précipitations du mois en cours et les précipitations pondérées sur une période antérieure définie.

- **Avantages d'EDI**

Le calcul de l'indice ne nécessite que des données de précipitations, ce qui permet de le calculer pour tout emplacement où ces données sont disponibles. Des documents accompagnent le programme pour expliquer la méthode utilisée. Étant donné que l'indice est normalisé, les valeurs obtenues peuvent être comparées dans tous les régimes climatiques. L'EDI se révèle efficace pour détecter le début, la fin et la durée des périodes de sécheresse.

- **Inconvénients d'EDI**

L'indice ne tient pas compte directement de l'impact des températures sur la sécheresse, car il se base uniquement sur les données de précipitations. De plus, l'utilisation de données quotidiennes peut rendre l'application difficile en pratique, car il n'est pas toujours possible de les mettre à jour avec une telle fréquence.

2.6.10. Indice de Végétation par Différence Normalisée (NDVI)

Le NDVI est un indicateur numérique utilisant les bandes visibles et proches infrarouges du spectre électromagnétique. Utilisé pour analyser les résultats des mesures de télédétection et évaluer si la cible d'observation contient de la végétation verte vivante. Il quantifie la végétation en mesurant la différence entre le proche infrarouge (que la végétation reflète fortement) et la lumière rouge (que la végétation absorbe).

L'indice de végétation en télédétection est probablement l'un des indices les plus courants. L'application pratique de cet indice est incroyablement diverse, notamment pendant la quantification de l'approvisionnement forestier et utilisation comme indice de sécheresse. NDVI est très connu par sa sensibilité à la présence d'une végétation verte et par son efficacité pour le suivi des sécheresses (Boyd et al. 2002).

L'algorithme NDVI soustrait les valeurs de réflectances rouge du proche infrarouge et les divise par la somme des bandes proche infrarouge et rouge. Il est défini par la formule suivante :

$$NDVI = (NIR - RED)/(NIR + RED) \quad (2.24)$$

Où

NIR : lumière réfléchie dans le spectre proche infrarouge

RED : lumière réfléchie dans la gamme rouge du spectre

Cette formulation permet de tenir compte du fait que deux parcelles de végétation identiques peuvent avoir des valeurs différentes si l'une est, par exemple, en plein soleil et l'autre sous un ciel nuageux. Les pixels lumineux auraient tous des valeurs plus élevées, et donc une différence absolue plus importante entre les bandes. Ce problème est évité en divisant par la somme des réflectances. En théorie, les valeurs NDVI sont représentées sous la forme d'un rapport allant de -1 à 1, mais en pratique, les valeurs négatives indiquent de nuages, d'eau et de neige, les valeurs autour de zéro représentent le sol nu et les valeurs élevées représentent une végétation verte et dense.

- **Avantages de NDVI**

Les avantages de l'utilisation du NDVI pour la surveillance de la végétation sont notamment sa capacité à fournir des informations phénologiques sur le terrain à intervalles rapprochés à l'aide d'images satellite à haute résolution. Le NDVI est efficace pour évaluer la qualité de la végétation et peut être utilisé pour la classification de l'occupation des sols, en fournissant rapidement et avec précision des informations spatiales sur la surface de la terre.

- **Inconvénients de NDVI**

Les inconvénients de l'utilisation du NDVI sont liés à la couverture nuageuse, qui entraîne des lacunes dans les données.

2.6.11. Indice de Condition de la Végétation (VCI)

Le VCI, sert à évaluer les niveaux de sécheresse en surveillant la santé de la végétation grâce à des mesures de sa verdure. Cet indice permet de comprendre comment la végétation évolue dans le temps et dans l'espace, ce qui facilite l'évaluation de l'impact des variations climatiques sur celle-ci. Sa popularité repose sur sa fiabilité et son efficacité à repérer les périodes de sécheresse sur différents types de végétation. Le VCI est dérivé des données de l'indice de végétation normalisé (Normalized Difference Vegetation Index - NDVI), en utilisant la formule développée par Kogan en 1995.

$$VCI = \frac{(NDVI - NDVI_{min})}{(NDVI_{max} + NDVI_{min})} * 100 \quad (2.25)$$

Où :

NDVI représente le NDVI des années étudiées,

$NDVI_{min}$: La valeur minimum de la période étudiée,

$NDVI_{max}$: La valeur maximum de la période étudiée.

Le VCI est classé en cinq classes comme le montre le tableau ci-après (**Tableau 2.7**).

Tableau 2.7. Classification des degrés du VCI selon Kogan, 2003.

Degré VCI en (%)	Classes
$0 < \text{VCI} < 20$	Sécheresse extrême
$20 < \text{VCI} < 40$	Sécheresse sévère
$40 < \text{VCI} < 60$	Sécheresse modérée
$60 < \text{VCI} < 80$	Sécheresse faible
$80 < \text{VCI} < 100$	Pas de sécheresse

D'autres indices peuvent être aussi utilisés pour la caractérisation de la sécheresse. Le

Tableau 2.8 montre une liste non exhaustive de ces indices.

Tableau 2.8. Indices de sécheresse.

Indice de Sécheresse	Description
SWI – Indice de niveau d'eau normalisé	<ul style="list-style-type: none"> • Défini par Bhuiyan (2004) à l'Institut indien de technologie. • Utilisé dans des secteurs dans lesquels les cours d'eau présentent souvent des étiages saisonniers. • Calculs similaires à ceux du SPI, en remplaçant les précipitations par des données sur les eaux souterraines ou les niveaux dans les puits.
SRSI – Indice d'alimentation des réservoirs normalisé	<ul style="list-style-type: none"> • Mis au point par Gusyev et al. (2015) au Japon • L'indice tient compte de l'apport total et du stockage dans un réservoir précis ; il procure des informations utiles aux responsables municipaux de l'approvisionnement en eau et aux prestataires locaux de services d'irrigation. • Calculs similaires à ceux du SPI avec des données sur les réservoirs
SDI – Indice de sécheresse fondé sur l'écoulement fluvial	<ul style="list-style-type: none"> • Élaboré par Nalbantis et Tsakiris (2008) • L'indice sert à déceler et à suivre les épisodes de sécheresse à une station précise, qui n'est pas forcément représentative d'un plus large bassin. • Calculs similaires à ceux du SPI, en remplaçant les précipitations par des données sur l'écoulement.

2.7. Comparaison des indices de sécheresse

Plusieurs tentatives ont été faites pour comparer les indices afin de trouver les indices les plus adaptés aux objectifs spécifiques de surveillance de la sécheresse.

Dans les travaux de Guttman (1998) et Hayes et al. (1999), une comparaison entre SPI et PDSI a été réalisée. Ils ont montré que le SPI présente des avantages en termes de cohérence statistique et de capacité à décrire les impacts de la sécheresse à court et à long terme à travers les différentes échelles de temps des anomalies de précipitations. De plus, en raison de sa nature probabiliste intrinsèque, le SPI est le candidat idéal pour réaliser une analyse des risques de sécheresse. Il y a eu de nombreuses comparaisons entre le SPI et le PDSI pour la surveillance des sécheresses. Certaines des différences comprennent :

- Les caractéristiques particulières du PDI varient d'un site à l'autre (e.g. étude de cas aux États-Unis réalisée par Guttman (1999)), tandis que ceux de SPI ne varient pas d'un site à l'autre. En outre, le PDI a une structure complexe avec une mémoire exceptionnellement longue, tandis que le SPI est un processus de moyenne mobile simple et facile à interpréter. Par conséquent, le SPI peut être utilisé comme principal indice de sécheresse, parce qu'il est simple, spatialement invariant dans son interprétation, et probabiliste, il peut donc être utilisé dans l'analyse des risques et des décisions [Guttman, 1998].
- Le SPI est plus représentatif des précipitations à court terme que le PDSI et constitue donc un meilleur indicateur de l'humidité du sol. SPI est un meilleur prédicteur de la production agricole, car il représente l'état d'humidité meilleure qualité du sol [Quiring et Papakyriakou, 2003]. SPI fournit une meilleure standardisation spatiale que le PDSI en ce qui concerne les événements de sécheresse extrême [Lloyd-Hughes et Saunders, 2002].
- Basé sur 14 indices de sécheresse bien connus utilisant un ensemble pondéré de six critères d'évaluation, Keyantash et Dracup (2002) ont constaté que le SPI s'est révélé un précieux estimateur de la gravité de la sécheresse. Le SPI détecte le début d'une sécheresse plus tôt que le PDSI (une étude de cas : Texas, par Hayes et al. (1999)).
- Morid et al. (2006) ont comparé les performances de sept indices de sécheresse dans la province iranienne de Téhéran. Les indices comprenaient l'indice des déciles (DI), le pourcentage de la normale (PN), l'indice de précipitations standard (SPI), l'indice China-

Z (CZI), le CZI modifié (MCZI), le score Z et l'indice effectif de sécheresse (EDI). Les résultats ont montré que SPI, CZI et Z-Score ont des performances similaires en ce qui concerne l'identification de la sécheresse et réagissent lentement au début de la sécheresse. Le DI semble être très sensible aux événements pluvieux d'une année particulière, mais ses variations spatiales et temporelles sont incohérentes. Il a été constaté que le SPI et l'EDI sont capables de détecter de manière cohérente le début d'une sécheresse, sa variation spatiale et temporelle, et l'EDI s'est avéré plus réactif à la sécheresse émergente et plus performant.

Par ailleurs, on peut déduire que la performance des indices de sécheresse est spécifique à la région. Cela est dû à la fluctuation des variables météorologiques ainsi qu'aux caractéristiques du débit qui sont généralement utilisées pour dériver des indices.

2.8. Sécheresse dans le monde

Depuis quelques années, les organisations internationales tels que le PNUE (Programme des Nations Unies pour l'Environnement), l'Organisation des Nations Unies pour l'Alimentation et l'Agriculture (FAO), l'Organisation Météorologique Mondiale (OMM) et l'Organisation des Nations Unies pour l'Éducation et de la Culture (UNESCO) traitent des questions touchant la sécheresse, la dégradation des terres et la désertification.

Les sécheresses touchent un large éventail de zones géographiques. À l'échelle mondiale, 22 % des dégâts économiques causés par les catastrophes naturelles et 33 % des dégâts en termes de nombre de personnes touchées peuvent être attribués à la sécheresse [Iqbal et al. 2013].

Dans le continent africain, plusieurs pays sont touchés par la sécheresse. Par exemple dans le nord-africain, toutes les populations sont concernées, soit environ 150 millions de personnes. La partie sud de ces pays peuvent être gravement attaquées par la sécheresse climatique persistante. Les impacts de la sécheresse sont plus graves en Afrique subsaharienne, où l'agriculture pluviale représente 95 % de l'ensemble de l'agriculture. Cette dépendance à l'égard de l'agriculture pluviale rend l'Afrique subsaharienne vulnérable aux effets de la sécheresse. Par exemple, en 2009, de faibles précipitations ont entraîné une augmentation des sécheresses et une augmentation de 53 millions de personnes en situation d'insécurité alimentaire dans la région [Jayanthi et al. 2013].

Aussi, pour les pays de la zone sahélienne, tous les habitants environ 55 millions sont concernés pendant les grandes sécheresses des années 65-70. En Afrique Austral, la sécheresse de 1991-1992 a entraîné une réduction de 54% de la production céréale. Ce qui implique plus de 17 millions de personnes exposées à la famine.

La sécheresse de 2011 en Afrique de l'Est a provoqué des situations désastreuses dans plusieurs pays et a conduit à une famine généralisée et coûteuse dans la région.

2.9. Sécheresse en Algérie

L'Afrique est plus gravement touchée par la sécheresse que tout autre continent. Plus de 300 sécheresses ont été enregistrées au cours des 100 dernières années, représentant 44 % de toutes les sécheresses dans le monde. Récemment, l'Afrique subsaharienne a été dramatiquement touchée par des catastrophes climatiques de plus en plus fréquentes et graves.

L'Algérie, située en Afrique du Nord avec un littoral en bord de la Méditerranée, couvre une vaste superficie de 2 381 741 km². Le pays est fortement affecté par des problèmes de désertification et d'érosion des sols. Son climat varie de aride à semi-aride, bien qu'il prenne des nuances subtropicales humides dans certaines régions septentrionales. La géographie algérienne joue un rôle majeur dans la prévalence de la sécheresse. Le littoral, caractérisé par des collines fertiles, s'étend sur une étroite bande de seulement 150 km de largeur, bordé par la chaîne montagneuse du Tell Atlas, également appelé Petit Atlas. Cette région côtière capte la majorité des précipitations venant du nord, limitant ainsi l'arrivée de vents humides vers les régions des hauts plateaux et du sud.

L'historique des données climatiques en Algérie indique une persistance de la sécheresse, un phénomène naturel ancien qui a clairement conduit à la dégradation quantitative et qualitative des réserves d'eau du pays. Cette dégradation a eu un impact négatif significatif sur la satisfaction des besoins en eau dans divers secteurs socio-économiques, en particulier l'agriculture, tout en menaçant la préservation des écosystèmes terrestres et aquatiques. En Algérie, la sécheresse est principalement ressentie de manière plus prononcée sur les plans hydrologique et agricole. Au cours du siècle précédent, le pays a connu plusieurs périodes de sécheresse, parmi lesquelles les plus marquantes ont été observées en 1910 et en 1940, ainsi que de manière persistante dans les années 1975-80 et

au début du siècle actuel. L'analyse des données relatives aux apports en eau dans certains barrages durant les périodes 1945-98, 1945-75 et 1976-98 révèle une réduction de moitié des apports entre une période humide et une période sèche. Cette diminution témoigne de l'ampleur des sécheresses et de l'impact néfaste des changements climatiques qui en sont la cause.

La sécheresse actuelle perdure depuis déjà deux décennies, avec des conséquences particulièrement graves dans l'Ouest du pays. Cette tendance est soutenue par de nombreuses études scientifiques [Lazri et al. 2015 ; hamdad et al. 2023 ; Brahim et al. 2024]

2.10. Impacts de la sécheresse

La sécheresse représente un péril naturel dont les conséquences financières peuvent varier considérablement en fonction de son intensité. Son évaluation diffère selon les régions touchées. Souvent, la sécheresse engendre un ensemble complexe d'impacts, qu'ils soient directs ou indirects. Par exemple, la diminution des rendements agricoles est un impact direct, tandis que l'augmentation des prix des produits, résultant de la réduction des rendements, constitue un impact indirect de la sécheresse. Par conséquent, quantifier précisément le coût des pertes financières peut être difficile lorsque l'impact n'est pas directement imputable à la sécheresse.

Les impacts de la sécheresse se répartissent généralement en trois grandes catégories : environnementaux, économique et sociaux (voir **Figure 2.3**).

2.10.1. Impacts environnementaux

Les impacts environnementaux peuvent se traduire par des perturbations dans le cycle hydrologique d'une région, lorsque les conditions sèches sont prolongées, les eaux superficielles telles que les lacs, les rivières, les étangs, les ruisseaux et les lagunes s'assèchent, ce qui détruit les habitats naturels locaux. La sécheresse entraîne la perte de terres fertiles, ce qui entraîne la désertification. La qualité du sol est diminuée en raison de la diminution de l'activité organique et de la sécheresse, qui tue les organismes du sol. La migration des animaux, voire leur décès, peut résulter de leur recherche de nouveaux habitats vulnérables et menacés, entraînant une diminution de la biodiversité et des perturbations dans les écosystèmes naturels.

2.10.2. Impacts économiques

Les conséquences économiques englobent les pertes agricoles, lors des périodes de sécheresse, les agriculteurs sont contraints d'augmenter leurs dépenses budgétaires pour l'irrigation des cultures afin de préserver les rendements agricoles. La diminution des revenus dans le secteur touristique et chez les petites entreprises, Les économies qui dépendent largement de l'hydroélectricité sont confrontées à des pertes tant industrielles que gouvernementales, ainsi qu'à des coûts énergétiques plus élevés.

2.10.3. Impacts sociaux

Les impacts sociaux peuvent entraîner des problèmes de santé et des conflits liés à l'accès aux ressources en eau. L'éclosion de maladies causées par l'eau, la migration de populations et l'anxiété qui en découle ont des répercussions importantes sur la santé, notamment en exacerbant la faim, l'anémie, la malnutrition et le taux de mortalité.

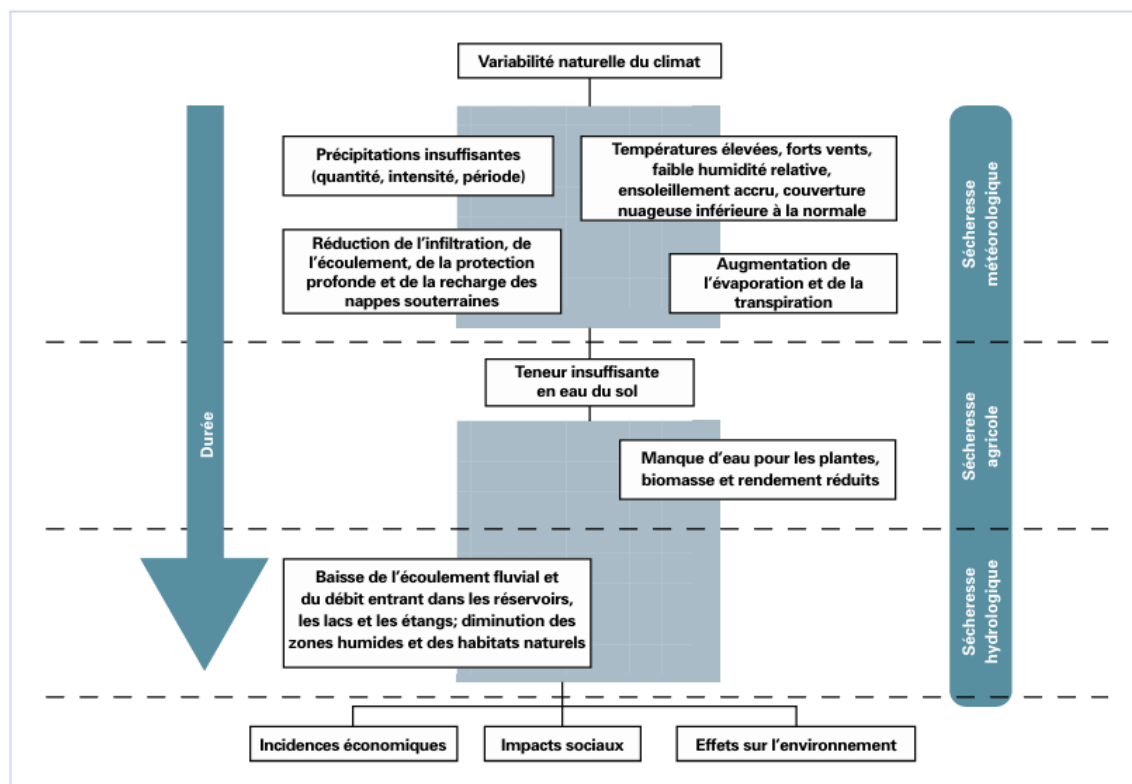


Figure 2.3. Causes et conséquences des sécheresses. [WMO 2006].

2.11. Discussion

A travers ce chapitre, nous avons mis en évidence le phénomène de sécheresse et ses répercussions graves dans divers domaines de la vie humaine. Comme nous l'avons évoqué, elle peut être déclenchée par des causes météorologiques, telles que les variations des précipitations et des températures, mais elle est également influencée par des facteurs humains tels que la gestion des ressources en eau et les pratiques agricoles. L'analyse de la sécheresse est cruciale pour comprendre et gérer ce phénomène complexe.

Les indices de sécheresse présentés dans ce chapitre sont des paramètres caractérisant et représentant la sécheresse. Ils contribuent ainsi à la quantification de niveau de sécheresse dans les régions étudiées. Cependant, ces indices montrent certaines limites pour une caractérisation complète de la sécheresse. Ainsi, les avantages et les inconvénients sont étudiés dans plusieurs travaux de recherche, et des compromis sont trouvés. Dans le cas de l'indice SPI, ces travaux ont mis en relief ses énormes avantages par rapport à l'utilisation des autres indices. Le SPI est basé sur un seul paramètre en l'occurrence les précipitations. Cet avantage est exploité dans plusieurs études où les différentes données météorologiques ne sont pas disponibles.

Pour faire face aux défis croissants de la sécheresse, il est important de développer des stratégies de gestion efficaces, particulièrement pour les régions à risque comme le cas de l'Algérie. Dans cette optique, la prévision de la sécheresse à court, moyen et long terme peut aider d'une façon significative à réduire ses effets désastreux. Pour ce faire, des modèles mathématiques sont mis au point pour tenter d'étudier et prédire la sécheresse. Ces modèles sont basés sur l'utilisation judicieuse des indices de sécheresse, tels que SPI, PN, PDSI, pour la prise de décision. Dans le prochain chapitre, nous présentons une synthèse sur les techniques employées pour l'analyse et la prédiction du phénomène de sécheresse.

Chapitre 3 Apprentissage automatique et méthodes d'analyse de la sécheresse

3.1. Préambule

L'amélioration des prédictions en utilisant les modèles climatiques mondiaux contribuera à atténuer et à mieux gérer les risques liés aux changements climatiques, y compris des phénomènes météorologiques catastrophiques. Dans cette optique, le phénomène de sécheresse qui s'étend et gagne du terrain se situe parmi les phénomènes les plus dévastateurs. L'analyse des séries temporelles et la prédiction du comportement de la sécheresse revêtent une importance considérable au sein de la communauté scientifique. La mise en place d'un système d'alerte précoce et la maîtrise des modèles de sécheresse futurs sont des outils essentiels. Afin de mieux appréhender ce phénomène, des modèles statistiques et ceux basés sur l'intelligence artificielle sont largement utilisés [Paulo et Pereira 2007 ; Lazri et al. 2015 ; Mokhtarzad et al. 2017 ; Hamdad et al. 2023]. Ces modèles sont basés sur l'analyse d'un ensemble d'indices caractérisant les sécheresses météorologiques que nous avons présentés précédemment. Ces dernières années, les travaux de recherches sont surtout orientés vers l'utilisation des modèles basés sur l'intelligence artificielle pour étudier la sécheresse. Les résultats obtenus ont montré des performances intéressantes [Khan et al. 2020 ; Altunkaynak et Jalilzadnezamabad 2021].

Le but de ce chapitre est de faire un état de l'art sur les méthodes employées pour l'analyse de la sécheresse appliquée à des cas réels à travers le monde. Nous avons classé ces méthodes selon les indices de sécheresse météorologique utilisés. Des méthodes statistiques et celles basées sur l'intelligence artificielle sont présentées en respectant l'ordre chronologique. Dans un premier temps, nous décrivons le concept de l'intelligence artificielle en mettant en évidence l'apprentissage automatique et l'apprentissage profond. Dans un second temps, nous discuterons des différentes techniques qui ont été appliquées dans la littérature ainsi que la portée de leurs résultats.

3.2. Intelligence Artificielle (IA)

Le processus de rendre les machines aussi intelligentes que le cerveau humain est appelé intelligence artificielle ; son émergence remonte aux années 1950. L'IA repose sur la création et l'application d'algorithmes exécutés dans un environnement informatique dynamique. Son but est de permettre à des ordinateurs de penser et d'agir comme des êtres humains, pour résoudre des phénomènes complexes. Afin de se rapprocher le plus possible du comportement humain, l'IA a besoin d'une quantité de données et d'une capacité de traitement élevées. Elle est utilisée dans de nombreux domaines tels que la météorologie, la santé, les finances et bien d'autres, pour améliorer les processus, optimiser les résultats et proposer des solutions innovantes et pertinentes. Elle utilise un large éventail de techniques, dont l'apprentissage automatique, et l'apprentissage profond. La **Figure 3.1** montre la position de l'apprentissage profond et l'apprentissage automatique par rapport à l'intelligence artificielle

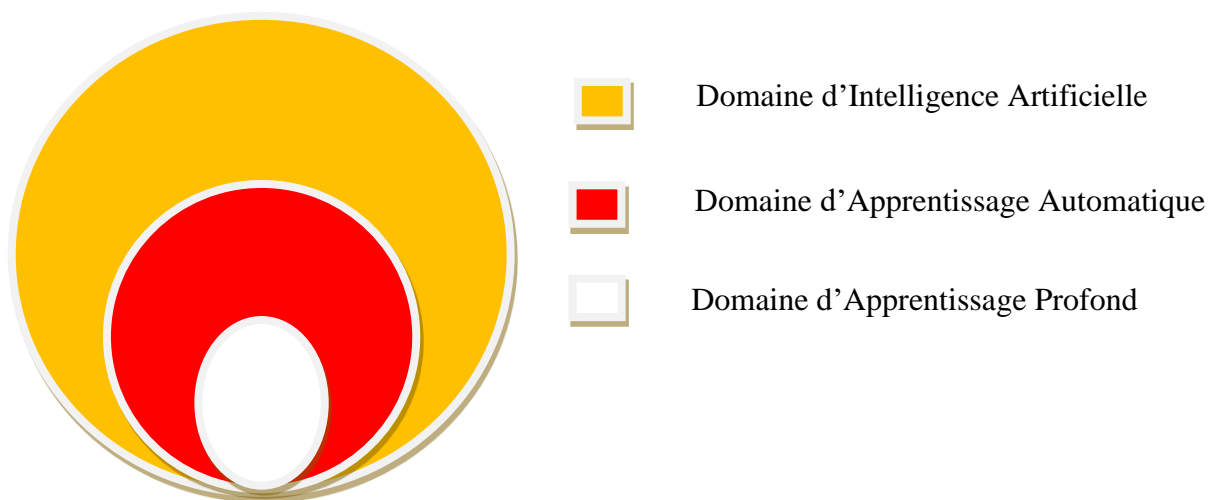


Figure 3.1. Illustration de la position de l'Apprentissage Profond et l'Apprentissage Automatique par rapport à l'Intelligence Artificielle.

L'utilisation d'outils d'intelligence artificielle montre des performances exceptionnelles, car ils prennent moins de temps et offrent une bonne précision [Zhang et al. 2016]. Malgré la flexibilité et l'adaptabilité de l'IA, des efforts considérables ont été déployés pour améliorer l'apprentissage automatique au cours des dernières décennies. Cela entraîne des attentes plus élevées des machines. L'apprentissage profond est une tentative dans cette direction.

3.2.1. Apprentissage Automatique (Machine Learning – ML)

L'Apprentissage Automatique (Machine Learning – ML en anglais) est la science qui permet aux ordinateurs d'apprendre sans être explicitement programmés. C'est la définition de l'apprentissage automatique selon son inventeur Samuel Arthur, un mathématicien américain qui a développé un programme pouvant apprendre tout seul comment jouer aux Dames en 1959.

En 1998, une définition un peu plus moderne du ML est donnée par un autre américain du nom de Tom Mitchell en énonçant qu'une machine apprend quand sa performance à faire une certaine tâche s'améliore avec de nouvelles expériences.

L'apprentissage automatique est un sous-domaine de l'IA. ML fait référence au développement, à l'analyse et l'implémentation de méthodes qui permettent à une machine d'évoluer grâce à un processus d'apprentissage, et ainsi d'accomplir des tâches qu'il est difficile ou impossible de réaliser par des moyens algorithmiques plus classiques. Il a pour objectif d'extraire et d'exploiter automatiquement l'information présente dans un jeu de données. Il est utilisé dans un large spectre d'applications pour doter des ordinateurs ou des machines de capacité d'analyser des données d'entrée. La **Figure 3.2** montre le schéma d'Apprentissage Automatique du modèle et son application.

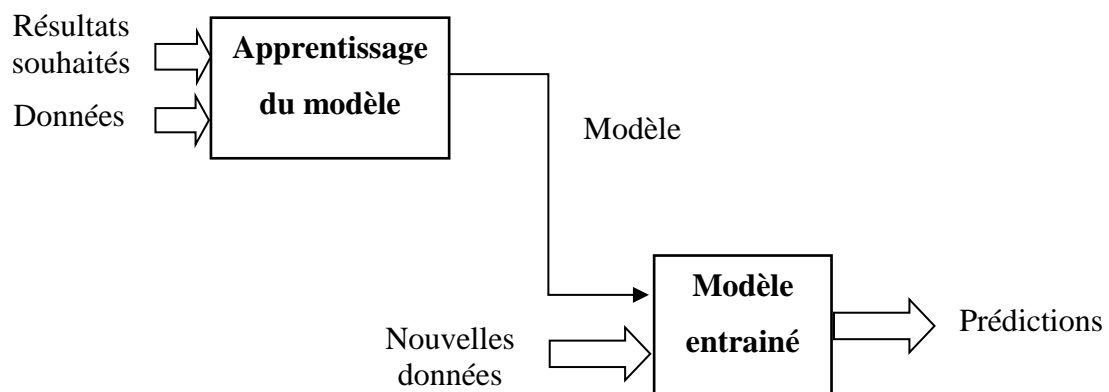


Figure 3.2. Apprentissage Automatique du modèle et son application.

3.2.1.1. Méthodes d'Apprentissage Automatique

Deux catégories d'algorithmes d'apprentissage automatique sont couramment utilisées, à savoir : l'apprentissage supervisé et l'apprentissage non supervisé.

a. Apprentissage supervisé

Les méthodes d'apprentissage supervisé représentent les algorithmes les plus répandus en apprentissage automatique. Ce processus implique l'utilisation d'échantillons de données, également appelés données d'entraînement, ainsi que de leurs étiquettes ou réponses correspondantes, tout au long du processus d'apprentissage. L'apprentissage supervisé consiste à trouver une correspondance entre les échantillons de données d'entrée et les sorties après avoir effectué plusieurs instances de données d'entraînement.

Par exemple, nous avons x comme variable d'entrée et y la variable de sortie. L'objectif d'un algorithme d'apprentissage supervisé est de trouver une fonction f de mise en correspondance de la variable d'entrée (x) avec la variable de sortie (y), c'est-à-dire une expression du type $y = f(x)$. Une fois la fonction est déterminée, nous pouvons facilement prédire la variable de sortie en utilisant des nouvelles données d'entrée (**Figure 3.3**).

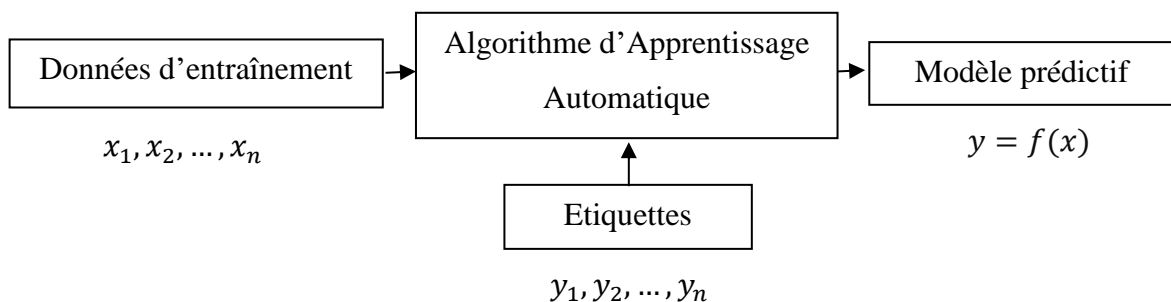


Figure 3.3. Processus d'un Apprentissage Automatique supervisé.

L'apprentissage supervisé peut être divisé en deux sous catégories : la classification et la régression.

- Les algorithmes de régression qui prédisent une valeur continue, une quantité.
- Les algorithmes de classification, qui prédisent une classe/catégorie.

L'apprentissage supervisé offre de nombreux avantages qui le rendent précieux dans divers domaines. Les algorithmes d'apprentissage supervisé sont capables d'apprendre des

modèles complexes et non linéaire, leur permettant ainsi de faire des prédictions plus précises. Il existe plusieurs modèles basés sur l'apprentissage automatique supervisé ; parmi les plus populaires on peut citer : les réseaux neuronaux artificiels [Rosenblatt 1958], les machines à vecteurs de support [Vapnik 1995], les arbres de décision [Quinlan 1986], les forêts aléatoires [Breiman 2001], et les k plus proches voisins [Cover et Hart 1967].

❖ **Réseau de neurones artificiels (Artificial Neural Network – ANN) :**

Principalement utilisés pour les algorithmes d'apprentissage en profondeur, les réseaux neuronaux traitent les données d'entraînement en imitant l'inter connectivité du cerveau humain par des couches de nœuds. Chaque nœud est composé d'entrées, de pondérations, d'un biais ou d'un seuil et d'une sortie. Si cette valeur de sortie dépasse un seuil donné, elle "déclenche" ou active le nœud, en transmettant les données à la couche suivante du réseau. Les réseaux neuronaux apprennent cette fonction de mappage par un apprentissage supervisé, en s'ajustant sur la base de la fonction de perte par le processus de descente de gradient. Lorsque la fonction de coût est égale à zéro ou proche de zéro, la précision du modèle peut être considérée comme assez fiable pour générer la bonne réponse [Rosenblatt 1958].

❖ **Machine à vecteur de support (Support Vector Machine – SVM) :**

Le SVM, développé par Vapnik en 1995, est un modèle d'apprentissage supervisé largement employé tant pour la classification que pour la régression des données. Principalement utilisé dans des problèmes de classification, il construit un hyperplan où la distance entre deux classes de points de données est maximale. Cet hyperplan sépare les classes de points de données de chaque côté, comme illustré dans la **Figure 3.4**.




Figure 3.4. Classification par SVM.

❖ **Arbre de décision (Decision Trees) :**

Un arbre de décision est un classifieur graphique sous forme d'un arbre. Il part généralement d'un nœud central d'où émergent différentes branches. Chaque branche mène à un autre nœud représentant une décision ou une opportunité découlant du nœud initial. Les branches représentent généralement l'action ou la réponse à une question, qui, si elle est prise, mènera au nœud suivant. Les différentes classes sont situées aux extrémités de branches représentées par les feuilles de l'arbre. Elles sont atteintes en fonction de décisions prises à chaque étape (voir **Figure 3.5**).




Figure 3.5. Schéma d'un arbre de décision.

❖ Forêts aléatoire (Random Forest – RF) :

Le RF est un algorithme qui a été proposé par Breiman (2001). Il effectue un apprentissage en parallèle sur de multiples arbres de décision construits aléatoirement et entraînés sur des sous-ensembles de données différents selon le principe du bagging. Les prédictions sont ensuite moyennées lorsque les données sont quantitatives ou utilisés pour un vote pour des données qualitatives, dans le cas des arbres de classification. La **Figure 3.6** illustre le schéma d'une forêt aléatoire.

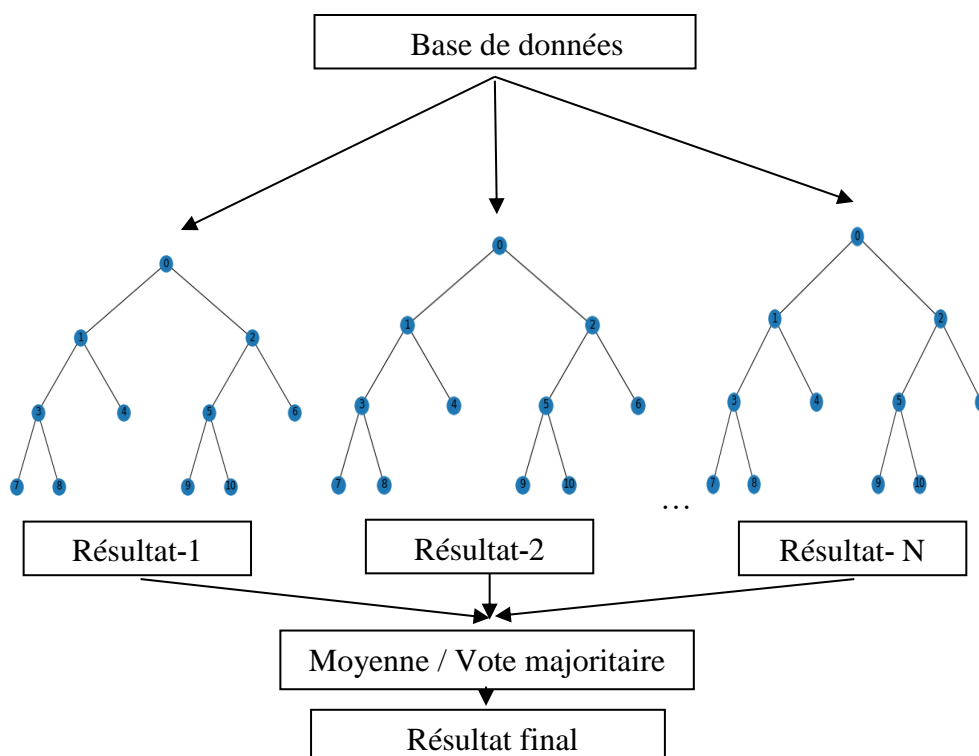


Figure 3.6. Schéma d'une forêt aléatoire.

❖ k plus proches voisins (k-Nearest Neighbors – k-NN) :

K-NN est une méthode utilisée pour résoudre des problèmes de classification ou de régression. Elle a pour principe de classer un nouvel échantillon dans la classe à laquelle appartiennent les k plus proches voisins dans l'espace des variables caractéristiques. Le principe de classification par K NN est illustré par la **Figure 3.7**.




Figure 3.7. Principe de classification par K-NN.

b. Apprentissage non supervisé

Les algorithmes d'apprentissage non supervisé sont conçus pour découvrir des structures cachées dans des ensembles de données non étiquetés, dans lesquels la sortie souhaitée est inconnue. L'objectif de l'apprentissage non supervisé est de trouver la structure sous-jacente d'un ensemble de données, de regrouper ces données en fonction de leurs similarités et de représenter cet ensemble de données dans un format compressé qui permet de réduire la complexité des données tout en préservant les informations essentielles. À aucun moment le système ne possède une connaissance absolue de la sortie correcte. Au lieu de cela, il infère ce que la sortie devrait être en se basant sur les ensembles de données disponibles. Il existe plusieurs méthodes d'apprentissage non supervisé parmi les plus populaires figurent l'algorithme K-means (K-moyennes) [MacQueen 1967] et l'analyse en composantes principales (ACP) [Pearson 1901]. La Figure 3.8 montre le processus d'un apprentissage non supervisé.




Figure 3.8. Processus d'un Apprentissage non-supervisé.

L'utilisation de l'apprentissage non supervisé peut être réunie en problèmes de clustering et d'association.

- **Clustering** : Un problème de clustering est un problème pour lequel on attend de la machine qu'elle rassemble sous forme de groupe (mise en cluster) des objets présents

dans des groupes de données, et ce de la manière la plus juste et efficace possible. Cette technique consiste à grouper des données non-étiquetées en fonction de leurs similarités et de leurs différences. Ainsi, les points sont rassemblés dans des groupes (ou des clusters) de telle manière à ce que les points au sein d'un même groupe soient le plus similaire possible, pendant que les points dans des groupes différents soient les plus différents possible. Pour cela, une analyse de cluster identifie les caractéristiques, au sein des données, et groupe les points en fonction de la présence ou de l'absence de ces caractéristiques. Un exemple d'algorithme très souvent utilisé dans le clustering est le K-means [MacQueen 1967].

- **Association** : Le système d'association permet de trier et regrouper les données qui peuvent être liées grâce à certaines caractéristiques. Le but est donc de trouver des objets liés les uns aux autres sans qu'il s'agisse d'objets identiques.

3.2.2. Apprentissage profond (Deep Learning – DL)

L'apprentissage profond est un sous-ensemble de l'apprentissage automatique qui utilise des réseaux neuronaux multicouches, appelés réseaux neuronaux profonds, pour simuler le pouvoir de décision complexe du cerveau humain. Il repose sur l'utilisation des réseaux de neurones artificiels organisés en plusieurs couches, interconnectées entre elles. La première couche correspond aux neurones d'entrée et la dernière transmet les résultats de sortie. Entre les deux se trouvent plusieurs couches intermédiaires par lesquelles l'information est traitée. Cette architecture est propre au Deep Learning et permet que chaque couche analyse de manière plus précise les données d'entrée.

Ainsi, plus le réseau de neurones artificiels est profond et donc contient plusieurs couches, plus le système peut effectuer des tâches complexes. Il est capable de déterminer par lui-même une représentation de ce qu'il reçoit, que ce soit une image ou un texte.

À chaque information intégrée, les connexions entre neurones s'étendent et se modifient. C'est pour cela qu'un système avec un IA à apprentissage profond a la capacité d'apprendre de nouvelles choses en autonomie. Il améliore également de lui-même ses prévisions et ses prises de décision, sans qu'aucune intervention humaine ne soit requise. Il a donc pour particularité d'apprendre de ses propres erreurs.

3.3. Prédiction de la sécheresse

De nombreux modèles dynamiques et statistiques de prédiction de la sécheresse ont été utilisés pour fournir des informations sur la sécheresse. Le choix et la construction d'un modèle de prédiction approprié constituent un défi majeur dans la prédiction des sécheresses. La littérature scientifique est riche d'études qui ont permis de suivre les sécheresses à partir des différents indicateurs. Ceux-ci permettent d'observer l'évolution des épisodes secs à différentes échelles temporelles et spatiales et sa probabilité de récurrence. Chaque approche présente ses avantages et ses inconvénients, et le choix du modèle le plus adapté dépend souvent des caractéristiques spécifiques des données ainsi que des objectifs de la prédiction.

Dans un premier temps, les méthodes employées pour réaliser des prédictions sur la sécheresse sont basées sur des modèles purement probabilistes, statistiques ou stochastiques, comme ARIMA (AutoRegressive Integrated Moving Average), SARIMA (Seasonal AutoRegressive Integrated Moving Average), les chaînes de Markov, etc. Ils exploitent les données météorologiques disponibles en calculant des indices qui caractérisent la sécheresse. En fonction des régions d'étude et les indices sélectionnés, les prédictions sont très bien corrélées avec les données observées. Avec l'apparition du concept de l'apprentissage automatique, des méthodes sont élaborées et appliquées à l'analyse de la sécheresse exploitant ce concept. Ainsi, la qualité des prédictions ont connu quelques améliorations. Toutefois, bien que le choix du modèle soit déterminant, les types d'indices de sécheresse sélectionnés contribuent aussi à l'amélioration de la qualité des prédictions.

Un état de l'art des méthodes utilisées pour la prédiction de la sécheresse est réalisé et discuté dans les sections suivantes. Ces méthodes sont classées selon l'indice ou les indices de sécheresses utilisés.

3.3.1. Méthodes de prévisions utilisant SPI

Le SPI est l'un des indices de sécheresse les plus utilisés dans la littérature, en raison de ces avantages. Les séries SPI peuvent être comparées dans l'espace et dans le temps, qui en ont fait un outil précieux pour évaluer et surveiller la sécheresse dans différentes régions du monde. Ainsi, plusieurs méthodes utilisant cet indice sont appliquées à la prédiction et à l'analyse de la sécheresse.

Mishra et Desai (2005) ont appliqué des modèles stochastiques linéaires connus sous le nom d'ARIMA, et des modèles multiplicatifs de moyenne mobile intégrée autorégressive saisonnière (SARIMA) pour prévoir les sécheresses à l'aide de séries d'indices SPI dans le bassin de la rivière Kansabati en Inde. Les résultats de prévisions ont été comparés aux données observées, montrant une bonne concordance jusqu'à une période d'exécution de deux mois, bien que la précision de la valeur prédite diminue au fur et à mesure que la période augmente. Une approche similaire a été élaborée et appliquée pour une région de la Turquie [Durdu 2010]. Les deux applications ont montré que ces modèles peuvent être efficacement utilisés pour prévoir la sécheresse sur une période de prévision maximale de deux mois.

Paulo et Pereira (2007) ont utilisé l'indice SPI sur une période de 67 ans pour étudier le phénomène de sécheresses dans la région de l'Alentejo, au Portugal. Pour ce faire, ils ont appliqué les chaînes de Markov pour prédire les transitions entre les niveaux de sévérité de la sécheresse jusqu'à trois mois à l'avance, utilisant à la fois des formulations homogènes et non homogènes. Leurs résultats indiquent l'efficacité particulière des formulations non homogènes, permettant de différencier les prédictions en fonction du mois initial considéré, tenant compte de l'influence du climat et de la saisonnalité des précipitations. Selon les auteurs, bien que promoteurs pour la gestion de la sécheresse, les résultats nécessitent des développements supplémentaires et devraient être complétés par d'autres outils prédictifs, qu'ils soient de nature stochastique ou physique. Ils ont également discuté les possibilités d'utilisation des prédictions de transition des classes de sécheresse pour la gestion des risques liés à la sécheresse.

Lazri et al. (2015) ont étudié le phénomène de la sécheresse dans le Nord de l'Algérie, en utilisant l'indice SPI pour identifier les classes de sécheresse (pas de sécheresse, sécheresse moyenne, sécheresse modérée, sécheresse sévère/extrême). Ils ont appliqué la méthode des chaînes de Markov, en construisant une matrice de probabilité de transition à partir des distributions de sécheresse. Les résultats de cette étude, révèlent une augmentation significative de la probabilité des sécheresses sévères ou extrêmes.

Khadr (2016) a développé divers modèles de Markov cachés (Hidden Markov Model HMM) utilisant l'indice SPI pour prédire la sécheresse. Une caractéristique notable du HMM est son indépendance conditionnelle en sortie, ce qui facilite la compréhension des statistiques à différentes échelles, du local au global. Les modèles HMM ont montré que le HMM a produit de bons résultats pour une période courte, mais la précision des prévisions

a diminué avec l'augmentation de la période de prévision. Cependant, le HMM a donné des performances satisfaisantes pour une période de 7 mois.

Mokhtarzad et al (2017) ont étudié la prédiction des sécheresses dans la province de Bojnourd en Iran, en utilisant l'indice SPI sur une échelle de trois mois. Pour cela, ils ont appliqués 3 modèles, à savoir le réseau neuronal artificiel, le système d'inférence neuro-floue adaptatif (Adaptive Neuro-Fuzzy Inference System – ANFIS) et machine à vecteurs de support. Une comparaison des performances de ces différents modèles, est réalisée. Les résultats ont montré que le modèle SVM offre des prévisions plus précises.

Liu et al. (2019) ont étudié la sécheresse dans la plaine de Chine du Nord, une région sujette à cette catastrophe climatique, en utilisant l'indice SPI sur une échelle de temps de 9 mois. La base de données utilisée est basée sur le taux de précipitations mensuelles de 1965 à 2015 dans cinq stations de la province de Shandong. Deux modèles ont été appliqués pour réaliser ces prediction. Les modèles utilisés sont le modèle ARMA et le modèle composite ARMA-GARCH. Le modèle GARCH est utilisé pour corriger l'hétéroscédasticité des résidus du modèle ARMA (voir annexe B). Une étude comparative des deux modèles a été réalisée, et les résultats ont montré que l'ARMA-GARCH offre une meilleure prédiction par rapport au modèle ARMA.

Hamdad et al. (2023) ont réalisé une analyse spatio-temporelle du phénomène sec/humide de la période des pluies dans le Nord de l'Algérie afin de prédire la sécheresse. Pour ce faire, ils ont utilisé des réseaux neuronaux artificiels pour analyser les processus ainsi que des chaînes de Markov pour une analyse comparative. Le phénomène sec/humide a été divisé en 9 classes basées sur l'indice SPI. Les données utilisées sont des estimations des taux de précipitations annuelles à partir des observations du satellite MSG sur une période allant de 1985 à 2021. Ils ont évalué les performances des deux méthodes en comparant leurs prévisions à court terme aux données réelles. Les résultats montrent que les prédictions obtenues sont en corrélation avec les données réelles, aussi bien pour la méthode de la chaîne de Markov que pour la méthode de réseaux de neurones. Des prédictions à long terme (de 2022 à 2050) du phénomène sec/humide en utilisant ANN et MC sont aussi réalisés. Les résultats aux simulations du modèle Phase 6 du Projet d'inter comparaison de modèles couplés (Coupled Multi-model Inter-comparison Project version 6 – CMIP6) sous le scénario socio-économiques partagées SSP126 (voir annexe A) Ils ont constaté que l'orientation générale des prédictions des trois modèles (ANN, MC et CMIP6) était similaire,

à savoir une expansion des zones sèches au détriment des zones humides, bien que des différences légères entre les modèles aient été observées.

3.3.2. Méthodes de prévisions utilisant KBDI

L'indice KBDI est fréquemment employé par les agences de gestion des incendies pour évaluer le risque d'incendie et orienter les décisions relatives aux restrictions d'utilisation du feu et aux mesures de prévention. De plus, il peut être utilisé par les gestionnaires des ressources en eau pour évaluer la disponibilité de l'eau dans les sols. A titre d'exemple, nous présentons la méthode développée par Salehnia et al (2018).

Salehnia et al (2018) ont montré l'utilité de l'Indice de Sécheresse Keetch-Byram (KBDI) dans un environnement semi-aride pour suivre les changements de végétation et les variations des rendements des cultures. Le KBDI, initialement conçu pour évaluer l'inflammabilité des forêts, se base sur le déficit d'humidité dans le sol. L'étude visait à établir une relation temporelle entre le KBDI et le NDVI (Indice de Végétation par Différence Normalisée) dérivé des données MODIS (Moderate Resolution Imaging Spectroradiometer) sur 16 jours, ainsi qu'à corrélérer le KBDI avec les rendements du blé et de l'orge sur une période allant de 1984 à 2010. Les résultats ont montré une corrélation saisonnière entre le KBDI et le NDVI, plus forte en milieu de saison de croissance. Cependant, cette corrélation était sujette à des variations selon les sites. Les régions plus chaudes et moins végétalisées ont présenté une association plus faible entre les deux indices. Tandis que, la corrélation entre l'Indice de sécheresse KBDI et le rendement des cultures céréalières d'hiver n'ait pas été significative, elle l'était en revanche pour les cultures de printemps.

3.3.3. Méthodes de prévisions utilisant PDI

L'indice PDI, qui mesure les conditions de sécheresse sur une échelle allant de l'humidité extrême à la sécheresse extrême, est largement appliqué dans divers domaines. Par conséquent, de multiples approches se servent de cet indice pour prédire et analyser la sécheresse, telles que :

Rao et Padmanabhan (1984) ont employé l'indice de sécheresse annuel et mensuel de Palmer (PDI) comme mesure de la sécheresse, ils ont appliqué des modèles stochastiques pour prévoir les séries de PDI. Leur analyse, se concentre sur les données de PDI pour l'Iowa (1930-1962) et le Kansas (1887-1962), couvrant une période incluant les graves sécheresses

des années 1930 aux États-Unis. En ajustant des modèles autorégressifs aux séries temporelles. Ils sélectionnent les modèles finaux en utilisant des règles de sélection de classe. Les caractéristiques statistiques des données observées sont comparées à celles générées par les modèles sélectionnés. Les résultats indiquent que les séries PDI peuvent être prévues avec une précision raisonnable, jusqu'à plusieurs mois avant qu'elles ne se produisent. Bien que les prévisions annuelles soient moins précises.

Altunkaynak et Jalilzadnezamabad (2021) ont développé une approche pour améliorer la prévision de l'indice de PDSI en utilisant la transformée en ondelettes discrète (Discrete Wavelet Transform – DWT) simultanément avec les modèles flous (Fuzzy models), k-NN et SVM. DWT décompose le signal en un ensemble d'ondelettes mutuellement orthogonales, ce qui permet une analyse à différentes échelles de résolution temporelle. Les méthodes, développées, appelées W-Fuzzy, W-kNN et W-SVM, utilisent la DWT pour décomposer les données PDSI en sous-séries, puis utilisent ces informations comme entrées pour les modèles de prévision. Évalués dans la région de Marmara en Turquie, ces modèles hybrides montrent une performance accrue par rapport aux modèles autonomes Fuzzy, kNN et SVM, en particulier jusqu'à une période de prévision de 6 mois. Les résultats indiquent que le modèle W-Fuzzy surpasse légèrement W-kNN et W-SVM en termes de précision de prédiction, évaluée par des indicateurs tels que l'erreur quadratique moyenne (EQM), le coefficient d'efficacité (CE) et le coefficient de détermination (R^2).

3.3.4. Méthodes de prévisions utilisant SPEI

L'indice SPEI est un outil précieux pour évaluer les conditions de sécheresse ou d'humidité en prenant en compte à la fois les précipitations et l'évapotranspiration. Voici quelques exemples de méthodes qui ont recouru à cet indice :

Tian et al. (2018) ont mené une étude visant à analyser la relation entre l'humidité du sol et la sécheresse agricole dans le bassin de la rivière Xiangjiang. Ils ont utilisé l'indice de précipitation-évapotranspiration (SPEI) pour caractériser les sécheresses agricoles et ont développé un modèle de régression à vecteurs de support (Support Vector Regression SVR) intégrant les indices climatiques pour prédire ces sécheresses. L'analyse a identifié l'indice SPEI à six mois comme le plus représentatif de l'humidité du sol par rapport aux indices à trois et un mois. Le point de crête de l'anticyclone subtropical du Pacifique occidental (Western Pacific Subtropical High – WPSH) a été identifié comme le facteur clé influençant

la sécheresse agricole, principalement en contrôlant la température régionale. L'utilisation du modèle SVR avec les indices climatiques, notamment le point de crête du WPSH, a amélioré la précision des prédictions de la sécheresse agricole de manière significative, avec une augmentation mesurée par le coefficient d'efficacité de Nash Sutcliffe (NSE) de 4,4 % en entraînement et de 5,1 % en test pour une période de trois mois. L'amélioration était plus prononcée pour les prévisions à un mois d'avance (15,8% en entraînement et 27,0% en test) que pour celles à trois mois. Cependant, les chercheurs ont souligné la nécessité de sélectionner avec prudence les paramètres d'entrée, car l'ajout d'informations redondantes pourrait compromettre la qualité des prédictions.

Khan et al. (2020) ont réalisé une étude sur le développement de modèles de prévision de la sécheresse au Pakistan en utilisant trois techniques d'apprentissage automatique avancées : Machine à vecteur de support, Réseau de neurones artificiels, k plus proches voisins. Ils ont évalué et prédit trois catégories de sécheresses (modérées, sévères et extrêmes) en se basant sur l'indice SPEI et en utilisant des données provenant de la base de données de réanalyse, Centres nationaux de prévision environnementale / Centre national de recherche atmosphérique (NCEP/NCAR). Une approche innovante de sélection des caractéristiques, appelée Recursive Feature Elimination (RFE), a été utilisée pour identifier les ensembles optimaux de prédicteurs. Les modèles basés sur SVM ont démontré une meilleure capacité à prédire les caractéristiques temporelles et spatiales des sécheresses au Pakistan par rapport à ceux basés sur ANN et KNN. Les performances de KNN étaient limitées par rapport aux autres modèles lors de la validation. Les résultats ont également mis en évidence les corrélations positives entre l'indice SPEI et l'humidité relative ainsi que d'autres variables climatiques dans différentes régions pendant les saisons Rabi (printemps) et Kharif (automne). Selon les auteurs, ces conclusions mettent en évidence l'importance de prendre en compte des facteurs tels que l'humidité relative, la température et la vitesse du vent dans le développement de modèles de prévision de la sécheresse au Pakistan. Cette nécessité est particulièrement pertinente pour une zone géographique incluant plusieurs régions telles que la mer Méditerranée, la mer Caspienne, l'océan Indien et la mer d'Arabie.

3.3.5. Méthodes de prévisions utilisant EDI

L'EDI est un indice souvent utilisé pour estimer les besoins en eau des cultures et pour planifier l'irrigation de manière efficace. Il prend en compte des facteurs tels que la température, l'humidité, la vitesse du vent et l'insolation pour calculer la quantité d'eau qui

serait perdue par évaporation et transpiration dans des conditions optimales. En conséquence, il existe plusieurs méthodes qui font usage de cet indice, telles que :

Mondol et al. (2021) ont étudié l'impact du changement climatique sur les sécheresses au Bangladesh en utilisant EDI. Leur analyse des données météorologiques de 1979 à 2018 a révélé une augmentation de la fréquence des sécheresses saisonnières et annuelles, principalement pendant la mousson. Les sécheresses ont également débuté plus tôt et se sont prolongées après la saison des pluies. Les régions de Barind ont connu des pics d'intensité de sécheresse plus élevés que la plaine inondable de Teesta, avec une augmentation significative de la fréquence et de la gravité des sécheresses modérées à sévères. Bien que l'EDI soit corrélé à l'Indice de Précipitations Normalisé (SPI), la production de riz ne semble pas directement affectée par les sécheresses météorologiques identifiées. Les auteurs suggèrent l'existence d'autres facteurs influençant le rendement du riz, tels que les infrastructures d'irrigation et les stratégies de gestion. Les résultats de l'étude mettent en évidence la nécessité d'adapter les pratiques agricoles pour faire face aux défis croissants liés au changement climatique.

Kamruzzaman et al (2019) ont étudié les sécheresses agricoles au Bangladesh sur une période de 35 ans à l'aide de données de précipitations mensuelles provenant de 27 stations météorologiques. L'indice EDI est utilisé pour évaluer les conditions de sécheresse dans quatre sous-régions du pays. En comparant cet indice avec les enregistrements historiques de sécheresse. Les résultats montrent une augmentation de la sévérité globale des sécheresses au cours de la période étudiée, avec une vulnérabilité accrue dans les régions de l'Ouest et du centre du pays. Les régions du Sud-Ouest sont plus sujettes aux sécheresses extrêmes, tandis que la région centrale est plus touchée par les sécheresses sévères. Les zones côtières du Sud-Ouest ainsi que du centre et du nord-ouest sont plus affectées par les sécheresses de longue durée. De plus, la fréquence des sécheresses dans toutes les catégories a augmenté significativement de 2011 à 2015. Les régions du Nord-Ouest connaissent des sécheresses extrêmes pendant les saisons humides et sèches, tandis que les régions du centre et du Nord subissent des périodes de sécheresse de manière régulière, avec des épisodes de sécheresse qui se produisent de façon répétée au fil des saisons et des années. La région centrale, en particulier, montre une tendance à l'augmentation de la zone touchée par la sécheresse, surtout avant la mousson. En conclusion ; les résultats de cette étude offrent des données importantes pour les responsables gouvernementaux qui sont chargés de gérer les

sécheresses. En analysant les tendances des sécheresses dans diverses zones géographiques, ainsi que les moments où elles sont les plus fréquentes et les plus sévères, les responsables sont en mesure de mieux appréhender les défis associés à la sécheresse. Ces informations permettent alors de concevoir des stratégies adaptées pour atténuer ses effets néfastes.

3.3.6. Méthodes de prévisions utilisant NDVI

Le NDVI est un indice utile pour surveiller les changements de couverture végétale, la santé des cultures, la déforestation, la désertification et d'autres phénomènes environnementaux. Il varie de -1 à 1, où les valeurs plus élevées indiquent une végétation plus dense et en meilleure santé, tandis que les valeurs plus basses indiquent une végétation moins dense ou stressée. Voici un exemple concret d'une méthode intégrant l'indice susmentionné :

Sruthi et Mohammed Aslam (2015) ont mené une étude visant à analyser le stress de la végétation dans le district de Raichur, au Karnataka, en Inde. Ils ont utilisé des données du Radiomètre spectral pour imagerie de résolution moyenne (MODIS) pour calculer l'indice de végétation normalisé (NDVI) et la température de surface de la terre (Land Surface Temperature – LST). Leur objectif principal était de fournir une surveillance précise de la sécheresse agricole et un système d'alerte précoce pour les agriculteurs de la région. En analysant la corrélation entre la LST et le NDVI, ils ont observé une forte corrélation négative entre ces deux paramètres. Plus précisément, ils ont trouvé une corrélation de -0,635 pour l'année 2002 et de -0,586 pour l'année 2012. Cette corrélation significative entre la LST et le NDVI indique que la température de surface de la terre peut être utilisée comme indicateur pour détecter la sécheresse agricole dans la région étudiée.

3.3.7. Méthodes de prévisions utilisant VCI

L'indice VCI est utilisé pour évaluer l'état de santé et de vigueur de la végétation à partir de données satellitaires. Il est largement utilisé dans la télédétection et la surveillance environnementale, en particulier pour suivre les conditions de la végétation dans des régions sujettes à la sécheresse, à la déforestation ou à d'autres changements environnementaux. Voici un exemple concret d'une méthode qui met en œuvre cet indice :

Liang et al (2021) ont analysé les conditions de sécheresse végétative printanière en Chine sur une période de 1981 à 2015 en utilisant l'Indice VCI comme indicateur principal.

Leur analyse révèle que la sécheresse végétative printanière, en particulier la sécheresse modérée, est courante en Chine et présente des différences géographiques marquées, fortement influencées par les moussons. Les résultats indiquent une fréquence relativement élevée de sécheresse végétative printanière dans les régions du Sud et du Nord, fortement touchées par les moussons, tandis qu'elle est relativement faible dans les régions du Nord-Ouest et du Qinghai-Tibet, moins affectées par les moussons. Au cours de la période étudiée, l'indice VCI en Chine a généralement augmenté, mais cette tendance n'était pas linéaire. Elle présentait plutôt une tendance en forme de vague, se décomposant en quatre étapes distinctes : une croissance lente de 1981 à 1990, des fluctuations intenses de 1991 à 2000, une croissance régulière de 2001 à 2010, et enfin une descente lente après 2010. Les analyses statistiques, telles que le test de Mann-Kendall, qui a pour but d'évaluer statistiquement s'il existe une tendance monotone à la hausse ou à la baisse de la variable d'intérêt dans le temps, a confirmé une tendance à la hausse significative de l'indice VCI en Chine, avec des changements significatifs observés dans les régions du Sud, du Nord-Ouest et du Qinghai-Tibet. Des mutations ont été observées vers 1992 dans les régions du Nord-Ouest et du Qinghai-Tibet, et vers 2000 dans la région Sud. De plus, l'analyse des séries chronologiques par ondelettes a révélé des oscillations à courte période (5 à 7 ans) et à longue période (environ 23 à 28 ans) de la sécheresse printanière de la végétation en Chine, avec des dominances variables selon les régions, en fonction de leur exposition aux moussons.

3.3.8. Méthodes de prévisions utilisant des indices combinés

La combinaison des indices de sécheresse permet d'obtenir une évaluation plus complète et précise des conditions de sécheresse, ce qui facilite la prise de décisions éclairées en matière de gestion des ressources en eau, d'agriculture, de prévention des incendies de forêt, et d'autres domaines sensibles aux variations climatiques. À cet effet, diverses méthodes ont utilisé cette combinaison d'indices, comme par exemple :

Aghakouchak et al. (2015) présentent une méthodologie pour prédire la sécheresse en utilisant un cadre basé sur le concept de prévision ensembliste du débit (Ensemble Streamflow Prediction – ESP), tout en prenant en compte plusieurs variables et indices de sécheresse. Ils utilisent l'indice de sécheresse normalisé multivarié (Multivariate Standardized Drought Index – MSDI), qui intègre les précipitations et l'humidité du sol pour décrire la sécheresse. Leur approche combine le concept ESP pour prévoir les changements saisonniers des précipitations et de l'humidité du sol, puis estime le MSDI basé sur la

probabilité conjointe des précipitations cumulées prévues et de l'humidité du sol. Ce modèle probabiliste fournit à la fois une mesure de la gravité de la sécheresse et une probabilité d'occurrence. Testé sur une partie de la sécheresse de 2011 en Afrique de l'Est, en utilisant les données de précipitations et d'humidité du sol de MERRA-Land, les résultats montrent que les prédictions multi-indices sont cohérentes avec les observations, ce qui ouvre la voie à une éventuelle utilisation pour la mise en place d'un système d'alerte précoce probabiliste de la sécheresse dans la région.

Bayissa (2018), dans son étude en Éthiopie, en particulier dans le bassin du Haut Nil Bleu (Upper Blue Nil – UBN), a intégré plusieurs indices météorologiques pour surveiller efficacement différents types de sécheresse. Cette combinaison appelée CDI (Combined Drought Index) est conçu pour fournir des informations précises sur l'occurrence des sécheresses et faciliter la prise de décision en matière de gestion de la sécheresse. De plus, dans cette étude, un modèle de prédiction basé sur la régression des anomalies de rendement des cultures pour le bassin de l'UBN est appliqué. Les résultats montrent que le CDI et le modèle de régression sont efficaces pour détecter les événements de sécheresse historiques dans la région d'étude. La conclusion tirée de cette étude, indique que cette approche pourrait être utile pour améliorer la surveillance de la sécheresse et soutenir la prise de décision pour atténuer les effets néfastes de la sécheresse dans la région.

Brahim et al. (2024) ont mené une étude sur l'évaluation de la sécheresse dans le bassin Cheliff-Zahrez, caractérisé par un climat semi-aride avec des précipitations annuelles moyennes allant de 80 à 600 mm/an. La recherche a introduit un nouvel indice de probabilité de dépassement de la sécheresse (DEPI) avec des indices reconnus tels que l'indice SPI et l'indice EDI sur différentes échelles de temps (3, 6, 9, 12 et 24 mois). L'analyse s'est concentrée sur les données de précipitations mensuelles de septembre 1970 à août 2015, et indique une baisse générale, surtout entre 1970 et 1980, confirmée par le test de Mann-Kendall. Les indices SPI et EDI révèlent une sécheresse prolongée de janvier 1970 à mars 2010, avec des pics de sévérité atteignant -3. Cependant, l'indice DEPI identifie des périodes de sécheresse variables entre mars 1980 et décembre 2010. Les comparaisons entre les différents indices montrent une forte variabilité, avec des coefficients de détermination variant de 10 % à 90 % pour des échelles temporelles de 3 à 24 mois. En conclusion, la relation entre SPI/EDI et DEPI s'avère insignifiante, soulignant l'importance de ces résultats pour la gestion intégrée et durable des sécheresses et des pertes agricoles.

Tayfur et Alami (2022) ont évalué la sécheresse dans les stations de Lashkargah, Farah, Adraskan et Gardandiwal dans le bassin de la rivière Helmand (HRB) en Afghanistan sur une période de 37 ans, de 1979 à 2015. Les chercheurs utilisent différentes méthodes d'indice de sécheresse, telles que l'indice de précipitations normalisé (Normal-SPI, Log-SPI et Gamma-SPI), le pourcentage de normalité (PN) et les déciles. Toutes les méthodes sont appliquées aux données annuelles de précipitations à long terme. Les résultats indiquent que le log-SPI et le gamma-SPI prédisent des conditions de sécheresse extrême, tandis que le normal-SPI identifie des conditions humides et moins sèches. Les méthodes PN et Déciles prédisent plus d'années de sécheresse que les méthodes SPI, et la méthode des déciles montre une période de sécheresse extrême et sévère plus longue que les autres méthodes. Différentes intensités de sécheresse sont observées en 1985, 1987, 1994, 1997, 1999, 2000, 2001, 2002, 2003 et 2004 dans toutes les stations, confirmant les rapports de sécheresse enregistrés pour la région. Les conditions de sécheresse extrême en 2001 dans toutes les stations confirment les rapports de sécheresse enregistrés pour la même région. Les auteurs recommandent l'utilisation du log-SPI et du gamma-SPI comme indices de surveillance de la sécheresse pour le bassin de la rivière Helmand, car ils prédisent avec succès les périodes historiques de sécheresse extrême et sévère.

3.4. Discussion

Dans ce chapitre, nous avons présenté un ensemble de méthodes utilisées dans l'analyse et la prévision de la sécheresse. Ces dernières années, les modèles basés sur l'apprentissage automatique prennent le dessus par rapport aux modèles probabilistes, stochastiques ou statistiques, bien que ces modèles soient toujours performants. La description effectuée dans ce chapitre prend en compte la spécificité des indices de sécheresse. En fonction des données météorologiques disponibles, ces indices sont sélectionnés. Le choix de ces indices dépend aussi du type de sécheresse à étudier. Dans le cas de sécheresse météorologique, le SPI est très largement utilisé en étant un unique indice ou combiné à d'autres indices selon la disponibilité des données. Comme nous avons pu le constater, cette utilisation massive de SPI est due au fait que la caractérisation de la sécheresse puisse se faire en se basant uniquement sur les données de précipitations. De plus, l'emploi de SPI n'a pas de limite géographique et peut être intégré dans l'analyse de la sécheresse dans n'importe quelle région du monde.

D'après l'état de l'art que nous avons réalisé, les performances des techniques ne dépendent pas forcément des modèles employés, aussi bien pour ceux basés sur l'apprentissage automatique que pour les modèles probabilistes, stochastiques ou statistiques. Toutefois, des légères différences sont rapportées dans quelques travaux en mettant en évidence l'apport de l'apprentissage automatique. Les discussions sont controversées, et restent donc ouvertes sur la portée des prédictions données par ces modèles.

Dans cette optique, dans le prochain chapitre, nous réalisons une étude comparative entre deux modèles appliqués à l'analyse de la sécheresse, à savoir les chaînes de Markov basées sur les probabilités et les statistiques, et les réseaux de neurones basés sur l'apprentissage automatiques. Compte tenu des avantages de l'indice de sécheresse SPI, dans les deux modèles, nous utilisons cet indice.

Chapitre 4 Analyse de la sécheresse en utilisant CM et RNA

4.1. Préambule

Dans ce chapitre, nous présentons une analyse spatio-temporelle du phénomène sec/humide dans le Nord de l'Algérie pour prédire les situations de sécheresse. Le phénomène sec/humide correspond à la quantité des précipitations annuelles tombées dans la région d'étude. Nous avons donc implémenté les réseaux neuronaux artificiels (RNA) pour analyser l'évolution du phénomène. Pour une étude comparative, nous avons aussi analysé le comportement du phénomène sec/humide en utilisant les chaînes de Markov (CM). Le phénomène sec/humide est divisé en 9 catégories obtenues en fonction des valeurs de l'indice SPI. La base de données utilisée est construite à partir des estimations satellitaires des taux de précipitations annuelles sur une période allant de 1985 à 2021.

Nous donnons dans un premier temps les concepts mathématiques des chaînes de Markov et les réseaux de neurones. Ensuite, nous appliquons les deux modèles pour l'analyse et la prédiction du phénomène. Dans un second temps, pour évaluer les performances des deux méthodes, des prédictions à court terme ont été déterminées et comparées aux données satellitaires réelles. Aussi, les résultats de la prédiction à long terme du phénomène sec/humide réalisée par RNA et CM sont comparés aux simulations données par la Phase 6 du Projet d'inter comparaison de modèles couplés CMIP6 (Coupled Model Inter comparison Project Phase 6).

4.2. Matériels et méthodes

Deux techniques, à savoir les réseaux neuronaux artificiels et les chaînes de Markov, sont utilisées pour analyser le phénomène sec/humide dans le Nord de l'Algérie. La première est basée sur l'apprentissage automatique et la seconde est une méthode statistique. Pour mieux décrire notre méthodologie, nous avons opéré selon les étapes suivantes :

- Caractérisation du phénomène sec/humide.
- Données utilisées.
- Concept mathématique des chaînes de Markov et de RNA.
- Apprentissage de RNA et calcul des chaînes de Markov.

4.2.1. Caractérisation du phénomène sec/humide

Pour analyser le phénomène sec/humide à l'aide de RNA et de CM, nous avons converti notre base de données (taux de précipitations annuelles à l'échelle du pixel, voir section 4.2.2) en informations SPI. L'indice SPI proposé par McKee et al. (1993) et Paulo et Pereira (2007) mesure le niveau de la sécheresse météorologique. L'indice SPI est largement utilisé pour indiquer le degré de sécheresse en raison de ses avantages [Hayes et al. 1999] ; entre autres, l'indice SPI est basé sur un seul paramètre qui est la précipitation. L'évaluation de la sécheresse est donc possible même si d'autres mesures hydrométéorologiques ne sont pas disponibles.

L'un des avantages de SPI est qu'il peut être utilisé dans les régions climatiques du monde sans être affecté par les différences géographiques [Hayes et al. 1999]. L'Organisation météorologique mondiale [WMO 2006] a recommandé l'indice SPI pour la surveillance et la caractérisation de la sécheresse. L'indice SPI est calculé sur la base des précipitations accumulées sur différentes échelles de temps [Edwards et McKee 1997]. Il convient donc à l'identification de tous les types de sécheresse, tels que les sécheresses météorologiques, les sécheresses hydrologiques, les sécheresses agricoles et les sécheresses socio-économiques. En outre, elle est tout aussi efficace pour analyser les périodes et les cycles humides [de Oliveira-Júnior et al. 2021 ; CEDO 2020].

Dans notre cas, les valeurs de l'indice SPI sont calculées en utilisant les estimations des précipitations déterminées à partir des observations par satellite situées dans la zone d'étude (Nord de l'Algérie). Le SPI est exprimé mathématiquement selon l'équation (4.1) [McKee et al.1993] :

$$SPI = \frac{(P_i - P_m)}{S} \quad (4.1)$$

Avec

P_i : la quantité de précipitations pour l'année i ;

P_m : la quantité moyenne de précipitations pour la série sur l'échelle de temps considérée (35 ans) ;

S : l'écart-type de la série sur l'échelle de temps.

Un SPI de valeur 0 indique une quantité normale de précipitations. L'indice est négatif pour les situations sèches, et il est positif pour les situations humides [McKee et al. 1993]. Cependant, pour les cas de situation de sécheresse ou d'humidité, il est possible de les diviser en plusieurs classes. Nous avons donc classé le phénomène sec/humide selon les valeurs de l'indice SPI en 9 classes (voir **Tableau 4.1**).

Tableau 4.1. Catégorisation du degré du phénomène sec/humide en fonction des indices standardisés de précipitations.

Valeurs de SPI	Situation sec/humide	Classes (Catégories)
$SPI > 2$	Extrêmement humide	SPI9
$1.5 < SPI \leq 2$	Sévèrement humide	SPI8
$1 < SPI \leq 1.5$	Modérément humide	SPI7
$0 < SPI \leq 1$	Légèrement humide	SPI6
$SPI = 0$	Normale	SPI5
$-1 \leq SPI < 0$	Légèrement sec	SPI4
$-1.5 \leq SPI < -1$	Modérément sec	SPI3
$-2 \leq SPI < -1.5$	Sévèrement sec	SPI2
$SPI < -2$	Extrêmement sec	SPI1

4.2.2. Données utilisées

Pour analyser et prédire le comportement du phénomène sec/humide, nous avons construit une base de données constituées des estimations des précipitations annuelles à l'échelle du pixel sur le Nord de l'Algérie de 1985 à 2021. Pour ce faire, les images satellitaires obtenues à partir de Meteosat première génération (MFG : Meteosat First Generation en anglais) (1985-2005), puis de Meteosat deuxième génération (MSG en anglais) (2006-2021) ont été utilisées pour l'estimation des précipitations. La méthode utilisée pour les estimations des précipitations est basée sur l'apprentissage automatique combinant 6 modèles [Lazri et al. 2020] appliquée aux données MSG, et également ajustée pour être utilisée dans le cas des données MFG. Ainsi, des cartes annuelles des taux de précipitations sont obtenues et utilisées dans le cadre de cette étude.

Comme mentionné précédemment, nous avons eu recours à des observations par satellite en raison du manque de données provenant de pluviomètres ou de radars météorologiques pour couvrir l'ensemble de la zone d'étude (voir **Figure 4.1**). La résolution spatiale du MSG pour le point le plus proche du satellite est de $3 \times 3 \text{ km}^2$. Sur le Nord de l'Algérie, la résolution spatiale atteint environ $4 \times 5 \text{ km}^2$ (pixel). Dans le cas de MFG, la résolution peut atteindre $8 \times 9 \text{ km}^2$.

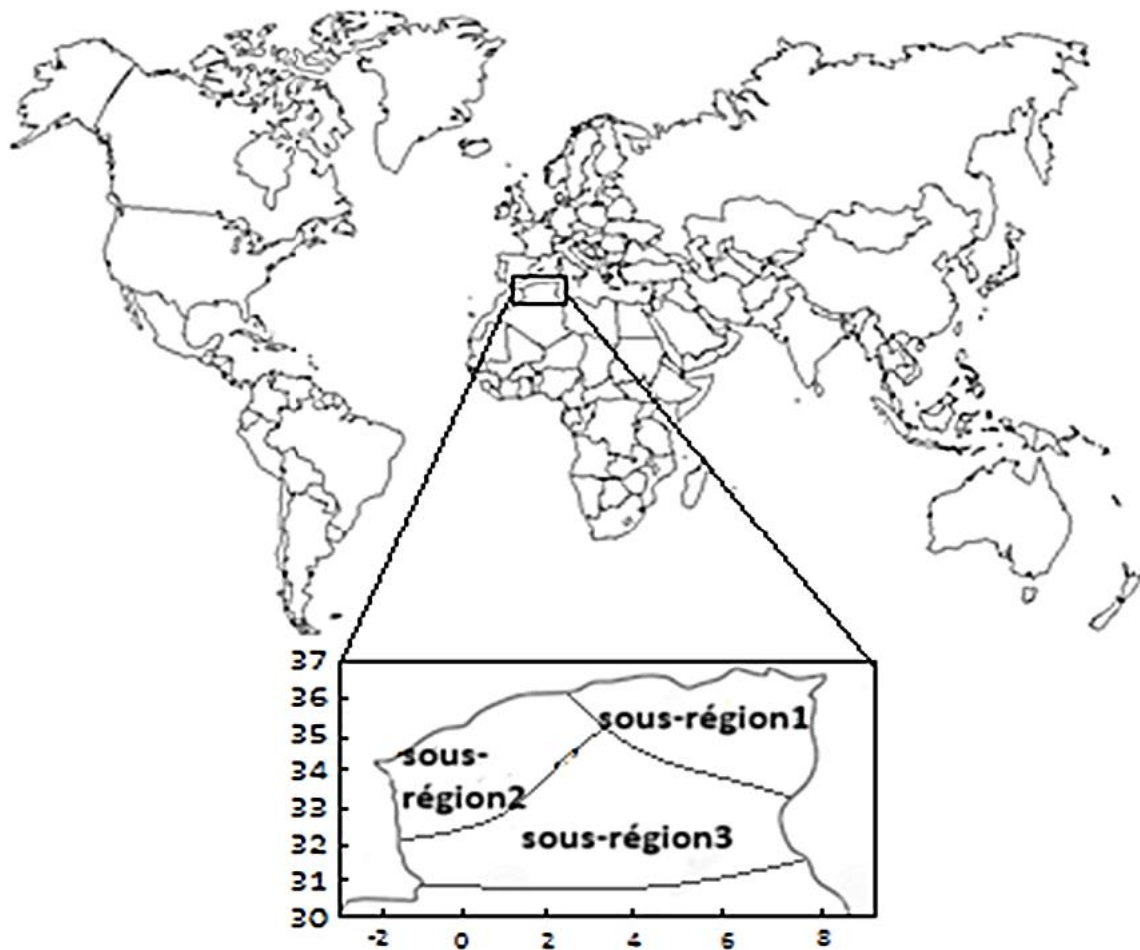


Figure 4.1. Région d'étude (Nord de l'Algérie).

Afin d'optimiser les prévisions, la région étudiée de $582\,320 \text{ km}^2$ est divisée en trois sous-régions dont le climat est relativement hétérogène d'après les données climatiques historiques.

Dans le **Figure 4.2**, nous donnons quelques situations chronologiques de précipitations annuelles converties en classes SPI dans le nord de l'Algérie.

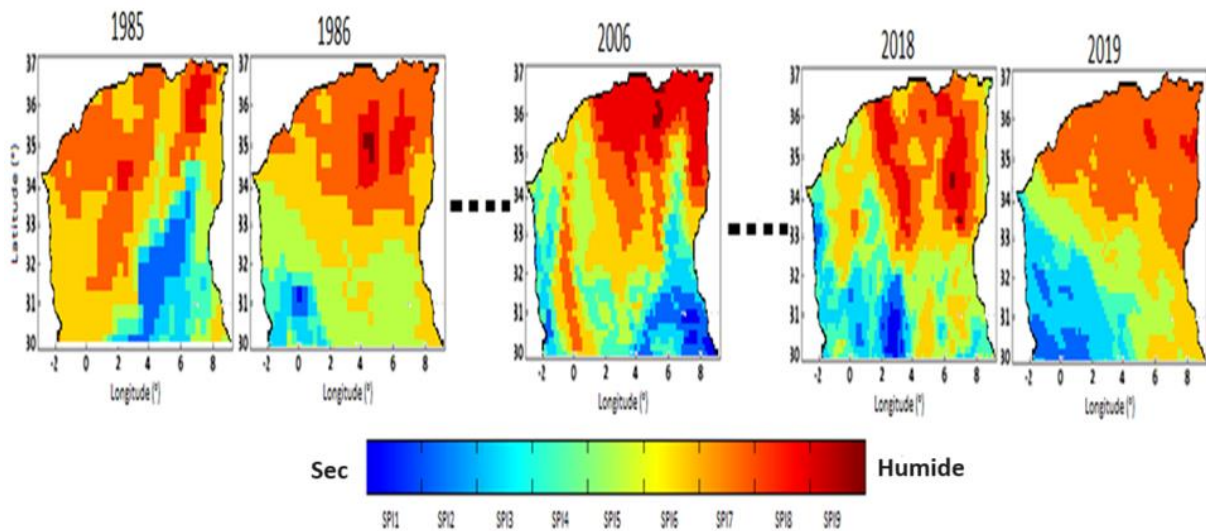


Figure 4.2. Evolution des répartitions des taux de précipitations dans le nord de l'Algérie de 1985 à 2019.

En outre, à titre d'illustration, nous montrons dans la **Figure 4.3** l'évolution d'un pixel pris au hasard dans chaque sous-région.

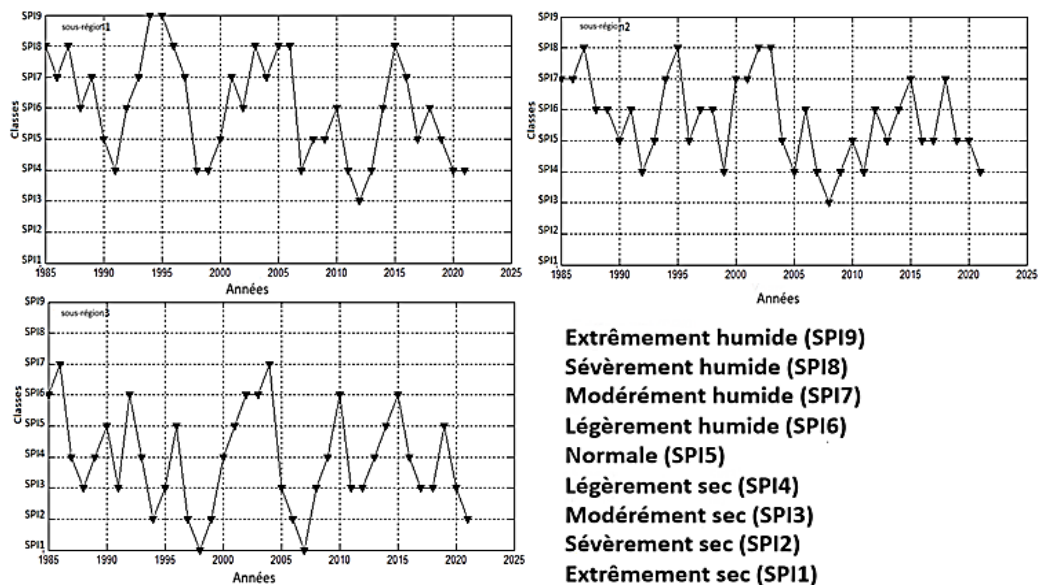


Figure 4.3. Evolution du phénomène sec/humide en fonction du SPI pour un pixel pris dans chaque sous-région.

La base de données des estimations des taux de précipitations est divisée en deux parties ; la première rassemblant toutes les données de 1986 à 2019 est utilisée pour l'estimation des matrices de probabilité de transition pour les chaînes de Markov et pour l'apprentissage automatique de RNA. La seconde partie contient les données des années 2020 et 2021 utilisées pour la prédiction et l'évaluation des performances des deux techniques.

4.2.3. Concepts mathématique des chaînes de Markov et de RNA

4.2.3.1 Chaîne de Markov

Une chaîne de Markov est un processus de Markov qui représente un processus stochastique pouvant être modélisé en déterminant empiriquement les probabilités de transition entre les états discrets des systèmes observés [Cinlar 1975].

Une chaîne de Markov (processus stochastique) est caractérisée par un ensemble d'états, $S = \{S_1, S_2, \dots, S_n\}$, et par les probabilités de transition, appelées P_{ij} , entre les états. Selon l'ordre de la chaîne, la chaîne de Markov d'ordre n est une chaîne pour laquelle un état à l'instant t dépend des n états immédiatement précédents.

Pour une chaîne d'ordre 1, la probabilité de transition P_{ij} représente la probabilité de passer à l'état j au temps t , sachant qu'elle se trouve dans l'état i au temps $t-1$. Dans le cas où le processus ne change pas d'état, cela se produit avec la probabilité P_{ii} . Pour spécifier l'état initial, une distribution de probabilité initiale est définie, il s'agit du vecteur de probabilité initial $Q(0)$:

$$Q(0) = [P_1 P_2 \dots P_n] \quad (4.2)$$

P_i est la probabilité que le processus se trouve dans l'état S_i .

Pour une chaîne de Markov de n états, la matrice de probabilité de transition est de taille $n \times n$ qui représente les transitions entre deux instants temporels successifs. Les P_{ij} peuvent donc être organisés dans une matrice de probabilité de transition (équation 4.3) :

$$P = \begin{bmatrix} P_{11} & P_{12} & \dots & P_{1n} \\ P_{21} & P_{22} & \dots & P_{2n} \\ \dots & \dots & \dots & \dots \\ P_{n1} & P_{n2} & \dots & P_{nn} \end{bmatrix} \quad (4.3)$$

Où P_{ij} est la probabilité de transition de l'état i à l'état j . Pour calculer ces probabilités, nous utilisons l'équation suivante :

$$P_{kj} = \frac{m_{kj}}{\sum_{i=1}^n m_{ki}} \quad (4.4)$$

Avec m_{kj} le nombre de transitions de l'état k à l'état j . Le dénominateur représente toutes les transitions de l'état k à n'importe quel état, les i , j et k varient de 1 à n .

Selon la théorie des processus stochastiques de Markov, le modèle de simulation de Markov est décrit par l'équation suivante :

$$Q(y) = P^1 * Q(y - 1) = P^y * Q(0) \quad (4.5)$$

Où $Q(y)$ est le vecteur de probabilité des états au temps y ; $Q(0)$ est le vecteur de probabilité de départ ($y = 0$). Ainsi, pour prédire l'état à l'instant y , ce qui revient à déterminer le vecteur de probabilité à l'instant y , on multiplie la matrice de probabilité de transition par le vecteur de probabilité à l'instant $y-1$. Il est également possible de prédire l'état de tout instant z à partir d'un vecteur de probabilité de départ multiplié par la matrice de probabilité de transition à la puissance z .

4.2.3.2 Réseau de neurones artificiels (RNA)

Un réseau neuronal artificiel est un système dont la conception s'est inspirée à l'origine du fonctionnement des neurones biologiques. Ainsi, la structure de base d'un RNA est un réseau composé de nœuds de calcul (neurones) reliés entre eux par des liens orientés et pondérés. Les liens pondérés représentent les connexions synaptiques (poids) reliant les neurones entre eux. En général, le neurone peut être un sommateur des potentiels des liaisons synaptiques qui l'atteignent. Le neurone transmet à son tour des informations basées sur cette somme en utilisant une fonction de transfert non linéaire (l'exemple d'un neurone numéro 6 est donné dans la **Figure 4.4**). Des données sont injectées à l'entrée de RNA (neurones d'entrée). L'information se propage en fonction des liens pondérés. L'information correspondante est collectée à la sortie.

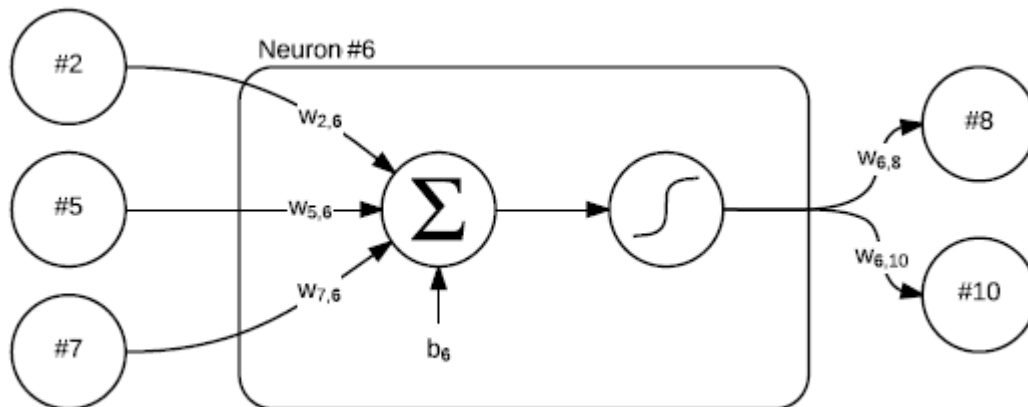


Figure 4.4. Structure interne d'un nœud sommateur (neurone artificiel) ; la somme pondérée des entrées du nœud est calculée, une fonction de transfert non linéaire est appliquée à cette somme. La sortie est ensuite transmise aux autres nœuds (neurones).

Diverses architectures de réseaux neuronaux ont été développées depuis l'apparition des neurones formels dans les années 1940 [McCulloch et Pitts 1943]. La variante la plus utilisée est le Perceptron multicouche (Multilayers Perceptron – MLP) [Rosenblatt 1958]. Un MLP se compose d'une couche d'entrée, d'une ou plusieurs couches intermédiaires dites cachées et d'une couche de sortie. Tous les nœuds d'une couche sont connectés à tous les nœuds de la couche précédente. La **Figure 4.5** donne une représentation d'un perceptron multicouche avec deux couches cachées.

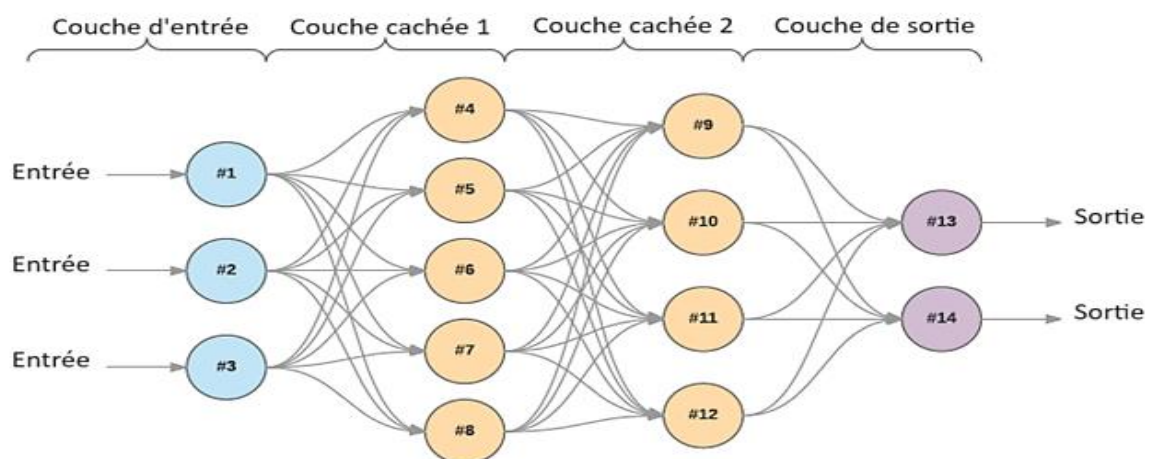


Figure 4.5. Le réseau neuronal structuré en couches est communément appelé MLP.

L'apprentissage se fait par rétro propagation de l'erreur de gradient appliquée à un perceptron multicouche [Hornik et Stinchcombe 1989]. Le perceptron multicouche permet d'approximer, avec une seule couche cachée et un nombre suffisant de neurones, n'importe quelle fonction non linéaire. Le perceptron multicouche est donc appelé approximation universel de fonctions.

Un MLP est défini par les n couches qui le composent et qui se succèdent. La couche $j \in [1, N]$ d'un MLP est donnée par un triplé : $L_j = (n_j, \sigma_j, a_j)$ où

- $n_j \in \mathbb{N}$ représente le nombre de neurones dans la couche j ,
- $a_j: R^{n_{j-1}} \rightarrow R^{n_j}$: est la transformation affine donnée par la matrice $W_j \in R^{n_j \times n_{j-1}}$ et le vecteur $b_j \in R^{n_j}$
- $\sigma_j: R^{n_j} \rightarrow R^{n_j}$: est la fonction de transfert de la couche j .
- La matrice W_j est appelée matrice de poids ou matrice d'interconnexion entre la couche $j-1$ et la couche j ,
- Le vecteur b_j représente le vecteur de biais de la couche j ,
- La fonction σ_j est choisie parmi les fonctions de \mathbb{R} à \mathbb{R} , bornées, non linéaires et différentiables telles que la sigmoïde ou la tangente hyperbolique.

La fonction de transfert est appliquée à chacun des éléments des vecteurs de dimension n_j . En prenant comme entrée des vecteurs de dimension n_e et comme sortie des vecteurs de dimension n_s , on a $n_0 = n_e$ et $n_N = n_s$. Ensuite, pour un vecteur d'entrée donné $x \in R^{n_e}$, on obtient le vecteur de sortie $z \in R^{n_s}$ en initialisant le vecteur $h_0 = x$ puis en appliquant itérativement chacune des couches $L_j, j \in [1, N]$ au vecteur de sortie de la couche précédente :

Nous appliquons la transformation affine a_j au vecteur de sortie de la couche précédente :

$$g_j = a_j(h_{j-1}) = W_j * h_{j-1} + b_j \quad (4.6)$$

Nous appliquons ensuite la fonction de transfert au résultat :

$$h_j = \sigma_j(g_j) \quad (4.7)$$

Avec $h_j, g_j \in \mathbb{R}^{n_j}$ et $z = h_N$.

Cette propagation de l'information de l'entrée de la première couche à la sortie de la dernière couche du MLP est communément appelée "passage en avant" du MLP.

Un MLP est donc une fonction $f_{mlp}: R_{ne} \rightarrow R_{ns}$ définie par la composition successive d'une transformation affine et d'une fonction de transfert non linéaire pour chacune de ses couches :

$$z = f_{mlp}(x) = \sigma_N \circ a_N \circ \sigma_{N-1} \circ a_{N-1} \circ \dots \circ \sigma_1 \circ a_1(x) \quad (4.8)$$

Ainsi, la fonction f_{mlp} est également différentiable dans le cas où l'ensemble des fonctions de transfert du MLP sont différentiables.

4.2.4. Apprentissage de RNA et calcul des chaînes de Markov

Sur une base de données constituée de cartes de précipitations annuelles de 1986 à 2019, nous avons réalisé l'apprentissage de RNA et nous avons construit la chaîne de Markov. Les modèles sont ensuite testés et validés sur les deux années 2020 et 2021. En utilisant les deux modèles, nous avons prédit le phénomène sec/humide de 2022 à 2050.

Le **Tableau 4.2** illustre les différentes périodes d'apprentissage ou de calcul, de prédiction et de validation.

Tableau 4.2. Périodes d'apprentissage ou de calcul de matrices de transitions, de prédiction et de validation.

	1986 à 2019	2020 à 2021	2022 à 2050
RNA	Apprentissage	Prédiction et évaluation	Prédiction
CM	Calcul de matrices de transitions	Prédiction et évaluation	Prédiction

Pour la mise en œuvre du modèle de Markov, nous avons considéré les hypothèses suivantes :

- Le phénomène sec/humide est décrit par l'espace d'état $S = \{SPI1, SPI2, SPI3, SPI4, SPI5, SPI6, SPI7, SPI8, SPI9\}$; il s'agit d'une chaîne de Markov avec un espace d'état fini.
- L'évolution du phénomène sec/humide est stochastique.
- Le futur ne dépend que du présent ; c'est la propriété de Markov (pas de mémoire).
- Les évolutions possibles du processus ne dépendent pas du temps ; le système vérifie la propriété d'homogénéité.

Selon la théorie des processus stochastiques de Markov, l'utilisation du vecteur de distribution de probabilité initial $Q(0)$ et de la matrice de probabilité de transition M permet de calculer la distribution de probabilité du phénomène sec/humide. Cette opération est la prédiction par le modèle markovien. La forme du vecteur de distribution de probabilité initiale pour un pixel x d'une sous-région est donnée comme suit :

$$Q_{sr}x(0) = [P_1 P_2 P_3 P_4 P_5 P_6 P_7 P_8 P_9] \tag{4.9}$$

P_i est la probabilité que le processus soit dans l'état SPI_i

Quant à la matrice de transition de probabilité pour une sous-région (sr), elle prend la forme suivante :

$$M_{sr} = \begin{bmatrix} p_{11}p_{12} p_{13}p_{14} p_{15}p_{16}p_{17}p_{18}p_{19} \\ p_{21}p_{22}p_{23}p_{24}p_{25}p_{26} p_{27}p_{28} p_{29} \\ p_{31}p_{32} p_{33}p_{34} p_{35}p_{36}p_{37}p_{38}p_{39} \\ p_{41}p_{42} p_{43}p_{44} p_{45}p_{46}p_{47}p_{48}p_{49} \\ p_{51}p_{52} p_{53}p_{54} p_{55}p_{56}p_{57}p_{58}p_{59} \\ p_{61}p_{62} p_{63}p_{64} p_{65}p_{66}p_{67}p_{68}p_{69} \\ p_{71}p_{72} p_{73}p_{74} p_{75}p_{76} p_{77}p_{78}p_{79} \\ p_{81}p_{82} p_{83}p_{84} p_{85}p_{86} p_{87}p_{88}p_{89} \\ p_{91}p_{92} p_{93}p_{94} p_{95}p_{96} p_{97}p_{98}p_{99} \end{bmatrix} \tag{4.10}$$

p_{ij} est une probabilité de transition de l'état i à l'état j .

Nous avons donc calculé trois matrices de transition de probabilité pour les trois sous-régions respectivement (**Tableau 4.3**). Dans ces calculs, les situations des années 2020 et 2021 ne sont pas incluses.

Tableau 4.3. Matrices de transition de probabilité pour la sous-région1, sous-région 2 et la sous-région 3 respectivement.

M1x	0.58	0.19	0.10	0.06	0.04	0.02	0.01	0.00	0.00
	0.11	0.64	0.12	0.06	0.03	0.02	0.02	0.00	0.00
	0.05	0.12	0.53	0.10	0.08	0.05	0.03	0.03	0.00
	0.03	0.06	0.11	0.60	0.12	0.04	0.02	0.01	0.01
	0.01	0.04	0.06	0.08	0.70	0.05	0.03	0.02	0.01
	0.00	0.02	0.03	0.08	0.18	0.42	0.15	0.10	0.02
	0.00	0.01	0.04	0.06	0.09	0.15	0.39	0.18	0.08
	0.00	0.01	0.03	0.06	0.08	0.10	0.24	0.38	0.10
	0.00	0.00	0.02	0.06	0.08	0.15	0.18	0.27	0.24
M2x	0.45	0.20	0.16	0.10	0.05	0.02	0.02	0.00	0.00
	0.08	0.44	0.20	0.15	0.05	0.03	0.03	0.02	0.00
	0.02	0.08	0.52	0.15	0.15	0.04	0.02	0.01	0.01
	0.01	0.04	0.09	0.51	0.10	0.10	0.07	0.06	0.02
	0.00	0.03	0.04	0.15	0.54	0.16	0.04	0.03	0.01
	0.00	0.01	0.01	0.04	0.07	0.61	0.20	0.04	0.02
	0.00	0.00	0.01	0.02	0.04	0.20	0.48	0.15	0.10
	0.00	0.00	0.01	0.02	0.04	0.10	0.30	0.33	0.20
	0.00	0.00	0.02	0.05	0.05	0.16	0.22	0.24	0.26
M3x	0.50	0.25	0.25	0.00	0.00	0.00	0.00	0.00	0.00
	0.01	0.60	0.15	0.14	0.04	0.03	0.02	0.01	0.00
	0.01	0.10	0.47	0.16	0.14	0.08	0.02	0.02	0.00
	0.00	0.05	0.07	0.46	0.11	0.13	0.08	0.06	0.04
	0.00	0.02	0.06	0.16	0.44	0.17	0.08	0.03	0.04
	0.00	0.00	0.00	0.02	0.05	0.53	0.21	0.11	0.08
	0.00	0.00	0.00	0.01	0.01	0.19	0.42	0.25	0.12
	0.00	0.00	0.00	0.01	0.04	0.11	0.21	0.40	0.23
	0.00	0.00	0.00	0.02	0.04	0.16	0.18	0.25	0.35

Le modèle de prédiction de Markov est le suivant :

$$Qsrx(y) = (Msrx) * Qsrx(y - 1) = (Msrx)^y * Qsrx(0) \tag{4.11}$$

Cette équation permet de prévoir les états du phénomène sec/humide en déterminant à chaque fois le vecteur de probabilité. Ainsi, l'état du processus au temps y correspond à l'état qui a la plus grande probabilité dans le vecteur de probabilité au temps y.

Dans le cas du MLP, nous avons effectué un apprentissage automatique sur les données disponibles. L'architecture MLP que nous avons choisie pour l'apprentissage est illustrée à la **Figure 4.6**.

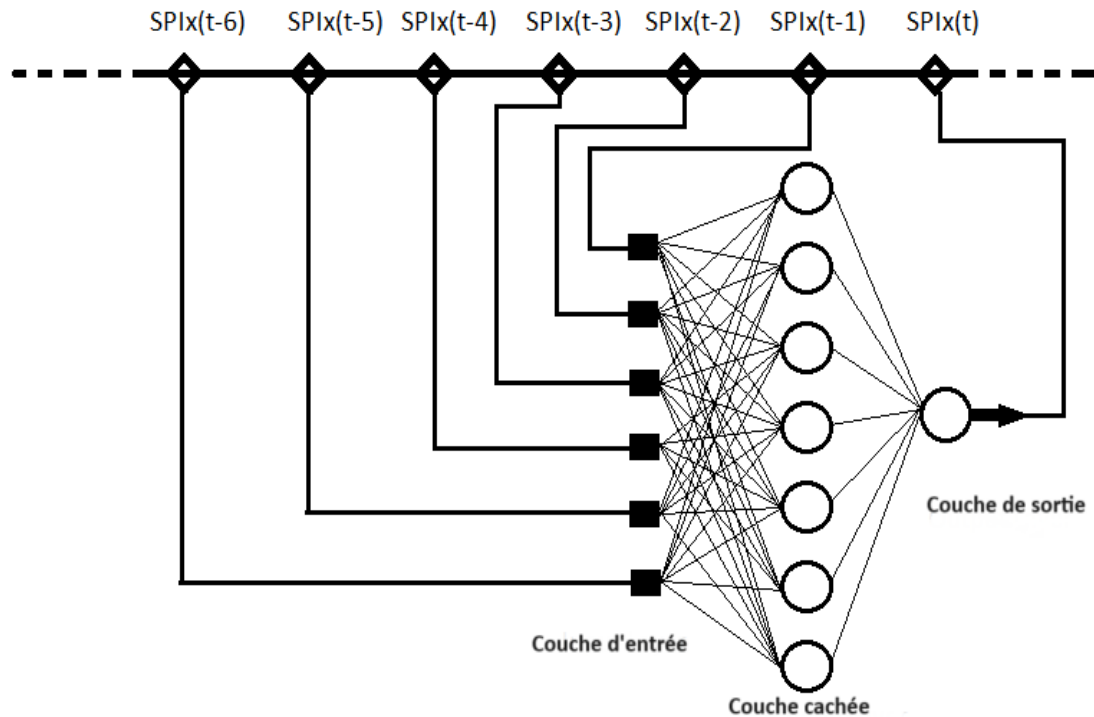


Figure 4.6. Architecture MLP pour l'apprentissage.

Pour chacune des sous-régions, nous avons réalisé l'apprentissage de MLP. Tous les pixels ont été utilisés lors de l'apprentissage, à l'exception des pixels des situations 2020 et 2021 qui sont laissés pour la validation. On obtient ainsi trois modèles de même architecture (MLP1, MLP2 et MLP3).

Pour prédire donc les états du phénomène sec/humide, nous avons utilisé le MLP après entraînement. Il permet de prédire l'un des états du SPI_x à l'instant t en appliquant les six situations précédentes à l'entrée du MLP (**Figure 4.7**).

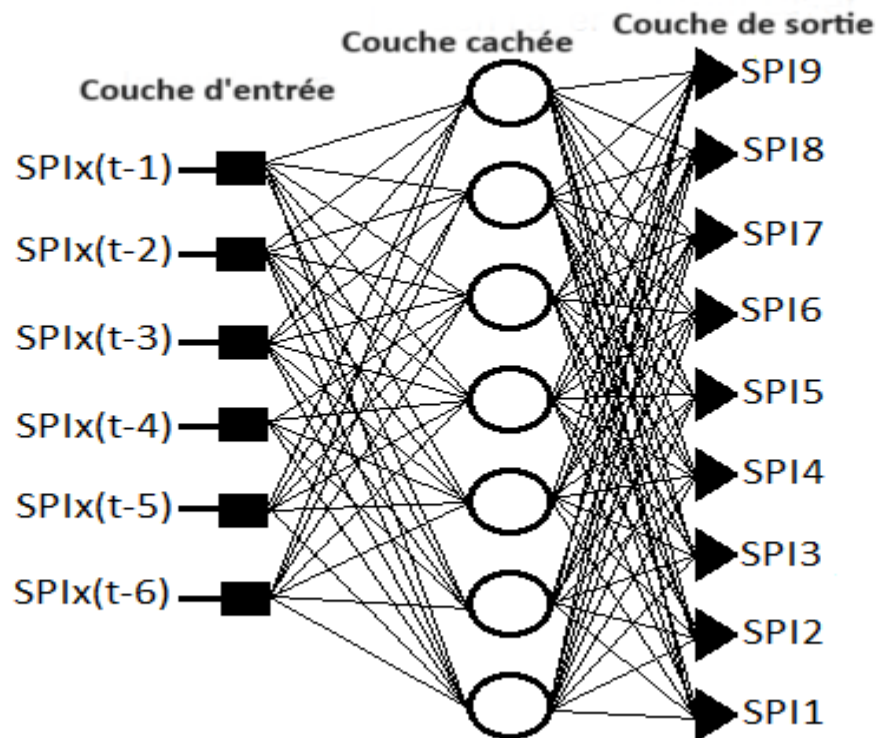


Figure 4.7. Modèle MLP appliqué pour la prédiction à l'instant t .

4.3. Résultats

Dans cette section, nous testons tout d'abord les deux méthodes de prévision du phénomène sec/humide pour les années 2020 et 2021 afin d'évaluer leurs performances. Pour ce faire, des comparaisons entre les résultats des prédictions et les données réelles sont effectuées. Ensuite, nous prédisons le comportement à long terme du processus en mettant en évidence la gravité que peut atteindre la sécheresse.

4.3.1. Prédiction et validation à court terme

Pour tester les deux méthodes, à savoir le MLP et la chaîne de Markov, nous avons prédit les situations du phénomène sec/humide des années 2020 et 2021 en utilisant l'équation (4.11) pour la CM, et le schéma de prédiction donné par la **Figure 4.7** pour le MLP.

Dans le cas du CM, pour prédire chaque pixel de l'année 2020, nous avons multiplié la matrice de transition des probabilités par le vecteur de probabilité du pixel correspondant de l'année 2019. Pour prédire les pixels de l'année 2021, nous avons multiplié les vecteurs de probabilité de l'année 2020 par la matrice de transition des probabilités.

Dans le cas du MLP, pour prédire les pixels de l'année 2020, nous avons appliqué à l'entrée du MLP les pixels correspondants des années 2019, 2018, 2017, 2016, 2015 et 2014. Pour prédire la situation de 2021, le MLP reçoit en entrée les situations des années 2020, 2019, 2018, 2017, 2016 et 2015.

Ainsi, des cartes de distribution des états de phénomènes secs/humides pour les trois sous-régions ont été prédites (**Figure 4.8**).

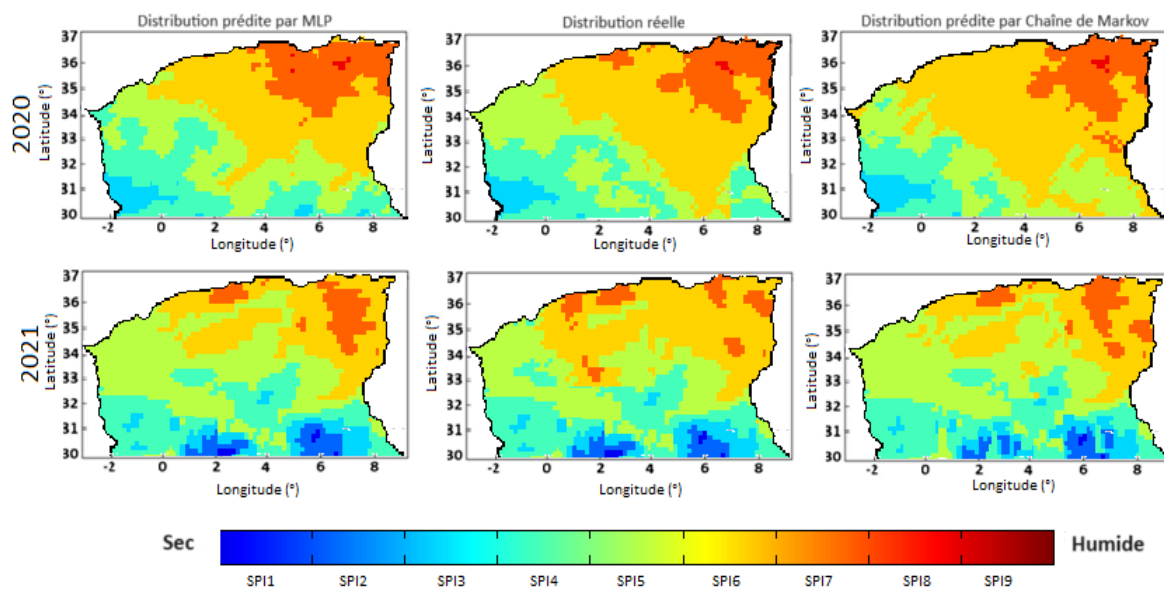


Figure 4.8. Distribution des phénomènes secs/humides pour les deux années 2020 et 2021, (gauche) prédite par MLP, (centre) distribution réelle, (droite) prédite par chaîne de Markov.

Visuellement, à partir de ces cartes, les résultats des prédictions faites par les deux méthodes pour les années 2020 et 2021 sont dans l'ensemble bien corrélés avec les données réelles. Les surfaces humides sont concentrées dans le Nord-Est de la zone d'étude pour les prévisions et pour les données réelles. En ce qui concerne le Sud de la zone d'étude, les champs représentant des situations sèches sont correctement prédits par les deux méthodes. Cependant, les résultats de prédiction obtenus par le MLP montrent une légère surestimation

des zones humides pour les deux années dans l'extrême nord de l'Algérie. Les résultats de prédiction donnés par les deux méthodes illustrent également une sous-estimation des zones affectées par une situation sèche, en particulier dans le centre.

Pour évaluer objectivement la qualité de la prédiction, nous avons comparé les résultats de prédiction des deux méthodes (chaîne de Markov et MLP) avec les données réelles. La **Figure 4.9** montre les résultats des taux de prédictions correctes et erronées.




Figure 4.9. Niveau de prédiction fausse/correcte des deux méthodes pour les différentes classes.

D'après les statistiques présentées dans la **Figure 4.9**, la méthode MLP dans son ensemble est légèrement meilleure que la méthode CM. En effet, pour les classes SPI8 (sévèrement humide), SPI5 (normal), SPI4 (légèrement sec), SPI3 (modérément sec), SPI2 (sévèrement sec), on note une meilleure prédiction pour MLP. Dans le cas des classes SPI9 (extrêmement humide) et SPI7 (modérément humide), la méthode CM a donné de meilleures prédictions. Quant aux classes SPI6 (légèrement humide) et SPI1 (extrêmement sec), les deux méthodes donnent presque les mêmes prédictions.

Pour mieux interpréter ces comparaisons, nous avons calculé les paramètres d'évaluation : la probabilité de détection (POD), la probabilité de fausse détection (POFD), le taux de fausse alarme (FAR), l'indice de succès critique (CSI) et la proportion correcte (PC) en utilisant les équations (4.12) à (4.17) respectivement.

Pour calculer ces paramètres, nous avons déterminé les valeurs de a, b, c et d qui représentent les coefficients d'un tableau de contingence (**Tableau 4.4**).

Tableau 4.4. Aperçu des combinaisons dans un tableau de contingence.

Classe prévue	Classe réelle			Totale
		<i>Classe(i)</i>	<i>Non classe(i)</i>	
<i>Classe(i)</i>	<i>a</i>	<i>b</i>	<i>a+b</i>	
<i>Non classe(i)</i>	<i>c</i>	<i>d</i>	<i>c+d</i>	
Totale	<i>a+c</i>	<i>b+d</i>	<i>a+b+c+d=n</i>	

- Le POD indique la fraction de pixels qui ont été correctement prédits :

$$POD = \frac{a}{a + c} \quad (4.12)$$

- Le POFD indique la partie des pixels qui est incorrectement prédite.

$$POFD = \frac{b}{b + d} \quad (4.13)$$

- Le FAR indique la partie des pixels prédits qui ne sont pas corrects :

$$FAR = \frac{b}{a + b} \quad (4.14)$$

- Le BIAS indique la sous-prédiction ou la sur-prédiction.

$$Bias = \frac{a + b}{a + c} \quad (4.15)$$

Un biais inférieur à 1 correspond à une sous-prédiction, tandis qu'un biais supérieur à 1 correspond à une sur-prédiction.

- Le CSI indique la fraction de pixels prédits et/ou réels qui ont été correctement diagnostiqués :

$$CSI = \frac{a}{a + b + c} \quad (4.16)$$

- Le PC mesure le pourcentage de prédictions correctes :

$$PC = \frac{a + d}{n} \quad (4.17)$$

Les résultats statistiques des prédictions pour les différentes classes du phénomène obtenues en appliquant les deux méthodes sont présentés dans le **Tableau 4.5**.

Tableau 4.5. Valeurs des paramètres d'évaluation pour les deux méthodes.

classes	POD		POFD		FAR		Bias		CSI		PC	
	MLP	CM	MLP	CM	MLP	CM	MLP	CM	MLP	CM	MLP	CM
SPI9	88	91	15	14	23	20	1.4	0.9	78	79	90	93
SPI8	92	86	12	16	19	22	1.2	1.5	84	76	94	89
SPI7	91	93	13	11	20	18	0.8	1.1	79	83	92	95
SPI6	91	92	13	12	20	19	1.1	1.1	78	78	93	94
SPI5	87	86	16	18	22	24	0.7	0.6	76	75	89	88
SPI4	88	83	16	20	23	28	0.6	0.5	77	72	90	86
SPI3	88	86	17	18	24	27	1.3	1.6	76	74	90	87
SPI2	90	89	14	16	23	25	1.1	0.8	78	75	92	90
SPI1	78	77	31	32	38	38	0.6	1.5	69	68	84	83
Total	89	85	17	19	22	24	1.1	1.2	78	77	91	90
Optimal	100	100	0	0	0	0	1	1	100	100	100	100

Les résultats indiquent clairement que les deux méthodes de prédiction des situations sèches/humides présentent des performances très intéressantes. Les classes prédites sont globalement bien corrélées avec les données réelles aussi bien pour la méthode CM que pour la méthode MLP. En effet, les POD, POFD et FAR montrent des valeurs situées dans les intervalles [78-92], [12-31] et [19-38] pour MLP, et [77-93], [11-32] et [18-38] pour CM respectivement.

En termes de biais, la tendance générale indique une très faible sur-prédiction pour MLP et CM avec 1,1 et 1,2 respectivement. Le CSI et le PC affichent la même tendance que

les autres paramètres. Ils confirment que les deux méthodes donnent de meilleures prédictions. Les intervalles pour CSI et PC sont respectivement [69-84] et [84-94] pour MLP, et [68-83] et [83-95] pour CM.

Malgré quelques fluctuations entre les classes, la tendance générale donne une performance légèrement meilleure pour MLP par rapport à CM. Toutefois, dans le cas des classes SPI9, SPI7 et SPI6, les prédictions sont meilleures pour CM que pour MLP.

4.3.2. Prédiction à long terme

Comme pour les prédictions à court terme, nous avons prédit le comportement du phénomène sec/humide pour les prochaines années, de 2022 à 2050, en utilisant le MLP et les CM.

Dans le cas du modèle markovien, nous avons utilisé les matrices de transition et les vecteurs de probabilité pour l'année 2021. Les probabilités de chaque état en fonction des zones occupées dans la zone d'étude de 2022 à 2050 ont été déterminées (voir **Figure 4.10**).

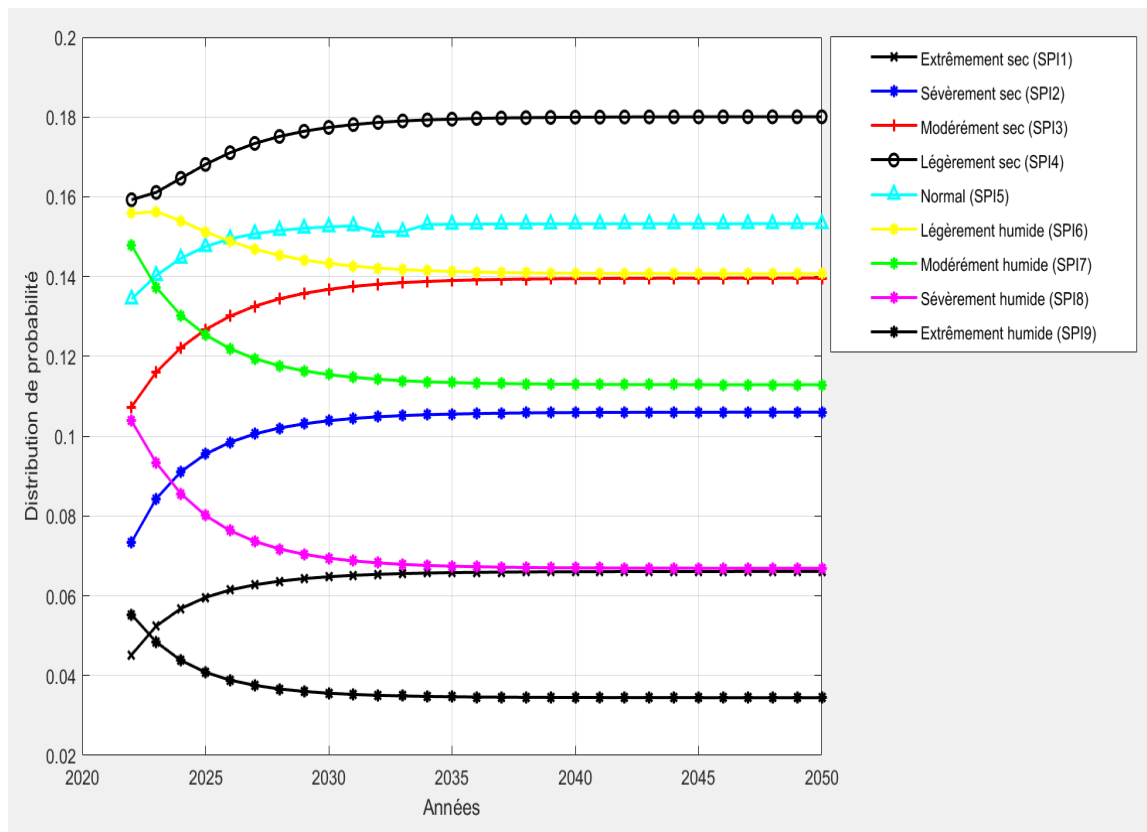


Figure 4.10. Prédications par CM données sous forme de probabilité d'occupation dans la zone d'étude de 2022 à 2050.

Dans la **Figure 4.10**, les résultats indiquent que les distributions sont dans un état stable à partir de l'année 2047. La tendance générale des prédictions montre que les états représentant des situations sèches ont dominé par rapport aux états représentant des situations humides. En effet, les probabilités indiquent que les états des situations sèches ont progressé au détriment des états des situations humides qui ont régressé.

Le **Tableau 4.6** et le **Tableau 4.7** donnent l'évolution chronologique des différents états en km² prédits par CM et MLP respectivement.

Tableau 4.6. Surfaces occupées en Km² par chacun des Etats de 2022 à 2050 prédites par les chaînes de Markov.

	SPI9 (x10 ⁵ km ²)	SPI8	SPI7	SPI6	SPI5	SPI4	SPI3	SPI2	SPI1
2022	0.3220	0.6047	0.9635	0.9074	0.7824	0.9274	0.6251	0.4276	0.2631
2023	0.2820	0.5437	0.8611	0.9101	0.8168	0.9381	0.6756	0.4909	0.3051
2024	0.2552	0.4985	0.7998	0.8966	0.8420	0.9587	0.7114	0.5304	0.3307
2025	0.2378	0.4667	0.7587	0.8808	0.8591	0.9790	0.7379	0.5561	0.3470
2026	0.2263	0.4444	0.7302	0.8667	0.8704	0.9961	0.7575	0.5735	0.3579
2027	0.2187	0.4288	0.7099	0.8553	0.8778	1.0096	0.7721	0.5856	0.3654
2028	0.2134	0.4178	0.6955	0.8464	0.8826	1.0198	0.7828	0.5942	0.3707
2029	0.2098	0.4099	0.6851	0.8395	0.8858	1.0274	0.7908	0.6004	0.3745
2030	0.2072	0.4043	0.6776	0.8344	0.8879	1.0330	0.7966	0.6049	0.3772
2031	0.2054	0.4003	0.6722	0.8306	0.8893	1.0371	0.8010	0.6082	0.3792
2032	0.2041	0.3974	0.6682	0.8277	0.8902	1.0402	0.8041	0.6106	0.3807
2033	0.2032	0.3952	0.6654	0.8255	0.8909	1.0424	0.8065	0.6124	0.3818
2034	0.2025	0.3937	0.6633	0.8239	0.8913	1.0440	0.8082	0.6137	0.3826
2035	0.2020	0.3926	0.6617	0.8228	0.8916	1.0452	0.8095	0.6146	0.3832
2036	0.2017	0.3918	0.6606	0.8219	0.8918	1.0461	0.8104	0.6153	0.3836
2037	0.2014	0.3912	0.6597	0.8212	0.8920	1.0468	0.8111	0.6159	0.3839
2038	0.2012	0.3907	0.6591	0.8207	0.8921	1.0472	0.8117	0.6163	0.3842
2039	0.2011	0.3904	0.6587	0.8203	0.8922	1.0476	0.8120	0.6166	0.3844
2040	0.2010	0.3902	0.6583	0.8201	0.8922	1.0479	0.8123	0.6168	0.3845
2041	0.2009	0.3900	0.6581	0.8199	0.8923	1.0480	0.8125	0.6170	0.3846
2042	0.2008	0.3898	0.6579	0.8197	0.8923	1.0482	0.8127	0.6171	0.3847
2043	0.2008	0.3897	0.6577	0.8196	0.8923	1.0483	0.8128	0.6172	0.3847
2044	0.2008	0.3897	0.6576	0.8195	0.8923	1.0484	0.8129	0.6172	0.3848
2045	0.2007	0.3896	0.6576	0.8194	0.8923	1.0484	0.8130	0.6173	0.3848
2046	0.2007	0.3896	0.6575	0.8194	0.8923	1.0485	0.8130	0.6173	0.3848
2047	0.2007	0.3895	0.6574	0.8193	0.8924	1.0485	0.8131	0.6174	0.3849
2048	0.2007	0.3895	0.6574	0.8193	0.8924	1.0485	0.8131	0.6174	0.3849
2049	0.2007	0.3895	0.6574	0.8193	0.8924	1.0485	0.8131	0.6174	0.3849
2050	0.2007	0.3895	0.6574	0.8193	0.8924	1.0485	0.8131	0.6174	0.3849

Tableau 4.7. Surfaces occupées en Km² par chacun des états de 2022 à 2050 prédites par le MLP.

	SPI9 (x10 ⁵ km ²)	SPI8	SPI7	SPI6	SPI5	SPI4	SPI3	SPI2	SPI1
2022	1.0598	0.7646	0.6359	0.9422	1.0435	0.6924	0.2917	0.1013	0.0297
2023	0.5113	0.9917	0.8746	1.6084	0.7093	0.6656	0.2848	0.1304	0.0472
2024	0.4775	1.0557	0.9853	0.9422	1.0435	0.9253	0.2917	0.0722	0.0297
2025	0.9777	1.2479	1.0284	0.6382	0.7885	0.4909	0.3447	0.1858	0.1211
2026	0.2271	0.8939	0.7733	1.3952	1.6136	0.3855	0.3575	0.1235	0.0536
2027	0.3494	0.7262	1.8046	0.9422	0.8205	0.5235	0.3721	0.1922	0.0926
2028	0.3471	1.4971	0.9020	1.1285	0.4565	0.7343	0.3843	0.2358	0.1374
2029	0.0681	0.1281	0.3191	0.7366	1.0656	1.2182	0.6982	0.8484	0.4496
2030	0.0122	0.0856	0.2684	0.4367	0.7454	0.9358	1.5484	1.2625	0.5282
2031	0.0035	0.0297	0.1427	0.2615	0.4845	1.2357	1.9263	1.2345	0.5049
2032	0.0576	0.1852	0.3447	0.6604	1.4331	1.3353	0.9090	0.6877	0.2102
2033	0.1165	0.1438	0.2323	1.0004	1.4028	1.6299	0.9544	0.2504	0.0926
2034	0.1660	0.1409	0.7197	2.0439	1.2386	0.5614	0.4519	0.3529	0.1479
2035	0.1170	0.3319	0.5352	0.7489	1.2933	1.0202	0.8828	0.2172	0.0943
2036	0.2760	0.6376	1.8355	1.0575	1.0622	0.4181	0.2556	0.1992	0.0815
2037	0.1543	0.4030	0.7786	2.0684	0.8752	0.6813	0.4321	0.3040	0.1264
2038	0.0972	0.5060	0.6836	1.8780	0.8129	0.7960	0.4758	0.3395	0.2341
2039	0.0384	0.1258	0.2335	0.5468	0.9067	1.9915	1.1763	0.5084	0.2958
2040	0.0367	0.1392	0.3476	0.7908	1.0895	0.8251	1.4284	0.8415	0.3244
2041	0.0204	0.1421	0.2504	0.5683	1.0919	1.7470	1.0837	0.6970	0.2224
2042	0.0314	0.1095	0.2003	0.4664	0.7197	1.8186	1.1390	0.8118	0.5264
2043	0.0093	0.0833	0.2422	0.4426	0.7593	1.1023	1.5897	1.1163	0.4781
2044	0.0087	0.0716	0.1677	0.4309	0.6906	0.8927	1.4506	1.4249	0.6854
2045	0.0082	0.0699	0.1310	0.3907	0.5654	0.7873	1.4005	1.6142	0.8560
2046	0.0058	0.0460	0.1735	0.4228	0.5398	1.2374	1.5024	1.0825	0.8129
2047	0.0052	0.0390	0.1648	0.3762	0.4519	1.2869	1.5880	1.0814	0.8298
2048	0.0029	0.0151	0.1951	0.4921	0.3511	1.8011	1.1507	0.9300	0.8851
2049	0.0012	0.0233	0.0804	0.1858	0.3028	1.7633	1.6404	0.8811	0.9451
2050	0.0006	0.0076	0.0402	0.1368	0.5404	1.2997	1.6194	1.1116	1.0656

On constate que toutes les surfaces correspondant aux états représentant des situations sèches gagnent remarquablement du terrain, contrairement aux surfaces correspondant à la situation humide qui diminuent.

Pour mieux montrer l'évolution chronologique des surfaces occupées par les différents états, l'équivalence du **Tableau 4.7** en termes de probabilités d'occupation des surfaces pour chaque état dans la région étudiée est donnée dans la **Figure 4.11**.

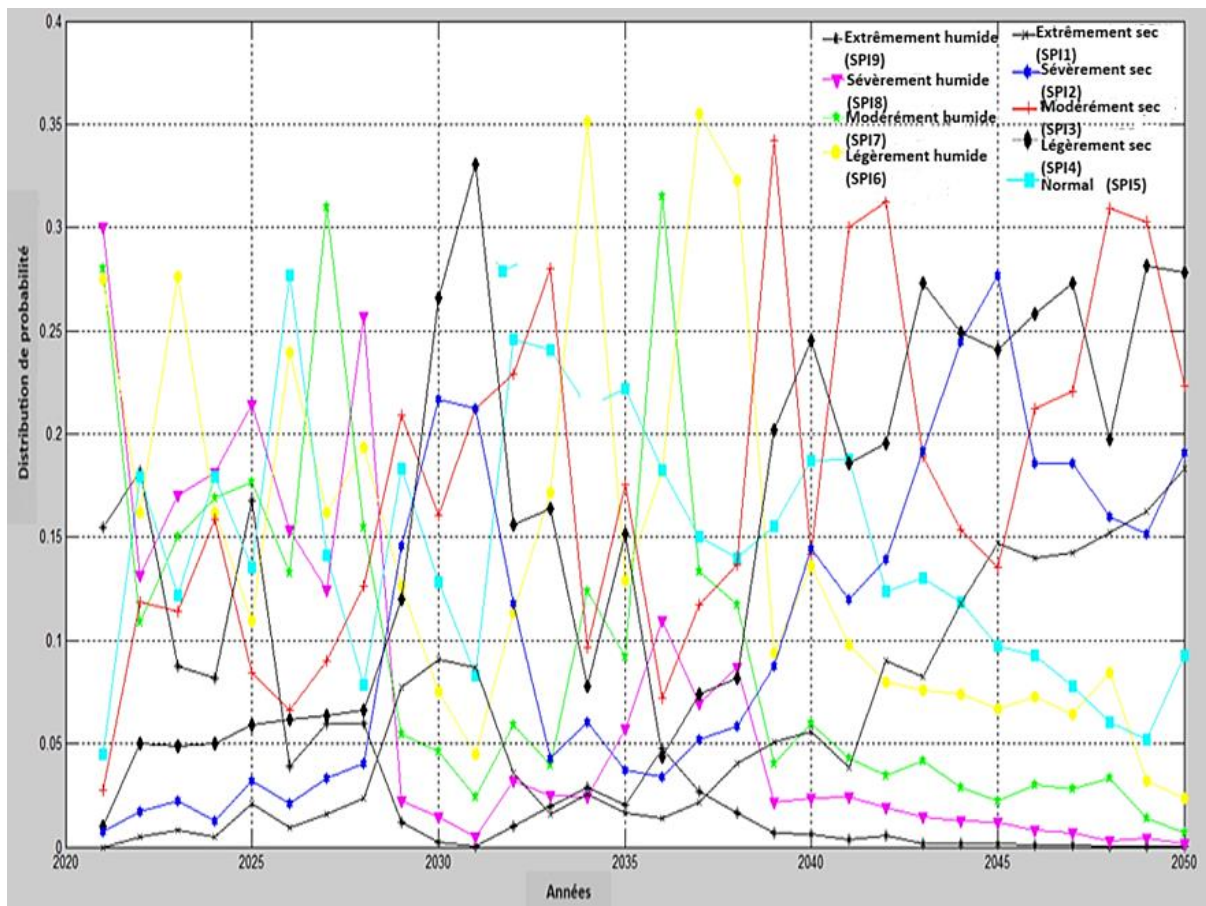


Figure 4.11. Variation de la probabilité de distribution de chaque état en fonction de la surface occupée.

Les situations spatiales des années 2047, 2048, 2049 et 2050 prédites par MLP et CM sont illustrées dans la **Figure 4.12**. Les prévisions spatiales montrent que la situation de

sécheresse est grave au Sud de la zone d'étude. La classe de sécheresse extrême domine dans cette zone.


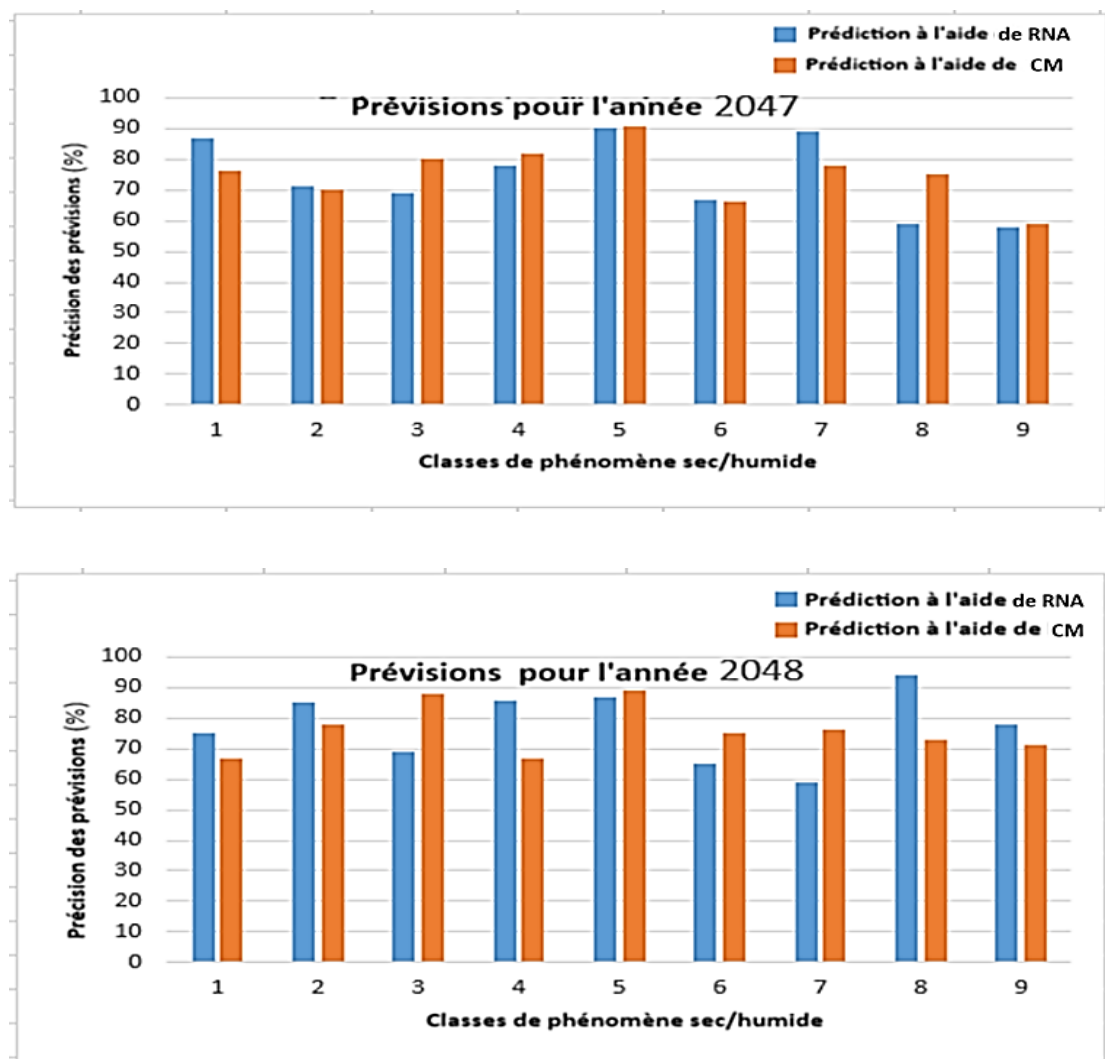


Figure 4.12. Résultats de la prédiction obtenus par application des deux méthodes pour les années 2047, 2048, 2049 et 2050.

La situation sèche, bien que moins sévère, n'a pas épargné le Nord. Les classes modérément sec et légèrement sec sont très présentes. Les situations humides restent concentrées dans le Nord-Est de la zone d'étude mais avec des degrés faibles. Cependant, les prévisions données par le modèle Markovien montrent des surfaces plus humides dans le Nord-Ouest. Par contre, dans cette partie, le MLP indique une situation variable entre sec et humide.

Pour une évaluation objective des modèles RNA et CM, les résultats de la sixième phase du Projet d'intercomparaison de modèles couplés (CMIP6) sont utilisés. Le CMIP6 donne des simulations très correctes dans les régions de latitude moyenne [Wang et al. 2021]. Le CMIP6 est utilisé avec succès pour étudier les sécheresses [Zhai et al. 2020]. Il est également utilisé pour l'évaluation des précipitations extrêmes [de Medeiros et al. 2022]. Dans cette étude, nous utilisons le scénario des profils socio-économiques partagées (SSP126) de CMIP6 [Gidden et al. 2019]. Pour plus de détails sur CMIP6, le lecteur peut se référer aux travaux publiés par Eyring et al. (2015).

Certaines scènes ont été comparées pour montrer la différence entre les prédictions obtenues par les deux modèles RNA et CM d'une part, et les simulations données par CMIP6 sous SSP126. Nous avons calculé la précision relative des prédictions par rapport aux simulations CMIP6 pour les différentes catégories pour les années 2047, 2048, 2049 et 2050 (Figure 4.13).



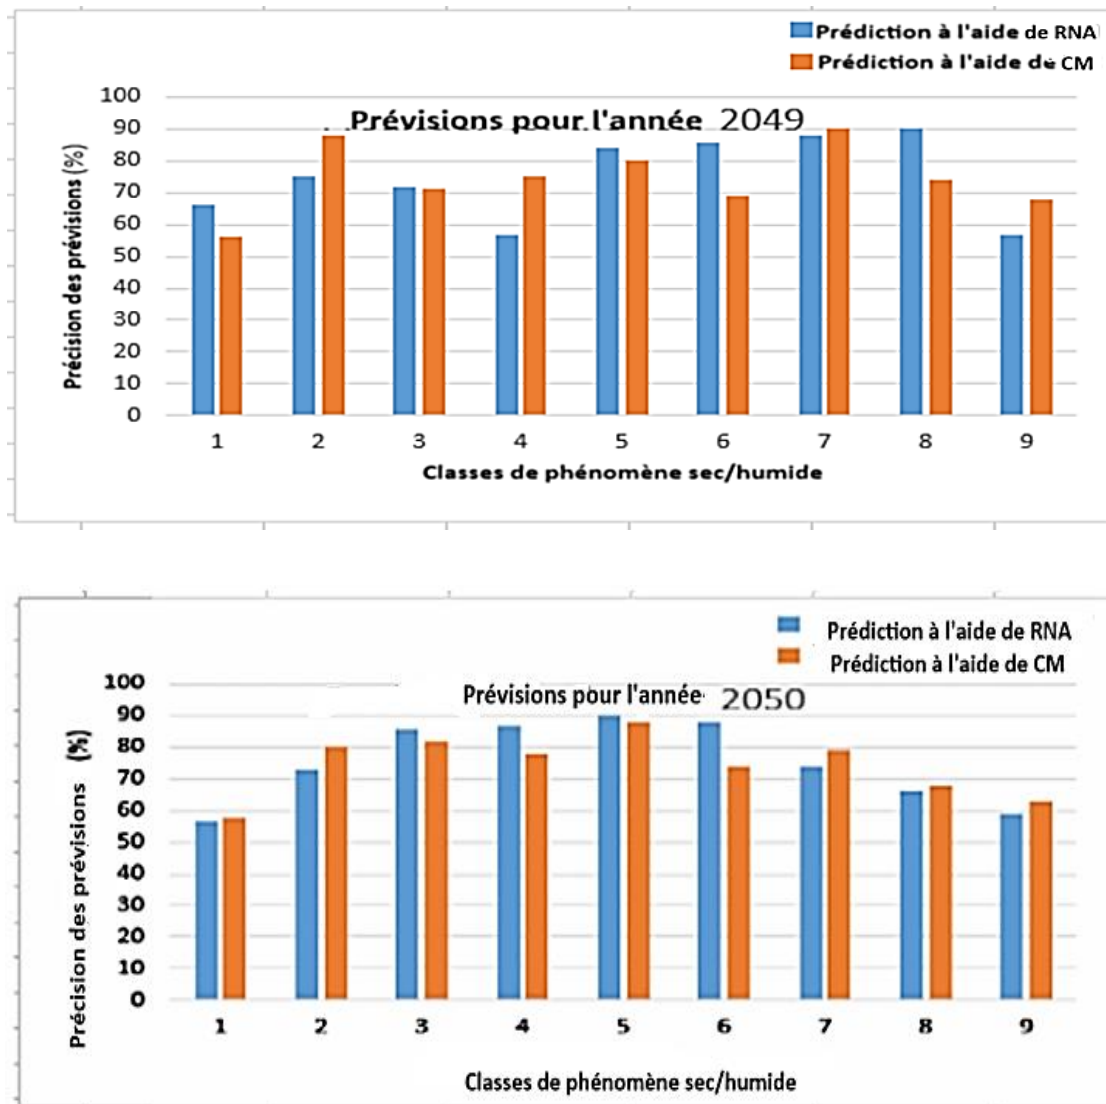


Figure 4.13. Résultats de précision de prédiction de RNA et CM par rapport aux prévisions de CMIP6 pour les différentes classes.

Les prévisions des deux modèles RNA et CM atteignent dans certains cas 90 % des simulations données par CMIP6. La précision de prédiction la plus faible dépasse 58 % des simulations CMIP6. Les bonnes performances des modèles RNA et CM sont intéressantes par rapport aux résultats de CMIP6. Les résultats montrent également qu'une tendance à la baisse dans les zones humides et une augmentation dans les zones sèches sont indiquées par RNA et CM, mais aussi par les simulations de CMIP6.

4.4. Discussion

Les paramètres d'évaluation utilisés montrent que les prédictions obtenues à court terme correspondent aux données réelles, tant pour la méthode de la chaîne de Markov que pour celle du réseau neuronal. Nous avons ensuite prédit le phénomène sec/humide à long terme, de 2022 à 2050. La tendance générale de prédiction est identique pour les trois modèles (RNA, CM et CMIP6). En effet, les résultats des prédictions effectuées par les trois modèles indiquent que les zones représentant des surfaces sèches gagnent du terrain au détriment des zones humides avec une légère différence. L'étude réalisée dans cette thèse a mis en évidence le risque croissant de l'installation progressive de la sécheresse dans le Nord de l'Algérie. En effet, les deux méthodes montrent une situation préoccupante quant à l'évolution du phénomène sec/humide représenté par neuf classes. Toutes les classes représentant des situations sèches ont gagné du terrain au détriment des classes représentant des situations humides. C'est ce que prévoyaient les deux méthodes. Malgré quelques différences dans les résultats des prévisions, la tendance générale montre que les classes de situations sèches sont dominantes et sévères, en particulier à très long terme. La persistance et l'expansion des situations sèches conduisent inévitablement à la sécheresse.

Bien qu'il s'agisse d'une prévision, la base de cette étude repose sur deux modèles connus pour leurs performances. Par conséquent, les résultats de ces prévisions sont nécessaires et devraient alerter les autorités concernées pour qu'elles interviennent rapidement afin de prévenir et de contrôler la situation. Cependant, la mise en œuvre opportune de mesures de préparation et d'atténuation face à cette situation doit être envisagée. Le risque est d'autant plus grand qu'environ 20 à 25 % de la consommation des ressources en eau provient des précipitations. Cette étude a mis en évidence le danger de la sécheresse qui est ici étudiée sur la base des seuls taux de précipitations annuelles à l'aide de SPI.

Comme il n'est pas possible de contrer directement le développement de la sécheresse, les autorités concernées doivent prendre certaines mesures, telles que :

- ✓ Augmenter la capacité de stockage de l'eau.
- ✓ Utiliser le dessalement de l'eau de mer.
- ✓ Explorer les eaux souterraines pour l'agriculture.

Conclusion

L'objectif de cette thèse est d'étudier le comportement du phénomène sec/humide dans la région Nord de l'Algérie. Cette étude de comportement a permis de mettre en évidence le risque de la sécheresse, liée principalement aux précipitations, qui peut survenir dans le futur. Afin de mieux aborder notre problématique, nous avons décrit le phénomène de sécheresse où nous avons présenté et discuté ses différents indices en montrant leurs avantages et leurs inconvénients. Nous avons aussi abordé le contexte scientifique de la prédiction de la sécheresse par des modèles empiriques et statistiques, et ceux basés sur l'apprentissage automatique. Ces modèles ont été discutés en fonction des types d'indices employés pour la caractérisation de la sécheresse.

Pour répondre donc à notre problématique, à savoir l'étude du phénomène sec/humide, nous avons appliqué les réseaux neuronaux et les chaînes de Markov en utilisant les estimations des précipitations annuelles obtenues à partir d'observations satellitaires de 1985 à 2021. Trois sous-régions ont été séparées où dans chaque sous-région le climat est considéré relativement homogène. Le phénomène sec/humide a été représenté par neuf classes d'intensités différentes selon les valeurs de l'indice SPI, à savoir extrêmement humide, sévèrement humide, modérément humide, légèrement humide, normal, légèrement sec, modérément sec, sévèrement sec, extrêmement sec.

Sur la base des données allant de 1986 à 2019, nous avons entraîné le réseau de neurones utilisé et calculé les différentes matrices de transitions des chaînes de Markov. Les modèles sont ensuite testés pour la prévision du phénomène sec/humide pour les années 2020 et 2021. D'après les résultats de comparaisons, les deux modèles présentent des performances intéressantes. En effet, les résultats de prédiction des différentes classes représentant le phénomène sec/humide sont bien corrélés avec les données réelles et ce, pour les deux méthodes. Les paramètres d'évaluation ont tous confirmé la bonne performance de la méthode CM et de la méthode MLP. Cependant, une légère supériorité a été observée pour la méthode MLP par rapport à la méthode CM.

Nous avons ensuite réalisé des prévisions à long terme du phénomène sec/humide en prédisant des différentes situations des années 2022 à 2050. Les prévisions données par les deux méthodes ont montré une dominance pour les classes représentant les situations sèches

au détriment des surfaces humides. Cependant, de légères différences de prévisions sont observées entre les deux méthodes. Pour la partie Nord-Ouest, le MLP a indiqué une fluctuation entre les états de situations sèches et les états de situations humides. En revanche, dans cette zone, la CM montre une situation stable avec une dominance des états humides, mais très inférieure aux situations initiales.

Les chaînes de Markov et les réseaux de neurones sont connus pour leurs performances dans les prédictions, étayés par plusieurs travaux de recherches publiés dans la littérature [Vidyarthi et Jain 2020 ; Gao et al. 2020]. La qualité des résultats de prédiction obtenus dans cette étude pour les années 2020 et 2021 est aussi un bon indicateur de performances. A cet effet, les prédictions à long terme réalisées par ces deux modèles doivent être prises en compte sérieusement, d'autant plus que les simulations par le CMIP6 ont montré les mêmes tendances.

Par ailleurs, l'une des limites que l'on peut soulever dans cette étude concerne l'utilisation d'un seul indice de sécheresse, à savoir le SPI. Par conséquent, pour mieux appréhender le phénomène de sécheresse dans ses différents aspects, il serait intéressant d'intégrer d'autres indicateurs, comme par exemple NDVI, PDSI et VCI.

Références bibliographiques

Abramowitz M, Stegun A (eds) (1965). Handbook of mathematical formulas, graphs, and mathematical tables. Dover Publications Inc, New York.

Adler, R. F., Huffman, G. J., Chang, A., Ferraro, R., Xie, P. P., Janowiak, J., et al. (2003). The version-2 global precipitation climatology project (GPCP) monthly precipitation analysis (1979–present). *Journal of Hydrometeorology*, 4(6), 1147–2116. [https://doi.org/10.1175/1525-7541\(2003\)004\1147:TVGPCP\[2.0.CO;2\]](https://doi.org/10.1175/1525-7541(2003)004\1147:TVGPCP[2.0.CO;2]).

AghaKouchak, A. (2015). A multivariate approach for persistence based drought prediction: Application to the 2010–2011 East Africa drought. *Journal of Hydrology*, 526, 127–135. <https://doi.org/10.1016/j.jhydrol.2014.09.063>.

AghaKouchak, A., & Nakhjiri, N. (2012). A near real-time satellite-based global Drought climate data record. *Environmental Research Letters*, 7(4), 044037.

Alexander, M.E., (1990). Computer Calculation of the Keetch-Byram Drought Index Programmers Beware! *Fire Management Notes*, 51-4, 23-25.

Altunkaynak, A., & Jalilzadnezamabad, A. (2021). Extended lead-time accurate forecasting of Palmer drought severity index using hybrid wavelet-fuzzy and machine learning techniques. *Journal of Hydrology*, 601, 126619. <https://doi.org/10.1016/j.jhydrol.2021.126619>.

Angelidis, P., Maris, F., Kotsovinos, N., & Hrissanthou, V. (2012). Computation of Drought Index SPI with Alternative Distribution Functions. *Water Resources Management*, 26(9), 2453–2473. Doi: 10.1007/s11269-012-0026-0.

Bayissa, Y. A. (2018). Developing an impact-based combined drought index for monitoring crop yield anomalies in the Upper Blue Nile Basin, Ethiopia, 1stedn. London: CRC Press. <https://doi.org/10.1201/9780429399510>.

Bazrkar, M. H., & Chu, X. (2021). Ensemble stationary-based support vector regression for drought prediction under changing climate. *Journal of Hydrology*, 603, 127059. <https://doi.org/10.1016/j.jhydrol.2021.127059>.

Beaudin, I (2006). Potentiel de la télédétection pour le suivi et la caractérisation de la condition de sécheresse en milieu méditerranéen, programme en sciences géomatiques faculté de foresterie et géomatique université Laval.

Belayneh, A., Adamowski, J., Khalil, B., & Ozga-Zielinski, B. (2014). Long-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet neural networks and wavelet support vector regression models. *Journal of Hydrology*, 508, 418–429. <https://doi.org/10.1016/j.jhydrol.2013.10.052>.

Bhuiyan, C., (2004). Various Drought Indices for Monitoring Drought Condition in Aravalli Terrain of India, Proceedings of the XXth ISPRS Conference, International Society for Photogrammetry and Remote Sensing, Istanbul (Turquie), <http://www.isprs.org/proceedings/XXXV/congress/comm7/papers/243.pdf>.

Billaut, M., Birot, P., Cavalier, D., & Pédelaborde, P. (1956). Problèmes climatiques sur la bordure nord du monde méditerranéen. In *Annales de Géographie* (Vol. 65, No. 347, pp. 15-39). Armand Colin.

Boyd, D. S., Phipps, P. C., Foody, G. M., & Walsh, R. P. D. (2002). Exploring the utility of NOAA AVHRR middle infrared reflectance to monitor the impacts of ENSO-induced drought stress on Sabah rainforests. *International Journal of Remote Sensing*, 23(23), 5141–5147. <https://doi.org/10.1080/01431160210163128>.

Brahim, H., Mohamed, M., Topçu, E. et al. (2024). Drought assessment and characterization using SPI, EDI and DEPI indices in northern Algeria. *Nat Hazards*. <https://doi.org/10.1007/s11069-024-06408-4>.

Breiman, L. (2001). *Machine Learning*, 45(1), 5–32. Doi: 10.1023/a: 1010933404324.

Byun, H. R., & Wilhite, D. A. (1999). Objective quantification of drought severity and duration. *Journal of climate*, 12(9), 2747-2756.

Cancelliere, A., Di, M. G., Bonaccorso, B., & Rossi, G. (2007). Drought forecasting using the standardized precipitation index. *Water Resources Management*, 21, 801–819. <https://doi.org/10.1007/s11269-006-9062-y>.

Cinlar, E. (1975). *Introduction to stochastic processes*. Prentice Hall.

CEDO, (2020). Standardized Precipitation Index (SPI). Copernicus European Drought Observatory (CEDO). <https://edo.jrc.ec.europa.eu/>.

Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1), 21-27.

de Medeiros, F. J., de Oliveira, C. P., & Avila-Diaz, A. (2022). Evaluation of extreme precipitation climate indices and their projected changes for Brazil: From CMIP3 to CMIP6. *Weather and Climate Extremes*, 38, 100511.

de Oliveira Junior, J. F., de Gois, G., de Lima Silva, I. J., de Oliveira Souza, E., da Rosa Ferraz Jardim, A. M., da Silva, M. V., Shah, M., & Jamjareegulgarn, P. (2021). Wet and dry periods in the state of Alagoas (Northeast Brazil) via Standardized Precipitation Index. *Journal of Atmospheric and Solar-Terrestrial Physics*, 224, 105746. <https://doi.org/10.1016/j.jastp.2021.105746>.

Djellouli, F., Bouanani, A., & Baba-Hamed, K. (2016). Efficiency of some meteorological drought indices in different time scales, case study: wadi Louza basin (NW-Algeria). *Journal of Water and Land Development*, 31(1), 33–41. Doi: 10.1515/jwld-2016-0034.

Durdu, Ö.F. (2010). Application of linear stochastic models for drought forecasting in the Büyük Menderes river basin, western Turkey. *Stoch Environ Res Risk Assess* 24, 1145–1162 <https://doi.org/10.1007/s00477-010-036>

Edwards, D. C., & McKee, T. B. (1997). Characteristics of 20th century drought in the United States at multiple times scales. *Atmospheric Science* pp. 1–30. <http://hdl.handle.net/10217/170176>.

Eyring, V., Bony, S., Meehl, G. A., Senior, C., Stevens, B., Stouffer, R. J., & Taylor, K. E. (2015). Overview of the coupled model intercomparison project phase 6 (CMIP6) experimental design and Organisation. *Geoscientific Model Development & Discussions*, 8, 10539–10583. <https://doi.org/10.5194/gmdd-8-10539-2015>.

Gao, C., Booij, M. J., & Xu, Y. P. (2020). Development and hydro meteorological evaluation of a new stochastic daily rainfall model: Coupling Markov chain with rainfall event model. *Journal of hydrology*, 589, 125337.

Gibbs W, Maher J (1967). Rainfall deciles as drought indicators. Bureau of Meteorology, Melbourne.

Gidden, M. J., Riahi, K., Smith, S. J., Fujimori, S., Luderer, G., Kriegler, E., & Takahashi, K. (2019). Global emissions pathways under different socioeconomic scenarios for use in CMIP6: a dataset of harmonized emissions trajectories through the end of the century. *Geoscientific model development*, 12(4), 1443-1475.

Gillette, H. P. (1950). A Creeping Drought underWay. *Water and Sewage Works*, 104-105.

GIEC, (2013). Changements climatiques 2013 : les éléments scientifiques. Résumé à l'intention des décideurs. Groupe Intergouvernemental D'Experts sur l'évolution du Climat (GIEC), Suisse, 34 p.

Gusyevev, M.A., A. Hasegawa, J. Magome, D. Kuribayashi, H. Sawano et S. Lee, (2015). Drought Assessment in the Pampanga River Basin, the Philippines. Part 1: A Role of Dam Infrastructure in Historical Droughts, Proceedings of the 21st International Congress on Modelling and Simulation (MODSIM 2015), Broad beach, Queensland (Australie).

Guttman N (1999). Accepting the standardized precipitation index: a calculation algorithm. *J Am Water Resour Assoc* 35(2):311–322

- Guttman, N. B. (1998). Comparing the palmer drought index and the standardized precipitation index 1. *JAWRA Journal of the American Water Resources Association*, 34(1), 113-121.
- Guttman, N. B., (1994). On the Sensitivity of Sample L Moments to Sample Size. *J. Clim.* 7:1026-1029.[http://dx.doi.org/10.1175/1520-0442\(1994\)007<1026:OTSOSL>2.0.CO;2](http://dx.doi.org/10.1175/1520-0442(1994)007<1026:OTSOSL>2.0.CO;2)
- Hamdad, S., Lazri, M., Mohia, Y., Labadi, K., & Ameer, S. (2023). Spatiotemporal Comparative Analysis of Dry/Wet Phenomenon of the Rainy Period Using Artificial Neural Networks and Markov Chains. *Journal of the Indian Society of Remote Sensing*, 51(7), 1409-1425.
- Hao, Z., Hao, F., Singh, V. P., Sun, A. Y., & Xia, Y. (2016). Probabilistic prediction of hydrologic drought using a conditional probability approach based on the meta-Gaussian model. *Journal of Hydrology*, 542, 772–780 <https://doi.org/10.1016/j.jhydrol.2016.09.048>.
- Hayes, M. J., Svoboda, M., Wilhite, D. A., & Vanyarkho, O. (1999). Monitoring the drought using the SPI. *Bulletin of the American Meteorological Society*, 80, 429–438. [https://doi.org/10.1175/1520-0477\(1999\)080<0429:MTDUTS>2.0.CO;2](https://doi.org/10.1175/1520-0477(1999)080<0429:MTDUTS>2.0.CO;2).
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5), 6080(89)90020-8. 359–366. <https://doi.org/10.1016/0893>.
- Iqbal, H. M. N., Kyazze, G., & Keshavarz, T. (2013). Advances in the Valorization of Lignocellulosic Materials by Biotechnology: An Overview. *Bio Resources*, 8(2). doi:10.15376/biores.8.2.3157-3176
- Jayanthi, H., & Husak, G. (2013). A probabilistic approach to assess agricultural drought risk. Background Paper Prepared for the Global Assessment Report on Disaster Risk Reduction.
- Kamruzzaman, M., Hwang, S., Cho, J., Jang, M. W., & Jeong, H. (2019). Evaluating the spatiotemporal characteristics of agricultural drought in Bangladesh using effective drought index. *Water*, 11(12), 2437.

- Kaur, A., & Sood, S. K. (2020). Deep learning based drought assessment and prediction framework. *Ecological Informatics*, 57, 101067.
- Keetch, J.J., Byram, O.M., (1968). A drought index for forest fire control. USDA. For. Serv. Southeastern For. and Range Exp. Stn. Res. Pap. SE-38.
- Keyantash, J., & Dracup, J. A. (2002). The quantification of drought: an evaluation of drought indices. *Bulletin of the American Meteorological Society*, 83(8), 1167-1180.
- Khadr, M. (2016). Forecasting of meteorological drought using Hidden Markov Model (case study: The upper Blue Nile river basin, Ethiopia). *Ain Shams Engineering Journal*, 7(1), 47-56.
- Khan, N., Sachindra, D. A., Shahid, S., Ahmed, K., Shiru, M. S., & Nawaz, N. (2020). Prediction of droughts over Pakistan using machine-learning algorithms. *Advances in Water Resources*, 139, 103562. <https://doi.org/10.1016/j.advwatres.2020.103562>.
- Kogan, F. N. (1995). Application of vegetation index and brightness temperature for drought detection. *Advances in space research*, 15(11), 91-100.
- Kogan, F., Gitelson, A., Zakarin, E., Spivak, L., & Lebed, L. (2003). AVHRR-based spectral vegetation index for quantitative assessment of vegetation state and productivity. *Photogrammetric Engineering & Remote Sensing*, 69(8), 899-906.
- Lazri, M., Ameer, S., & Haddad, B. (2007). Analyse de données de précipitations par approche markovienne. *LARHYSS Journal P-ISSN 1112-3680/E-ISSN 2521-9782*, (6).
- Lazri, M., Ameer, S., Brucker, J. M., Lahdir, M., & Sehad, M. (2015). Analysis of drought areas in northern Algeria using Markov chains. *Journal of Earth System Science*, 124, 61–70. <https://doi.org/10.1007/s12040-014-0500-6>.
- Lazri, M., Labadi, K., Brucker, J. M., & Ameer, S. (2020). Improving satellite rainfall estimation from MSG data in Northern Algeria by using a multi-classifier model based on machine learning. *Journal of Hydrology*, 584, 124705. <https://doi.org/10.1016/j.jhydrol.2020.124705>.

Liang, L., Qiu, S., Yan, J., Shi, Y., & Geng, D. (2021). VCI-based analysis on spatiotemporal variations of spring drought in China. *International Journal of Environmental Research and Public Health*, 18(15), 7967.

Lionello P., Malanotte-Rizzoli P., Boscolo R. et al. (2006). *The Mediterranean Climate: An overview of the main characteristics and issues*, Mediterranean Climate Variability, Elsevier B. V., 1–26.

Liu, Q., Zhang, G., Ali, S., Wang, X., Wang, G., Pan, Z., & Zhang, J. (2019). SPI-based drought simulation and prediction using ARMA-GARCH model. *Applied Mathematics and Computation*, 355, 96–107. <https://doi.org/10.1016/j.amc.2019.02.058>.

Lloyd-Hughes, B., & Saunders, M. A. (2002). A drought climatology for Europe. *International Journal of climatology: a journal of the royal meteorological society*, 22(13), 1571-1592.

MacQueen, J. (1967). Some methods for classification and analysis of multivariate observations. In *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability* (Vol. 1, No. 14, pp. 281-297).

McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133.

McKee, T. B., Doesken, N. J., & Kleist, J. (1993). The relationship of drought frequency and duration to time scales. In: *Proceedings of the eighth conference on applied climatology*, Am. Meteor. Soc. Boston, pp. 179–184

McKee, T. B., Doesken, N. J., & Kleist, J. (1995). Drought monitoring with multiple time scales. In: *Proceedings of the ninth conference on applied climatology*, Am. Meteor. Soc. Boston, pp. 233–236.

Mehrotra, R., & Sharma, A. (2005). A non-parametric nonhomogeneous hidden Markov model for downscaling of multi-site daily rainfall occurrences. *Journal of Geophysical Research*, 110, D16108. <https://doi.org/10.1029/2004JD00567>.

- Mehrotra, R., Srikanthan, R., & Sharma, A. (2006). A comparison of three stochastic multi-site precipitation occurrence generators. *Journal of Hydrology*, 331, 280–292. <https://doi.org/10.1016/j.jhydrol.2006.05.016>.
- Mehta, A. V., & Yang, S. (2008). Precipitation climatology over Mediterranean Basin from ten years of TRMM measurements. *Advances in Geosciences*, 17, 87-91.
- Mishra, A. K., & Desai, V. R. (2005). Drought forecasting using stochastic models. *Stochastic environmental research and risk assessment*, 19, 326-339.
- Mishra, A. K., & Singh, V. P. (2010). A review of drought concepts. *Journal of Hydrology*, 391(1–2), 202–216. <https://doi.org/10.1016/j.jhydrol.2010.07.012>.
- Mokarram, M., Pourghasemi, H. R., Ming, H., & Zhang, H. (2021). Determining and forecasting drought susceptibility in southwestern Iran using multi-criteria decision-making (MCDM) coupled with CA-Markov model. *Science of the Total Environment*, 781, 146703. <https://doi.org/10.1016/j.scitotenv.2021.146703>.
- Mokhtarzad, M., Eskandari, F., Jamshidi Vanjani, N., & Arabasadi, A. (2017). Drought forecasting by ANN, ANFIS, and SVM and comparison of the models. *Environmental earth sciences*, 76, 1-10.
- Mondol, M. A. H., Zhu, X., Dunkerley, D., & Henley, B. J. (2021). Observed meteorological drought trends in Bangladesh identified with the Effective Drought Index (EDI). *Agricultural Water Management*, 255, 107001.
- Moreira Elsa, E. E., Coelho, C. A., Paulo, A. A., Pereira, L. S., & Mexia, J. T. (2008). SPI-based drought category prediction using log linear models. *Journal of Hydrology*, 354, 116–130. <https://doi.org/10.1016/j.jhydrol.2008.03.002>.
- Moreira, E. E., Paulo, A. A., Pereira, L. S., & Mexia, J. T. (2006). Analysis of SPI drought class transitions using log linear models. *Journal of Hydrology*, 331, 349–359. <https://doi.org/10.1016/j.jhydrol.2006.05.022>.

Morid, S., Smakhtin, V., & Moghaddasi, M. (2006). Comparison of seven meteorological indices for drought monitoring in Iran. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 26(7), 971-985.

Nalbantis, I. et G. Tsakiris, (2008). Assessment of hydrological drought revisited, *Water Resources Management*, 23(5):881–897.

OIEau, (2017). *Gestion de la ressource en eau*. Office International de l'Eau (OIEau).

OMM, (2012). *Guide d'utilisation de l'indice normalisé de précipitations*, Organisation météorologique mondiale (OMM), pp15-25.

Palmer, W. C. (1965). *Meteorological Drought*. Office of Climatology Research Paper No. 45, Washington DC: US Weather Bureau.

Paulo, A. A., & Pereira, L. S. (2007). Prediction of SPI drought class transitions using Markov chains. *Water Resources Management*, 21, 1813–1827. <https://doi.org/10.1007/s11269-006-9129-9>.

Pearson, K. (1901). LIII. On lines and planes of closest fit to systems of points in space. *The London, Edinburgh, and Dublin philosophical magazine and journal of science*, 2(11), 559-572.

Quinlan, J. R. (1986). Induction of decision trees. *Machine learning*, 1, 81-106.

Quiring SM, Papakyriakou TN. (2003). An evaluation of agricultural drought indices for the Canadian prairies. *Agricultural and Forest Meteorology* 118: 49–62.

Rao, A. R., & Padmanabhan, G. (1984). Analysis and modeling of Palmer's drought index series. *Journal of hydrology*, 68(1-4), 211-229.

Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. Doi: 10.1037/h0042519.

Salehnia, N., Zare, H., Kolsoumi, S., & Bannayan, M. (2018). Predictive value of Keetch-Byram Drought Index for cereal yields in a semi-arid environment. *Theoretical and applied climatology*, 134(3), 1005-1014.

Sruthi, S., & Aslam, M. M. (2015). Agricultural drought analysis using the NDVI and land surface temperature data; a case study of Raichur district. *Aquatic Procedia*, 4, 1258-1264.

Tayfur, G., & ALAMI, M. M. (2022). Meteorological Drought Analysis for Helmand River Basin, Afghanistan. *Teknik Dergi*, 33(4), 12223-12242.

Thom HCS (1958). A note on the gamma distribution. *Mon Weather Rev* 86:117–122

Thornthwaite, C. W. (1948). An approach toward a rational classification of climate. *Geographical review*, 38(1), 55-94.

Tian, Y., Xu, Y.-P., & Wang, G. (2018). Agricultural drought prediction using climate indices based on Support Vector Regression in Xiangjiang River basin. *Science of the Total Environment*, 622–623, 710–720. <https://doi.org/10.1016/j.scitotenv.2017.12.025>.

Trigo, R. M., Xoplaki, E., Zorita, E. et al. (2006): Relationship between variability in the Mediterranean region and mid-latitude variability, *Mediterranean Climate Variability*, Elsevier, B. V., 179–226, 2006.

UNCCD (2022). La sécheresse en chiffres. United Nations Convention to Combat Desertification (UNCCD), COP-15 Côte D'Ivoire.

Vapnik, V. N. (1995). *The Nature of Statistical Learning Theory*. Doi : 10.1007/978-1-4757-2440-0.

Vidal, J.-P., Martin, E., Franchiste´guy, L., Habets, F., Soubeyroux, J. M., Blanchardet, M., & Baillon, M. (2010). Multilevel land multiscale drought reanalyze is over France with the SAFRAN ISBA-MODCOU hydro meteorological suite. *Hydrology and Earth System Sciences*, 14, 459–478. <https://doi.org/10.5194/hess-14-459-2010>.

- Vidyarthi, V. K., & Jain, A. (2020). Knowledge extraction from trained ANN drought classification model. *Journal of Hydrology*, 585, 124804. <https://doi.org/10.1016/j.jhydrol.2020.124804>.
- Wang, T., Xinjun, Tu., Singh, V. P., Chen, X., & Lin, K. (2021). Global data assessment and analysis of drought characteristics based on CMIP6. *Journal of Hydrology*, 596, 126091. <https://doi.org/10.1016/j.jhydrol.2021.126091>.
- WMO, (1992). International meteorological vocabulary, 2nd edn. Publication no. 182. World Meteorological Organization (WMO), Geneva, p 784.
- WMO, (2006). Drought monitoring and early warning: Concepts, progress and future challenges Meteorological Organization. World Meteorological Organization (WMO), Geneva, Switzerland WMO-No (2006), p. 1006.
- Yoo, J., Kwon, H. H., Kim, T. W., & Ahn, J. H. (2012). Drought frequency analysis using cluster analysis and bivariate probability distribution. *Journal of Hydrology*, 420, 102-111.
- Zargar, S. T., Joshi, J., & Tipper, D. (2013). A Survey of Defense Mechanisms against Distributed Denial of Service (DDoS) Flooding Attacks. *IEEE Communications Surveys & Tutorials*, 15(4), 2046–2069. doi:10.1109/surv.2013.031413.0012.
- Zhai, J., Mondal, S. K., Fischer, T., Wang, Y., Su, B., Huang, J., Tao, H., Wang, G., Ullah, W., & Uddin, M. J. (2020). Future drought characteristics through a multi-model ensemble from CMIP6 over South Asia. *Atmospheric Research*, 246, 105111. <https://doi.org/10.1016/j.atmosres.2020.105111>.
- Zhang, L., Zhang, L., & Du, B. (2016). Deep Learning for Remote Sensing Data: A Technical Tutorial on the State of the Art. *IEEE Geoscience and Remote Sensing Magazine*, 4(2), 22–40. doi:10.1109/mgrs.2016.2540798.
- Durdu, Ö.F. (2010). Application of linear stochastic models for drought forecasting in the Büyük Menderes river basin, western Turkey. *Stoch Environ Res Risk Assess* 24, 1145–1162 <https://doi.org/10.1007/s00477-010-0366-3>

Annexes

Annexe A Phase 6 du Projet d'inter comparaison de modèles couplés (CMIP6)

A.1. Phase 6 du Projet d'inter comparaison de modèles couplés (CMIP6)

La sixième phase du Projet d'inter comparaison de modèles couplés (CMIP6) a été organisée par le Programme Mondial de Recherche sur le Climat (PMRC). Le PMRC coordonne les efforts des partenaires et des groupes de modélisation participant au CMIP. Avec le temps, à mesure que la participation au CMIP augmentait et que le nombre et la complexité des modèles climatiques augmentaient, le besoin d'expériences de plus en plus détaillées et organisées a fait en sorte que le CMIP est devenu un cadre intégré au sein duquel un certain nombre de projets d'inter comparaison de modèles (PCM) individuels sont organisés. Les PCM sont des ensembles d'expériences et de simulations conçus pour mettre à l'essai et comparer des aspects particuliers des modèles climatiques. Chaque PCM individuel établit un plan expérimental visant à améliorer la compréhension des éléments suivants :

- les processus physiques importants du système climatique ;
- la réponse du système climatique aux facteurs externes (comme l'augmentation des gaz à effet de serre).

Le CMIP6 comprend 23 PCM individuels. Les simulations futures des changements climatiques sont coordonnées au sein du « Scénario MIP » pour lequel environ 30 modèles climatiques ont fourni des résultats. En outre, les expériences de Diagnostic, d'Evaluation et de Caractérisation de Klima (DECK) sont au cœur du CMIP6, car elles impliquent les simulations passées (de 1850 à aujourd'hui) qui permettent d'évaluer la simulation du climat passé par le modèle. Bien que les PCM se voient accorder la priorité par le CMIP et que les organisations peuvent participer au nombre qu'elles souhaitent, les expériences DECK sont obligatoires pour que n'importe quel modèle entre dans le CMIP. Le schéma ci-dessous illustre la nature complexe et interconnectée du CMIP6.




Figure A.1. Les 5 grandes trajectoires socio-économiques des SSP.

A.2. Profils socioéconomiques partagés (SSP)

Les scénarios SSP (Shared Socio-economic Pathways) sont des narratifs, traduits en ensembles d'hypothèses socio-économiques (Population, Éducation, Urbanisation, PIB). Ces narratifs décrivent des évolutions alternatives de la société future en l'absence de changement climatique ou de politique climatique. Cinq narratifs ont été construits par le GIEC, chacun étant numéroté de 1 à 5 :

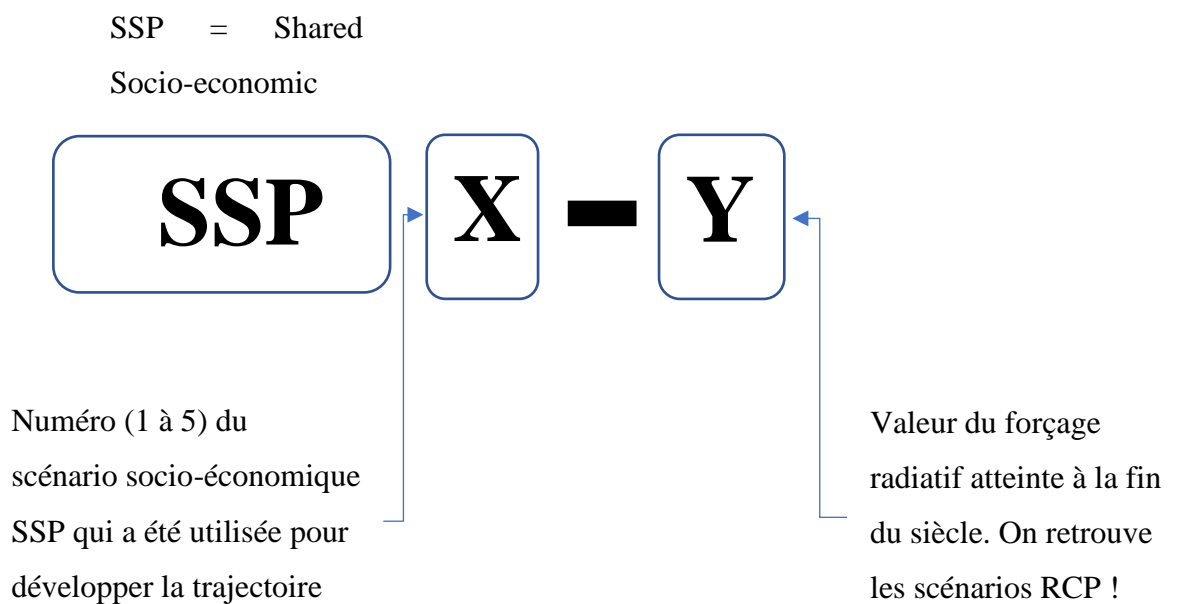
- Les SSP1 et SSP5 envisagent des tendances relativement optimistes pour le développement humain, avec des investissements substantiels dans l'éducation et la santé, une croissance économique rapide et des institutions qui fonctionnent bien. Cependant, le SSP5 suppose une économie à forte intensité énergétique et basée sur les combustibles fossiles, alors que le SSP1 prévoit une évolution croissante vers des pratiques durables.

- Les SSP3 et SSP4 envisagent des tendances de développement plus pessimistes, avec peu d'investissements dans l'éducation ou la santé, une croissance démographique rapide et des inégalités croissantes. Dans le SSP3, les pays donnent la priorité à la sécurité régionale, tandis que dans le SSP4, les grandes inégalités au sein des pays et entre pays dominant, conduisant dans les deux cas à des sociétés qui sont hautement vulnérables au changement climatique.

- Le scénario SSP2 envisage une trajectoire intermédiaire dans laquelle les tendances se poursuivent sans déviations substantielles.

Les projections climatiques sont présentées sur la base de ces scénarios, selon le terme « SSPx y » avec x le numéro du SSP et y le niveau de forçage radiatif approximatif en 2100.

Les projections climatiques sont présentées sur la base de ces scénarios, selon le terme « SSPx y » avec x le numéro du SSP et y le niveau de forçage radiatif approximatif en 2100.



SSPx-y est l'abréviation d'un scénario, où x est le numéro (1 à 5) du scénario socio-économique SSP qui a été utilisée pour développer la trajectoire d'émissions, et y indique la valeur approximative du forçage radiatif (en W/m²) atteint à la fin du siècle. Un « scénario SSPx-y » est ainsi une trajectoire d'émissions de GES et de réchauffement associé.

A.2.1. Les 5 scénarios principaux du GIEC

Les cinq scénarios retenus par le GIEC sont les suivants :

- Deux scénarios avec des émissions de GES élevées et très élevées SSP3-7.0 et SSP5 8.5
- Un scénario avec des émissions de GES intermédiaires : SSP2-4.5
- Deux scénarios avec des émissions de GES très faibles et faibles : SSP1-1.9 et SSP1-2.6.

Aucune projection présentée dans le résumé pour décideur ne dérive du scénario SSP4, mais le CMIP6 fournit un set de données pour 9 scénarios dont 2 issus du SSP4 (SSP4-3.4 et SSP4-6.0).




Figure A.2. Trajectoires de réchauffement planétaire selon les cinq scénarios SSPx-y retenus dans le résumé pour décideur du GIEC.

Annexe B Modèles statistiques

B.1. ARMA, ARIMA et SARIMA

Dans cette section, nous présenterons trois modèles différents - ARMA, ARIMA et SARIMA - pour la prévision des séries temporelles. D'une manière générale, les fonctionnalités de ces modèles peuvent être résumées comme suit :

- ARMA : Autorégressif + Moyenne mobile
- ARIMA : Autorégressif + Moyenne mobile + Différenciation des tendances
- SARIMA : Autorégressive + Moyenne mobile + Différenciation des tendances + Différenciation saisonnière

B.1.1. ARMA - Modèle de base

ARMA signifie Autoregressive Moving Average (moyenne mobile autorégressive), est un processus qui permet de modéliser les séries temporelles stationnaires. Comme son nom l'indique, il s'agit d'une combinaison de deux éléments :

- **Modèle autorégressif - AR(p)**

Le modèle autorégressif fait des prédictions basées sur les valeurs observées précédemment, ce qui peut être exprimé par AR(p) :

$$AR(X_t, p) = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \phi_3 X_{t-3} + \dots + \phi_p X_{t-p} \quad (\text{A.1})$$

Où p spécifie le nombre de points de données précédents à examiner. Comme indiqué ci-dessus, X représente les observations des points temporels précédents et ϕ représente les poids.

- **Modèle de moyenne mobile - MA(q)**

Le modèle de moyenne mobile, MA(q), ajuste le modèle sur la base de la moyenne des erreurs de prédiction des q observations précédentes, qui peut être exprimée comme suit :

$$MA(X_t, q) = e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (\text{A.2})$$

Où e représente les termes d'erreur et θ les pondérations. La valeur q détermine le nombre de termes d'erreur à inclure dans la fenêtre de la moyenne mobile.

B.1.2. ARIMA : Tendances de l'évolution

ARIMA signifie Autoregressive Integrated Moving Average (moyenne mobile intégrée autorégressive). Il s'agit d'une extension du modèle ARMA qui incorpore la composante intégrée (inverse de la différenciation). ARIMA, est un modèle statistique utilisé pour analyser les données des séries temporelles ou chronologiques en vue de faire des prédictions.

L'ARIMA s'appuie sur le modèle autorégressif (AR) et le modèle de moyenne mobile (MA) en introduisant des composantes de degré de différenciation (spécifiées par le paramètre d) - ARIMA (p, d, q). Cela permet de traiter les cas où une tendance évidente a été observée dans les données de la série temporelle.

B.1.3. SARIMA : Traiter la saisonnalité

Le modèle SARIMA (Seasonal Auto-Regressive Integrated Moving Average) est une extension du modèle ARIMA (Autoregressive Integrated Moving Average) qui intègre la saisonnalité en plus des composantes non saisonnières. Les modèles ARIMA sont largement utilisés pour l'analyse et la prévision des séries temporelles, tandis que les modèles SARIMA sont spécifiquement conçus pour traiter les données présentant des schémas saisonniers.

B.2. Modèles Markoviens à états cachés (Hidden Markov Model- HMM)

Les Modèles de Markov Cachés (MMC) sont utilisés pour modéliser des séquences d'observation. Ces observations peuvent être de nature discrète (par exemple les caractères d'un alphabet fini) ou continue (fréquences d'un signal, températures). MMC est une chaîne de Markov dont les états ne sont pas déterminés mais qui génèrent une suite de variables aléatoires (suite d'observations) indépendantes deux à deux.

Un MMC est un modèle stochastique particulier, il est composé de deux suites de variables aléatoires, la première est cachée et la deuxième est observable.

- La suite cachée correspond à la suite d'états q_1, q_2, \dots, q_r où les q_i prennent leurs valeurs parmi l'ensemble des N états i indice temps du modèle
- La suite observable correspond à la suite d'observations O_1, O_2, \dots, O_t où les O_i sont aussi en fonction du temps et se réalisent parmi un ensemble de M symboles.

B.3. Modèles GARCH

Les modèles GARCH (Generalized Autoregressive Conditional Heteroskedasticity), jouent un rôle crucial dans la compréhension et la modélisation de la dynamique de l'hétéroscédasticité conditionnelle dans les données de séries chronologiques financières. Ces modèles ont gagné en popularité dans le domaine de l'économétrie et de la finance en raison de leur capacité à capturer les modèles de volatilité variables dans le temps observés sur les marchés financiers.

L'hétéroscédasticité conditionnelle fait référence au phénomène dans lequel la variance d'une variable aléatoire n'est pas constante mais varie dans le temps, en fonction des informations disponibles à un moment donné. Ce concept est particulièrement pertinent sur les marchés financiers, où la volatilité peut présenter des périodes de forte volatilité suivies de périodes de faible volatilité.

Les modèles GARCH fournissent un cadre pour capturer et modéliser la volatilité variable dans le temps. Ils se composent de deux composantes principales :

La composante autorégressive ARCH qui capture les erreurs quadratiques décalées, reflétant la persistance des chocs de volatilité.

La composante GARCH qui capture les variances conditionnelles décalées, capturant l'impact de la volatilité passée sur la volatilité actuelle.

Ces deux composantes fonctionnent ensemble pour modéliser la variance conditionnelle de la série.

L'estimation des modèles GARCH implique de trouver les paramètres optimaux qui minimisent la différence entre les variances conditionnelles réelles et prédites. Diverses techniques d'estimation sont disponibles, notamment l'estimation du maximum de

vraisemblance (MLE), largement utilisée en raison de ses propriétés statistiques souhaitable. MLE estime les paramètres qui maximisent la fonction de vraisemblance, qui mesure la probabilité d'observer les données sous le modèle GARCH supposé.

Résumé

Le travail présenté dans cette thèse est une analyse spatio-temporelle du phénomène sec/humide de la période des pluies dans le Nord de l'Algérie pour prédire la sécheresse. A cette fin, nous avons mis en œuvre des réseaux neuronaux artificiels (RNA) pour analyser le comportement des processus. Pour une étude comparative, nous avons également analysé le comportement du phénomène sec/humide de la période des pluies en utilisant des chaînes de Markov (CM). Le phénomène sec/humide est divisé en 9 catégories obtenues en fonction des valeurs de l'indice SPI. La base de données est construite à partir des estimations satellitaires des taux de précipitations sur une période allant de 1985 à 2021. Pour évaluer la performance des deux méthodes, des prévisions à court terme ont été déterminées et comparées aux données satellitaires réelles. Les paramètres d'évaluation utilisés montrent que les prédictions obtenues correspondent aux données réelles, tant pour la méthode de la chaîne de Markov que pour celle du réseau neuronal. Nous avons ensuite prédit le phénomène sec/humide à long terme, de 2022 à 2050. Les résultats de la prédiction à long terme du phénomène sec/humide réalisée par ANN et CM sont comparés aux simulations données par la phase 6 du projet d'inter comparaison de modèles couplés CMIP6 sous les scénarios, profils socio-économiques partagés SSP126. L'orientation générale est identique pour les 3 modèles indiquent que les zones représentant des surfaces sèches gagnent du terrain au détriment des zones humides avec une légère différence.

Mots clés : Sécheresse, RNA, chaîne de Markov, prédiction

Abstract

The work presented in this thesis is a spatiotemporal analysis of the dry/wet phenomenon of the rainy period in northern Algeria to predict the drought. To that end, we implemented artificial neural networks (ANN) to analyze the behavior of processes. For a comparative study, we also analyzed the behavior of the dry/wet phenomenon of the rainy period using Markov chains (MC). The dry/wet phenomenon is divided into 9 categories obtained according to the values of SPI (Standard Precipitation Index). The database is built from satellite estimates of precipitation rates over a period from 1985 to 2021. To assess the performance of the two methods, short-term predictions were determined and compared to actual satellite data. The evaluation parameters used show that the predictions obtained correspond to real data for both the Markov chain method and the neural network method. We then predicted the long-term dry/wet phenomenon, from 2022 to 2050. The long-term prediction results of the dry/wet phenomenon performed by ANN and MC are compared to the simulations given by the coupled multi-model inter-comparison project version 6 (CMIP6) under scenarios, shared socioeconomic pathways SSP126. The overall orientation is identical for the three models (ANN, MC and CMIP6). Indeed, the prediction results performed by the three models indicate that areas representing dry surfaces are gaining ground at the expense of wetlands with a slight difference.

Keywords: Drought, ANN, Markov Chain, Prediction.