

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE  
**Ministère de l'Enseignement Supérieur et de la Recherche Scientifique**



**UNIVERSITE BADJI MOKHTAR ANNABA**



**FACULTE** : Sciences de la Terre

**DEPARTEMENT** : Géologie

**DOMAINE** : Sciences de la Terre et de l'Univers

**FILIERE** : Géologie

**SPECIALITE** : Hydrogéologie

Laboratoire des Ressource en Eau et Développement Durable

**THESE**

**Préparée en vue de l'obtention du diplôme de Doctorat LMD**

**Estimation et Modélisation de l'Indice de Sécheresse  
à l'aide de différents modèles d'Intelligence  
Artificielle (IA) dans le Bassin du Hodna**

Présentée par:

**Ladouali Sabrina**

Devant le jury composé de:

**Président:**

**Directeur de thèse:**

**Co-Directeur de Thèse:**

**Examineurs:**

Pr Azzedine HANI

Pr Hicham CHAFFAI

Pr Bachir SAKAA

Pr Nabil BOUGHERIRA

Pr Ammar MAOUI

Pr Lassaad GHRIEB

Université Badji Mokhtar Annaba

Université Badji Mokhtar Annaba

C.R.S.T.R.A - Biskra

Université Badji Mokhtar Annaba

Université 19 mai 1945 Guelma

Université 19 mai 1945 Guelma

**Soutenu le 08/07/2025**

## **Remerciements**

*Avant tout, je remercie Dieu pour m'avoir accordé la force, la patience et la sagesse nécessaires à l'accomplissement de ce travail.*

*Je tiens à exprimer ma profonde gratitude à mon encadrant, le Professeur Chaffai Hicham, pour ses orientations précieuses et ses encouragements constants tout au long de ce parcours.*

*Je remercie également mon co-encadrant, le Professeur Sakka Bachir, pour ses directives avisées, ses informations pertinentes, son soutien sans faille et ses encouragements précieux.*

*Je profite de cette occasion pour exprimer ma reconnaissance à tous les enseignants qui ont contribué à ma formation tout au long de mon parcours universitaire.*

*Je souhaite également remercier chaleureusement tous ceux qui ont contribué, de près ou de loin, à la réussite de ce travail, notamment le Professeur Ahmed Elbaltaji et le Dr. Salem Ali, pour leur aide et leur collaboration précieuse. Un grand merci à mes co-auteurs, en particulier le Dr. Oken Meret Katipoglu, le Professeur Mehdi Bahrami, le Pr. Mehdi Keblouti et le Dr. Veysi Kartal, pour leur collaboration fructueuse.*

*Enfin, je tiens à adresser une pensée affectueuse à ma famille, en particulier à mes parents et à toute la famille LADOUALI, pour leur soutien indéfectible, leurs encouragements constants et leur confiance inébranlable.*

## *Dédicace*

*Je dédie ce travail à mes chers parents, dont l'amour, le soutien inconditionnel et les sacrifices m'ont permis de poursuivre mes rêves.*

*À mes sœurs, pour leur affection, leur encouragement constant, et pour être à mes côtés à chaque étape de ce parcours.*

*À mes amis, pour leur précieuse amitié, leur soutien moral, et les moments de joie partagés.*

*Enfin, à toutes les personnes qui ont cru en moi, qui ont attendu mon succès et m'ont encouragé tout au long de ce chemin. Votre confiance et vos encouragements ont été ma plus grande force.*

يمكن إدارة الآثار السلبية للجفاف على الموارد المائية والزراعة والنظم الإيكولوجية وإنتاج الطاقة بفعالية من خلال التنبؤ بحدوثه في المستقبل، مما يمكن أن يساعد أيضا على منع المخاطر المحتملة. أصبحت تقنيات الحوسبة اللينة هي الطريقة المفضلة لإنتاج التنبؤات نظراً لقدرتها على تقليل وقت التطوير إلى الحد الأدنى، وتتطلب الحد الأدنى من البيانات وتقدم نهجاً أقل تعقيداً نسبياً مقارنة بالنماذج الديناميكية أو الفيزيائية. في هذه الدراسة، تم اقتراح نهج VMD-ELM الهجين، الذي تم إنشاؤه من خلال الجمع بين تقنية تحليل الوضع المتغير (VMD) وآلة التعلم المتطرف الخوارزمية (ELM) كتقنية المعالجة المسبقة، للتنبؤ بالجفاف في المستقبل. أولاً، تم تقدير قيم SPI لمدة 6 أشهر و 12 شهراً، وقيم زمنية لمدة شهر وشهرين و 3 أشهر باستخدام خوارزمية ELM. بعد ذلك، يتم تقديم متغيرات الطقس وقيم SPI، مقسمة إلى مكونات فرعية مع VMD، إلى نموذج ELM، ويتم تطوير نموذج التنبؤ بالجفاف. ونتيجة لذلك، تم تقييم تأثير مجموعات مختلفة من المدخلات وقيم مؤشر أسعار الصرف على التنبؤ بمؤشرات الجفاف في المستقبل. تم تقييم أداء النموذج باستخدام معايير بصرية وإحصائية مختلفة. حدد التحليل أنه يتم الحصول على أكبر دقة تنبؤ بشكل عام باستخدام نماذج VLD-ELM وتنبؤات SPI في غضون شهر واحد. وتوفر نتائج الدراسة رؤى هامة للمانحين بشأن تخطيط الموارد المائية واستراتيجيات التكيف مع تغير المناخ.

#### الكلمات المفتاحية

مؤشر هطول الأمطار القياسي (SPI)، التنبؤ بالجفاف، التعلم الآلي الشديد، تقسيم البيانات، تخطيط موارد المياه، تغير المناخ، حوض الحضنة.

### « Estimation et Modélisation de l'Indice de Sécheresse à l'Aide de différents modèles d'Intelligence Artificielle, Chott El Hodna »

#### RÉSUMÉ

Les conséquences négatives de la sécheresse sur les ressources en eau, l'agriculture, les écosystèmes et la production d'énergie peuvent être gérées efficacement en prédisant son occurrence dans le futur, ce qui peut également aider à prévenir les risques potentiels. Les techniques d'informatique douce sont devenues la méthode préférée pour produire des prévisions en raison de leur capacité à minimiser le temps de développement, à exiger des données minimales et à offrir une approche relativement moins complexe par rapport aux modèles dynamiques ou physiques. Dans cette étude, une approche hybride VMD-ELM, établie en combinant la technique de décomposition en mode variationnel (VMD) et l'algorithme Extreme Learning Machine (ELM) comme technique de prétraitement, est proposée pour prédire les sécheresses futures. Tout d'abord, les valeurs SPI à 6 et 12 mois, les valeurs de délai de 1, 2 et 3 mois ont été estimées à l'aide de l'algorithme ELM. Ensuite, les variables météorologiques et les valeurs SPI, divisées en sous-composantes avec VMD, sont présentées au modèle ELM, et un modèle de prévision de la sécheresse est développé. En conséquence, l'effet de diverses combinaisons d'entrées et de valeurs SPI sur la prévision des futurs indices de sécheresse a été évalué. Les performances du modèle ont été évaluées selon divers critères visuels et statistiques. L'analyse a permis de déterminer que les plus grandes précisions de prédiction sont généralement obtenues avec les modèles VLD-ELM et les prédictions SPI avec un délai d'un mois. Les résultats de l'étude donnent des idées importantes aux bailleurs de fonds en ce qui concerne la planification des ressources en eau et les stratégies d'adaptation au changement climatique.

**Mots-clés :** Indice de précipitations standard (SPI), prévision de la sécheresse, apprentissage automatique extrême, décomposition des données, planification des ressources en eau, changement climatique, Bassin Hodna.

**« Assessment & Modelling of Drought Index using different AI Models, Chott El Hodna as case study »**

**ABSTRACT**

The negative consequences of drought on water resources, agriculture, ecosystems, and energy production can be effectively managed by predicting its occurrence in the future, which can also help prevent potential risks. Soft computing techniques have become the preferred method for producing predictions due to their ability to minimize development time, require minimal input, and offer a relatively less complex approach when compared to dynamic or physical models. In this study, a hybrid VMD-ELM approach, established by combining the Variational Mode Decomposition (VMD) technique and the Extreme Learning Machine (ELM) algorithm as a preprocessing technique, is proposed for predicting future droughts. First, 6 and 12-month SPI values, 1, 2, and 3-month lead time values were estimated with the ELM algorithm. After that, meteorological variables and SPI values, divided into subcomponents with VMD, are presented to the ELM model, and a drought forecasting model is developed. Accordingly, the effect of various input combinations and SPI values on predicting future drought indices was evaluated. Model performances were evaluated according to various visual and statistical criteria. As a result of the analysis, it has been determined that the highest prediction accuracies are generally obtained in VLD-ELM models and SPI predictions with a 1-month lead time. The study outputs give important ideas to mite donors regarding water resource planning and climate change adaptation strategies.

**Keywords:** Standard Precipitation Index (SPI), Drought Forecasting, Extreme Machine Learning, Data Decomposition, Water Resources Planning, Climate Change, Hodna basin.

## Liste des Abréviations

---

### Liste des Abréviations

PDSI	Palmer Drought Severity Index (indice de gravité de la sécheresse de Palmer)
SPI	Standardized Precipitation Index (indice standardisé des précipitations)
SWSI	Surface Water Supply Index ('indice d'approvisionnement en eau de surface)
CZI	Chine-Z Index (indice Chine-Z)
MCZI	Modified China-Z Index (indice Chine-Z modifié)
EDI	Effective Drought Index (indice de sécheresse effective)
ADI	Agricultural Drought Index (Indice de Sécheresse Agricole)
RDI	Reconnaissance Drought Index (indice de reconnaissance de la sécheresse)
IA	Intelligence Artificielle
SPEI	Standardized Precipitation Evapotranspiration Index (indice des précipitations et d'évapotranspiration de sécheresse)
SSI	Standardized Streamflow Index (Indice Standardisé d'Écoulement Fluvial)
PMDI	Palmer Modified Drought Index (Indice de Sécheresse Modifié de Palmer)
SVM	Support Vector Machine (machines à vecteurs de support)
ANFIS	Adaptive Neuro-Fuzzy Inference System (systèmes d'inférence floue neuronale adaptative)
RF	Random Forest (forêt aléatoire)
DT	Descision tree (arbres de décision)
SVR	Support Vector Regression (la régression vectorielle de soutien)
ANN	Artificial Neural Network (réseaux neuronaux artificiels)
WNN	Wavelet Neural Network (réseau neuronal à ondelettes)
BP	Backpropagation
DBN	Deep Belief Network (Réseau de croyances profondes)
ARIMA	AutoRegressive Integrated Moving Average (Moyenne mobile intégrée auto-régressive)
SARIMA	Seasonal AutoRegressive Integrated Moving Average (Saisonnier AutoRegressive Moyenne mobile intégrée)
RMSNN	Recurrent Multi-Scale Neural Network (réseaux neuronaux récurrents à plusieurs étapes)
DMSNN	Deep Multi-Scale Neural Network (réseaux neuronaux profondes à plusieurs étapes)
MLPNN	Multi-Layer Perceptron Neural Network (réseau neuronal perceptuel multicouche)
CANFIS	Coactive Neuro-Fuzzy Inference System (système d'inférence neuro-floue coactif)
MLR	Multiple Linear Regression (régression linéaire multiple)
MPMR	(Minimum Probability Machine Regression) régression de machine à probabilité minimale

## Liste des Abréviations

---

ELM	Extreme Learning Machine machine d'apprentissage extrême
OSELM	Online Sequential Extreme Learning Machine (ELM séquentiel en ligne)
PHDI	Plant Hydric Deficit Index (Indice de Stress Hydrique des Plantes)
RAI	Rainfall Anomaly Index (Indice d'Anomalie des Précipitations)
CMI	Crop Moisture Index (Indice d'Humidité des Cultures)
BMDI	Bhalme and Mooley Drought Index (Indice de Sécheresse de Bhalme et Mooly)
SWSI	Surface Water Supply Index (Indice d'Approvisionnement en Eau de Surface)
NRI	National Rainfall Index (Indice National des Précipitations)
RDI	Reclamation Drought Index (Indice de Remise en État de la Sécheresse)
SMDI	Soil Moisture Drought Index (Indice d'Humidité du Sol)
CSDI	Crop-Specific Drought Index (Indice de Sécheresse Spécifique aux Cultures)
MCG	modèles de circulation générale
EEA	European Environment Agency
SRI	standardized runoff index (indice standardisé de ruissellement)
ML	machine learning
XGB	XGBoost (Extreme Gradient Boosting)
CNN	Convolutional Neural Network (Réseau Neuronal Convolutif)
LSTM	Long Short-Term Memory (Mémoire à Long et Court Terme )
DLSTM	Dynamic Linear Spatio-Temporal Model (Modèle Dynamique Linéaire Spatio-Temporelle )
SHDI	Standardized Hydrological Drought Index (Indice Standardisé de la Sécheresse Hydrologique)
WA-ANN	Wavelet Artificial Neural Network
OS-ELM	Online Sequential Extreme Learning Machine (Machine à Apprentissage Extrême Séquentiel en Ligne)
SADE-ELM	Self-Adaptive Differential Evolution Extreme Learning Machine (Machine à Apprentissage Extrême avec Évolution Différentielle Auto-Adaptive)
ANFIS	Adaptive Neuro-Fuzzy Inference System (Système d'Inférence Neuro-Flou Adaptatif )
SSTA	Sea Surface Temperature Anomalies (Anomalies de la Température de Surface de la Mer )
IDFV	Independent Drought Forecasting Variables (Variables Indépendantes de Prévision de la Sécheresse)
NDVI	Normalized Difference Vegetation Index (Indice de Végétation par Différence Normalisée)
PCA	Principal Component Analysis (Analyses en Composantes Principales)

## Liste des Abréviations

---

t-SNE	T-distributed Stochastic Neighbor Embedding
OMM	Organisation Météorologique Mondiale
SLFN	Single-Layer Feedforward Neural Network
SVD	Singular Value Decomposition (Décomposition par Valeur Singulière)
MSE	Mean Squared Error (Erreur Quadratique Moyenne)
MAPE	Mean Absolute Percentage Error (Erreur Absolue Moyenne en Pourcentage)
MAE	Mean Absolute Error (Erreur Absolue Moyenne)
MBE	Mean Bias Error (Erreur de Biais Moyenne)
ONM	organisation météorologique nationale
VMD	Variable Mode Decomposition (Décomposition en Modes Variés )
DWT	Discrete Wavelet Transform (Transformée en Ondelettes Discrète)
WPT	Wavelet Packet Transform (Transformée en Paquets d'Ondelettes)
sc-PDSI	Self-Calibrating Palmer Drought Severity Index (Indice de Gravité de la Sécheresse de Palmer Auto-Calibré)
DBN	Deep Belief Networks (Réseaux de Croyance Profonds)
EMD	Empirical Mode Decomposition (Décomposition en Mode Empirique)
GEP	Genetic Programming Expression (Programmation de l'Expression Génétique)
QR	QR Decomposition (Décomposition Matricielle Triangulaire Orthogonale)
OS	Online Sequential (Mécanisme d'Apprentissage en Ligne)

**Liste des figures**

<b>Figure 1.</b>	Propagation entre les types de sécheresse.....	8
<b>Figure 2.</b>	Carte de localisation des stations d'étude dans le bassin du Hodna.....	28
<b>Figure 3.</b>	Flowchart de la Collecte, Visualisation et Analyse des Données Météorologiques.....	29
<b>Figure 4.</b>	Tendances mensuelles des précipitations pour six stations (1981-2020).....	31
<b>Figure 5.</b>	Diagrammes en violon de divers paramètres de données météorologiques des stations.....	36
<b>Figure 6.</b>	Nuage de points 3D des données avec ACP.....	37
<b>Figure 7.</b>	Graphique 3D t-SNE des données.....	38
<b>Figure 8.</b>	SPI time séries à 6-et 12-mois.....	45
<b>Figure 9.</b>	Structure du modèle d'une machine d'apprentissage extrême (ELM).....	48
<b>Figure 10.</b>	Décomposition de certaines variables d'entrée dans la station AH avec VMD.....	54
<b>Figure 11.</b>	Comparaison de l'SPI prévue et mesurée à l'aide des modèles ELM et VMD- ELM pour la station Ain Elhadjel.....	57
<b>Figure 12.</b>	Comparaison du SPI prévu et mesuré à l'aide des modèles ELM et VMD-ELM pour la station Bou Saada.....	59
<b>Figure 13.</b>	Comparaison de l'SPI prévue et mesurée à l'aide des modèles ELM et VMD- ELM pour la station El Kantara.....	61
<b>Figure 14.</b>	Comparaison de l'SPI prévue et mesurée à l'aide des modèles ELM et VMD- ELM pour la station Msaad.....	63
<b>Figure 15.</b>	Comparaison de l'SPI prévue et mesurée à l'aide des modèles ELM et VMD- ELM pour la station M'doukel.....	65
<b>Figure 16.</b>	Comparaison de l'SPI prévue et mesurée à l'aide des modèles ELM et VMD- ELM pour la station M'sila.....	67
<b>Figure 17.</b>	Graphiques polaires de l'estimation de l'SPI des stations Ain Elhadjel, Msaad et Bou Saada.....	69
<b>Figure 18.</b>	Graphiques polaires de l'estimation SPI des stations El Kantara, M'sila et M'doukel.....	71
<b>Figure 19.</b>	Comparaison des résultats des prévisions de l'indice de sécheresse avec les séries chronologiques.....	73

## Liste des Tableaux

---

### Liste des Tableaux

<b>Tableau 1.</b>	Coordonnées, Elévation et ID des stations Sélectionnées.....	33
<b>Tableau 2.</b>	Statistiques des facteurs recueillis pour six stations (1981-2020).....	33
<b>Tableau 3.</b>	Tableau des SPI.....	43
<b>Tableau 4.</b>	Résultats des essais des modèles ELM.....	55

## Sommaire

<b>Introduction Générale.....</b>	<b>1</b>
<b>Chapitre 1. Sècheresse &amp; Généralités.....</b>	<b>5</b>
1.1 Introduction .....	5
1.2. Définition de la Sècheresse .....	6
1.3. Conception mathématique de la Sècheresse .....	6
1.4. Différents Modèles de Sècheresses.....	7
1.5. Les Etudes de la Sècheresse en régions Maghrébine .....	9
1.6. Causes de la Sècheresse .....	10
1.7. Impact de Sècheresse .....	12
1.8. Conclusion .....	13
<b>Chapitre 2. Etat de l’art sur les Modèles de prévision de la sècheresse.....</b>	<b>15</b>
2.1. Introduction .....	15
2.2. Les Modèles de Prévision de la sècheresse .....	15
2.3. Variables Indépendantes pour la prévision de sècheresse.....	22
2.4. Variable dépendante de prévision de la sècheresse.....	23
2.5. L’historique de la prévision par les modèles d’IA .....	24
2.6. Conclusion.....	25
<b>Chapitre 3. Zone d’étude &amp; Base de données.....</b>	<b>27</b>
3.1. Introduction .....	27
3.2. Présentation de la zone d’étude.....	27
3.3. Processus de Collecte et Analyse des Données Météorologiques pour la Prévision de la Sècheresse.....	29
3.4. Présentation et Critique de la base de données.....	30
3.5. Indice de précipitation standardisé.....	40
3.6. Conclusion.....	46
<b>Chapitre 4. Prévision de la sècheresse par les techniques de l’IA.....</b>	<b>47</b>
4.1. Introduction.....	47
4.2. Extrême Learning Machine (ELM).....	47
4.3. Variable Mode Décomposition (VMD).....	50
4.4. Indicateurs de performance.....	50
4.5.Sélection des variables indépendantes et description de la base des données.....	51
4.6. Résultats.....	52
4.7. Discussion.....	78

## Sommaire

---

4.8. Conclusion.....	81
Conclusion Générale.....	83
Références bibliographiques.....	85

### Introduction Générale

La sécheresse est l'un des problèmes hydrologiques les plus graves (Khan et al., 2020 ; Mishra et Desai, 2005), car elle est répandue et en augmentation sans cesse dans le monde entier. Parmi ses raisons les plus importantes figurent les fluctuations des précipitations et leur pénurie résultant des changements climatiques et de la diminution des réserves d'eau (Coşkun et Citakoglu, 2023 ; Katipoğlu, 2023). En raison de son importance pour la survie de toutes les formes de vie sur Terre, le manque d'eau ou la difficulté à l'obtenir a des répercussions négatives sur de nombreux domaines, notamment l'agriculture, l'industrie, l'écosystème et la vie quotidienne de la population (Guha-Sapir et al., 2011 ; Tabari et al., 2013).

1

Selon les différentes perspectives disciplinaires, la définition de la sécheresse qui peut se produire peut-être classée en quatre groupes, chacun avec ses caractéristiques spécifiques. Premièrement, nous trouvons la sécheresse météorologique, qui est associée à un manque de précipitations, avec une période prolongée de faibles précipitations par rapport à la normale. Dans le deuxième groupe, on trouve la sécheresse hydrologique, qui se traduit par le manque de ressources en eau dans les rivières, les lacs et les nappes phréatiques. Elle survient lorsque les précipitations sont insuffisantes pendant une longue période. Troisièmement, le manque important d'humidité du sol peut être appelé sécheresse agricole, qui nuit à la croissance de la couverture végétale et des cultures (Wilhite et al, 1987). Enfin, l'effet de la pénurie d'eau sur les activités humaines et les systèmes sociaux et économiques est appelé sécheresse sociale et économique, cette sécheresse a de nombreuses répercussions négatives sur le plan socio-économique.

Les indices de sécheresse font partie des outils essentiels pour surveiller, évaluer et atténuer les effets de la sécheresse sur un bassin hydrographique ou un écosystème. Ces indices présentent plusieurs avantages dans la mesure où ils contribuent à une meilleure gestion des ressources en eau et apportent des solutions aux effets du changement climatique sur l'agriculture et l'industrie (Al, 2014). Plusieurs indices et méthodes ont été développés et utilisés pour mieux identifier et analyser les caractéristiques de la sécheresse, en prenant uniquement en compte les précipitations comme données d'entrée

; parmi ces indices, on trouve l'indice de gravité de la sécheresse de Palmer (Palmer, 1965), l'indice standardisé des précipitations connu sous le nom de SPI (McKee et al. 1993), l'indice d'approvisionnement en eau de surface (SWSI), l'indice Chine-Z (CZI) et l'indice Chine-Z modifié (MCZI), l'indice Z-score (Hayes, 2001) et l'indice de sécheresse effective (EDI) (Byun et Wilhite, 1999). En outre, certains indices prennent en compte des paramètres comme données d'entrée, tels que les précipitations, l'évapotranspiration et la disponibilité de l'eau.

2

Nous pouvons citer l'agrégat complet multivarié (ADI) proposé par (Keyantash et Dracup, 2004). Cet indice prend en compte plusieurs paramètres, à savoir les précipitations, le débit des cours d'eau, le stockage dans les réservoirs, l'évapotranspiration de la surface terrestre, l'humidité du sol, la teneur en eau de la neige et l'indice de reconnaissance de la sécheresse (RDI) (Tsakiris et al., 2007). Ce dernier indice considère le paramètre de l'évapotranspiration potentielle avec les précipitations comme base des données.

Ces dernières années, l'utilisation de modèles d'intelligence artificielle IA a augmenté pour l'estimation des paramètres hydrologiques, y compris les débits des cours d'eau, le niveau des eaux souterraines, les précipitations, etc. (Apaydin et al., 2021 ; Nourani et al., 2014). Ceci est dû à la capacité de ces modèles à améliorer la précision des prédictions et à contribuer à la compréhension de processus hydrologiques complexes. Parmi les caractéristiques du phénomène de la sécheresse, nous constatons qu'il est multivarié, non linéaire et aléatoire. Par conséquent, plusieurs modèles d'apprentissage automatique se sont révélés prometteurs pour prédire avec précision les conditions de sécheresse à l'aide de divers indices, tels que l'indice des précipitations standardisées (SPI), l'indice des précipitations et d'évapotranspiration de sécheresse (SPEI), Standardized Streamflow Index (SSI), Palmer Modified Drought Index (PMDI) et Palmer Drought Severity Index (PDSI).

Ces modèles comprennent les réseaux neuronaux (Hosseini-Moghari & Araghinejad, 2015 ; Mishra & Desai, 2006), les machines à vecteurs de support (SVM), les systèmes d'inférence floue neuronale adaptative (ANFIS) (Ali et al, 2018), la forêt aléatoire (RF)

(Rhee et Im, 2017), les arbres de décision (DT) (Gyaneshwar et al., 2023) et la régression vectorielle de soutien (SVR) (Xu et al., 2018), un bon nombre de ces modèles ont été appliqués et comparés dans de nombreuses études sur la sécheresse. Dans une étude réalisée sur le bassin de la rivière Awash en Éthiopie, (Belayneh et Adamowski, 2012), trois modèles ont été utilisés et comparés, à savoir les réseaux neuronaux artificiels (ANN), la régression à vecteur de support (SVR) et le réseau neuronal à ondelettes (WNN), pour prévoir le SPI.

3

(WN) pour prévoir les valeurs SPI sur plusieurs pas de temps. Les résultats de la comparaison ont montré que le réseau de neurones en ondelettes (WNN) a donné une meilleure estimation par rapport aux autres modèles. Pour trouver le meilleur modèle pour la prévision de la sécheresse pour le bassin de la rivière Huaihe, en Chine, Chen et al., (2012) ont comparé deux modèles, le réseau neuronal BP (Backpropagation) et le modèle DBN (Deep Belief Network), le dernier modèle a montré ses compétences pour la prédiction de l'indice de sécheresse (SPI) avec différentes échelles de temps, pour une bonne prédiction des sécheresses futures dans le bassin de la rivière Selangor en Malaisie, Hong et Hong, (2016) ont utilisé le modèle de réseau neuronal artificiel multicouche pour prédire les valeurs SPI pour des durées de 3 à 9 mois, les résultats ont montré que le modèle Mishra et Desai,(2006) ont essayer de comparer les modèles stochastiques linéaires (ARIMA/SARIMA), les réseaux neuronaux récurrents à plusieurs étapes (RMSNN) et les réseaux neuronaux directs à plusieurs étapes (DMSNN) pour prévoir l'indice de sécheresse (SPI) dans le bassin de la rivière Kansabati, West Bengal, Inde, les résultats ont montré une bonne efficacité des modèles utilisés, en utilisant des données climatiques provenant de sept stations situées dans la région de Garhwal de l'état d'Uttarakhand, Inde, Malik et al. (2021) ont utilisé un réseau neuronal perceptuel multicouche (MLPNN) et un système d'inférence neuro-floue coactif (CANFIS), ainsi qu'une régression linéaire multiple (MLR), en utilisant des données climatiques de sept stations situées dans la région de Garhwal, en Inde.

(Achite et al, 2023) ont utilisé cinq types d'apprentissage automatique à savoir la machine à vecteur de support (SVM), la régression additive, le bagging, le sous-espace

aléatoire et la forêt aléatoire pour la prévision de l'indice de sécheresse SPI à 3, 6, 9 et 12 mois, le modèle de machine à vecteur de support a montré son efficacité par rapport aux quatre autres modèles utilisés, Sur les données pluviométriques mensuelles de quatre stations et avec une série de 1949-2013 dans la région du Bangladesh, (Yaseen et al., 2021) ont utilisé des modèles de forêt aléatoire (RF), de régression de machine à probabilité minimale (MPMR), d'arbre M5 (M5tree), d'apprentissage machine extrême (ELM) et d'ELM séquentiel en ligne (OSELM) pour prédire l'indice de sécheresse (SPI), tous les modèles ont donné de bons résultats pour la prédiction de l'indice de sécheresse (SPI). Enfin, il existe plusieurs autres travaux qui ont utilisé des modèles d'intelligence artificielle pour la prévision de l'indice de sécheresse, la majorité de ces études ont la même conclusion, qui est l'efficacité et la capacité des modèles d'intelligence artificielle à aider et à fournir des solutions pour faire face à la sécheresse. Par ailleurs, l'impact du traitement du signal en tant que technique de prétraitement sur les performances du modèle d'apprentissage automatique a été évalué. En outre, l'étude apporte des contributions significatives en termes d'évaluation de prévision de la sécheresse pour les valeurs SPI à 6 et 12 mois à des périodes d'avance d'un, deux et trois mois, ce qui est d'une grande importance dans la littérature.

### Chapitre1. Sècheresse: Définition & Généralités

#### 1.1. Introduction

Le changement climatique se manifeste souvent par la fréquence, la gravité et la durée croissantes des épisodes de sécheresse dans le monde entier, qui se caractérise par une période de faible humidité dans le cycle climatique naturel. Il se déploie progressivement et se distingue par une diminution des précipitations, entraînant un déficit de disponibilité en eau (Wilhite&Vanyarkho, 2000). Des recherches récentes indiquent que dans de nombreuses régions du monde, la portée géographique, la probabilité et la durée des sécheresses devraient augmenter au cours des prochaines années (Dai, 2013 ; Touma, Ashfaq, Nayak, Kao, &Diffenbaugh, 2015).

5

Dans l'étude de la sécheresse, plusieurs indices sont utilisés pour quantifier et surveiller les conditions de sécheresse. Parmi les indices les plus couramment utilisés, on trouve l'Indice Standardisé de Précipitation (SPI), l'Indice de Stress Hydrique des Plantes (PHDI) et l'Indice de Précipitation-Potentiel d'Evapotranspiration (PDSI). Ces indices permettent de caractériser l'intensité, la durée et la sévérité de la sécheresse dans une région donnée.

En raison de précipitations réduites, d'épuisement de l'humidité du sol et de limitations du débit du canal ou de la capacité du réservoir, la sécheresse se manifeste sous forme de sécheresse météorologique, de sécheresse agricole, de sécheresse hydrologique et de sécheresse socioéconomique (Heim, 2002).

La région du Maghreb, est confrontée à des défis liés à la sécheresse en raison de son climat semi-aride à aride. Des recherches sont menées dans cette région pour comprendre les tendances de la sécheresse, évaluer ses impacts sur les ressources en eau, l'agriculture et les communautés locales, et développer des stratégies d'adaptation et d'atténuation.

Selon un rapport de 1984 de la Croix-Rouge suédoise (Hagman, 1984), la sécheresse touche plus de personnes que tout autre danger naturel ; elle est également perçue

comme étant le moins compris de tous les dangers naturels. La sécheresse peut avoir de graves répercussions sur la santé, l'agriculture, les économies, l'énergie et l'environnement. Il est essentiel de comprendre la complexité de la sécheresse, ses causes, ses impacts et les stratégies d'atténuation pour renforcer la résilience et s'adapter aux changements climatiques.

### 1.2. Définition de la Sécheresse

6

La sécheresse est le phénomène naturel le plus complexe ou un événement extrême, car la détection des sécheresses est très difficile ou exigeante. Elle est généralement définie comme un événement météorologique éphémère résultant du manque de prélèvement sur une période prolongée par rapport à une moyenne de précipitation à long terme. Elle progresse lentement avec le temps et est provoquée par une distribution inégale des précipitations, une demande d'eau supérieure à l'offre ou une combinaison des deux (Mishra, 2010). La préparation et l'atténuation de la sécheresse dépendent principalement de l'information en temps réel sur le début, la progression et l'étendue de la sécheresse, pouvant être générée par le suivi de la sécheresse. Ce suivi est effectué à travers différents types d'indices de sécheresse, fournissant aux décideurs des informations sur la gravité, la fréquence et la durée de la sécheresse, pouvant être utilisés pour déclencher un plan d'urgence en cas de disponibilité (Kumar Daksh et al., 2018).

### 1.3. Conception Mathématique de la Sécheresse

Le concept de sécheresse peut être mathématiquement compris au moyen d'indices qui tiennent compte des aspects météorologiques et socioéconomiques de la sécheresse. Ces dernières années, divers indices de sécheresse ont été développés. En règle générale, un indice de sécheresse sert d'évaluer l'impact d'une sécheresse et déterminer divers aspects des conditions de sécheresse, tels que l'intensité, la durée, la gravité et la portée géographique (Mishra *et al.*, 2010). Plusieurs indices ont été créés pour évaluer la sécheresse, chacun avec ses propres forces et faiblesses. Ceux-ci comprennent l'indice de gravité de la sécheresse de Palmer (PDSI), l'indice d'anomalie des précipitations (RAI), les déciles, l'indice d'humidité des cultures (CMI), l'indice de sécheresse de Bhalme et

Mooly (BMDI), l'indice d'approvisionnement en eau de surface (SWSI), l'indice national des précipitations (NRI), l'indice normalisé des précipitations (SPI), Indice de remise en état de la sécheresse (RDI), Indice d'humidité du sol (SMDI), Indice de sécheresse spécifique aux cultures (CSDI) et autres. Ces indices ont été élaborés pour mesurer divers aspects de la sécheresse, comme les impacts météorologiques, hydrologiques, agricoles et socioéconomiques. Chaque indice sert un objectif spécifique pour évaluer et surveiller les conditions de sécheresse (Achite *et al.*, 2023). Des indices de sécheresse standardisés ont été sélectionnés pour évaluer la sécheresse météorologique. En règle générale, les indices de sécheresse normalisés sont calculés sur différentes périodes 1, 3, 6, 9, 12 et 24 mois, bien qu'ils puissent également être calculés sur d'autres périodes agrégées (Svoboda *et al.*, 2012). Les indices calculés sur des périodes plus courtes (1, 3 et 6 mois) examinent les fluctuations saisonnières des niveaux de précipitations et d'humidité, qui ont une incidence sur l'agriculture. À l'inverse, les indices calculés sur des périodes plus longues (9, 12 et 24 mois) donnent un aperçu des conditions hydrologiques telles que le ruissellement, le niveau des réservoirs, les eaux souterraines et leurs conséquences socio-économiques (Shukla & Wood, 2008).

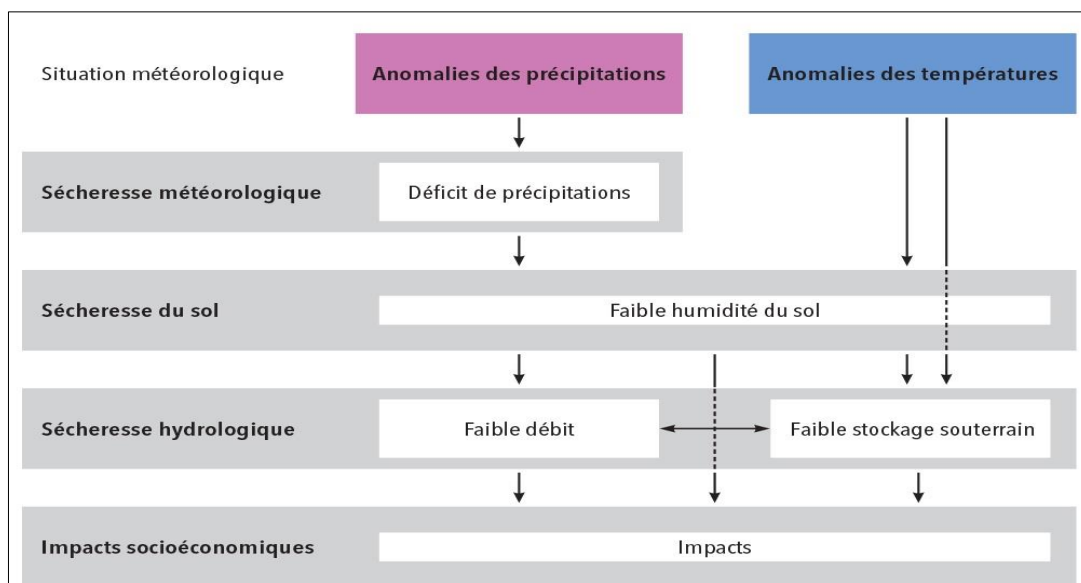
7

### 1.4. Différents Types de Sécheresses

En raison de la grande variation des besoins en eau dans différents secteurs, il est impossible de décrire la condition générale de sécheresse prévalant pour l'ensemble du secteur en une seule fois. Cependant, certaines définitions générales sur les différents types de sécheresse sont énumérées ci-dessous :

- La sécheresse météorologique se caractérise par un manque de précipitations dans une région particulière pendant une certaine période. Les précipitations ont traditionnellement servi d'indicateur principal pour analyser la sécheresse météorologique (Pinkeye, 1966 ; Santos, 1983). Plusieurs études ont examiné les sécheresses en les considérant comme des déficits de précipitations par rapport aux valeurs moyennes (Gibbs, 1975), en utilisant des données mensuelles sur les précipitations pour l'analyse.

- La sécheresse hydrologique est associée à une période pendant laquelle les ressources en eau de surface et souterraines sont insuffisantes pour répondre aux besoins en eau établis d'un système de gestion des ressources en eau spécifique ((Dracup *et al.*, 1980 ; Sen, 1980). Hisdal et Tallaksen, (2003) ont constaté que les sécheresses hydrologiques sont souvent retardées par rapport aux sécheresses météorologiques.
- La sécheresse agricole désigne généralement une période marquée par la diminution des niveaux d'humidité du sol et la perte subséquente des cultures, sans tenir compte de la disponibilité des eaux de surface (Daksh *et al.*, 2018). Divers indices de sécheresse, utilisant un mélange de données sur les précipitations, la température et l'humidité du sol, ont été élaborés pour l'analyse des sécheresses agricoles (Mishra&Singh, 2010).
  - La sécheresse socio-économique concerne les situations où les systèmes de ressources en eau ne répondent pas aux besoins socio-économiques en eau, ce qui entraîne un approvisionnement en eau insuffisant pour répondre aux demandes économiques (Daksh *et al.*, 2018). Les ramifications sociales de la sécheresse englobent principalement des préoccupations telles que la sécurité publique, les problèmes de santé, les conflits entre les utilisateurs d'eau, la diminution de la qualité de vie et les disparités dans la distribution des secours en cas de catastrophe (Wilhite&Glantz, 1985).



**Figure 1.** Propagation entre les types de sécheresse (Van Loon ; 2015)

### 1.5. Les Etudes de la Sècheresse en régions Maghrébine

Les pays du Maghreb (Mauritanie, Maroc, Algérie, Tunisie et Libye) sont confrontés à une raréfaction de l'eau aggravée par des pratiques de gestion de l'eau inefficaces et l'exploitation excessive des réservoirs d'eau. Il est évident que les eaux de surface diminuent et que les niveaux d'eau souterraine chutent rapidement. Ces pays sont les plus touchés par le changement climatique, caractérisé par des régimes de précipitations imprévisibles, des sécheresses prolongées et intenses, entrecoupées de pluies diluviennes et d'inondations dévastatrices (Gaaloul, 2021).

Selon l'étude de Droogers et al., (2012), les changements climatiques devraient contribuer à 22 % des déficits hydriques d'ici 2050, les facteurs socio-économiques représentant 78 % des pénuries en Afrique du Nord.

La répartition des ressources en eau dans la région du Maghreb est sujette à des variations imprévisibles, en fonction des lieux et des périodes. Les données climatiques historiques montrent une hausse de la température de 1 °C au cours du XXe siècle (Stour and Agoumi, 2007), avec une tendance au réchauffement particulièrement notable observée au cours des quatre dernières décennies, coïncidant avec une augmentation marquée de la fréquence des sécheresses et des inondations (Moujahid *et al.*, 2014).

De nombreux résultats de recherche indiquent que les prévisions climatiques générées par les modèles de circulation générale (MCG) actuels sous-estiment l'augmentation des températures et la diminution des niveaux de précipitations dans la région du Maghreb. Cela laisse entendre que les pays du Maghreb seront plus touchés par les conséquences du changement climatique que les autres, ce qui en fait une préoccupation majeure pour la région (Tabet-Aoul, 2008). Les modèles disponibles pour la région du Maghreb prévoient que les sécheresses deviendront de plus en plus fréquentes, sévères et prolongées (Elrafy, 2009). Les simulations des modèles indiquent également une réduction de 4 à 27 % des précipitations annuelles, parallèlement à des épisodes de fortes pluies plus fréquents (PNUE, 2008). Cette situation intensifiera la concurrence de l'eau

dans la région, entraînant potentiellement des conflits et servant de moteurs importants pour la migration.

Depuis le début du XXe siècle, l'Algérie a été confrontée à des périodes de sécheresse qui se sont répétées, commençant en 1944, puis en 1981, 1989, 1990, 1992, 1994, 1996 et 1999. Les régions du nord-ouest et du centre des plaines du pays ont été les plus touchées, ce qui a entraîné des baisses importantes de la production agricole et de la disponibilité de l'eau, ainsi que des dommages importants aux cultures (Meddi *et al.*, 2013).

10

La consommation d'eau agricole s'élève à environ 7 milliards de mètres cubes par an, ce qui représente 70% de la consommation totale d'eau du pays. En Tunisie, environ 80% de la consommation totale d'eau est allouée à l'irrigation (Chebil *et al.*, 2019). Au Maroc, environ 80 % des ressources mobilisées du pays sont affectées à l'irrigation, le reste étant destiné à l'eau potable et à des fins industrielles (MDCE, 2016). Les volumes importants d'eau alloués à l'irrigation en Tunisie, au Maroc et en Algérie soulignent le rôle crucial des études et de la planification de scénarios concernant l'impact du changement climatique sur les ressources en eau. Ces efforts sont essentiels pour élaborer des mesures visant à répondre à la demande croissante en eau à moyen et long terme, ce qui est crucial pour assurer la sécurité alimentaire et le développement socioéconomique dans ces pays.

### 1.6. Causes de la Sécheresse

Les causes de la sécheresse peuvent être attribuées à des facteurs naturels et humains. Les causes naturelles comprennent les températures des terres et de l'eau qui entraînent une évaporation accrue, la circulation de l'air et les conditions météorologiques qui influent sur les précipitations, les niveaux d'humidité du sol qui influent sur la formation des nuages et le moment où l'approvisionnement en eau ne correspond pas aux besoins agricoles (Seleiman *et al.*, 2021). D'un autre côté, les facteurs humains engendrent une demande excessive en eau en raison de la croissance démographique et des pratiques agricoles intensives, ce qui peut épuiser les ressources en eau et aggraver les conditions de sécheresse (Van Loon *et al.*, 2016). Le changement climatique, en particulier le

réchauffement climatique, joue un rôle important en rendant les phénomènes météorologiques extrêmes plus probables et peut entraîner des conditions plus sèches en augmentant l'évaporation. L'apparition et la gravité des sécheresses sont influencées par différents facteurs combinés comme :

- Le manque de précipitations : L'une des principales causes naturelles de la sécheresse est une période prolongée de faibles précipitations. Lorsque les précipitations sont nettement inférieures à la moyenne pendant une période prolongée, cela peut entraîner des déficits d'humidité du sol et une pénurie d'eau.
- Variabilité et changement climatiques : Les changements dans les modèles de circulation atmosphérique, comme les événements El Niño et La Niña, peuvent influencer sur les régimes de précipitations et contribuer aux conditions de sécheresse. Les changements climatiques peuvent également exacerber les sécheresses en modifiant les régimes météorologiques et en augmentant la fréquence et l'intensité des phénomènes météorologiques extrêmes.
- Températures élevées : Les températures élevées peuvent augmenter les taux d'évaporation, ce qui entraîne un épuisement plus rapide de l'humidité du sol et des sources d'eau de surface. Les vagues de chaleur peuvent exacerber les conditions de sécheresse en intensifiant la perte d'eau des sols et de la végétation.
- Déforestation : Le défrichage des forêts à des fins agricoles, d'urbanisation ou à d'autres fins peut perturber les cycles hydrologiques locaux et régionaux, réduisant la disponibilité de l'eau et exacerbant les conditions de sécheresse.
- Changements dans l'utilisation des terres : Les changements dans l'utilisation des terres, comme l'étalement urbain, l'expansion agricole et la construction de barrages et de réservoirs, peuvent modifier le débit naturel de l'eau et réduire la capacité des écosystèmes à retenir l'humidité.
- Surexploitation des eaux souterraines : Le pompage excessif des eaux souterraines à des fins d'irrigation, industrielles et domestiques peut épuiser les aquifères plus rapidement qu'ils ne peuvent être réapprovisionnés, entraînant l'épuisement des eaux souterraines et contribuant aux conditions de sécheresse.

- Mauvaise gestion de l'eau : De mauvaises pratiques de gestion des ressources en eau, y compris des techniques d'irrigation inefficaces, une infrastructure de stockage de l'eau inadéquate et l'absence de politiques pour une utilisation durable de l'eau, peuvent exacerber les effets de la sécheresse et prolonger les périodes de rétablissement.
- Variabilité naturelle : Les sécheresses sont une partie naturelle du système climatique, et la variabilité des régimes de précipitations est inhérente. Bien que certaines sécheresses soient à court terme et relativement bénignes, d'autres peuvent être graves et durables, entraînées par des interactions complexes ;

### 1.7. Impact de Sècheresse

Les sécheresses ont des répercussions profondes dans divers secteurs de la société, y compris l'économie, et peuvent s'étendre au-delà des zones touchées (Kogan, 1997). Ils sont un phénomène répandu, avec environ la moitié des surfaces terrestres de la terre étant sensibles à eux, en particulier les grandes terres agricoles. Au XXe siècle, les sécheresses ont eu l'impact le plus négatif parmi les risques naturels. Ces dernières années, des sécheresses intensives à grande échelle ont été observées sur tous les continents, affectant des zones étendues et entraînant des coûts économiques et sociaux élevés (HerreraEstrada *et al.*, 2019). L'interconnectivité des sécheresses sur différents continents a également attiré l'attention, les recherches montrant qu'une sécheresse peut en amplifier ou en provoquer une autre, et l'impact de la sécheresse sur différents secteurs varie selon les régions et les continents (Downing and Bakker, 2000). Par exemple, en Europe, les sécheresses ont un impact significatif sur les fonctions des terres et des sols, ainsi que sur les services écosystémiques dans les zones urbaines et rurales (European Environment Agency EEA). En Afrique, la Corne de l'Afrique connaît actuellement sa pire sécheresse depuis plus de 40 ans, avec des effets dévastateurs sur l'agriculture et la production alimentaire, affectant des millions de personnes et de vastes zones de cultures. Les Nations Unies ont mis en garde contre l'impact sévère de la sécheresse sur le continent, avec plus de 130 millions de personnes et 229 millions d'acres de cultures actuellement touchés (Iran Steel service center). L'étude mondiale indique également que les sécheresses extrêmes ont des impacts importants sur les prairies et les

arbustes dans le monde entier. Par conséquent, l'impact des sécheresses est une préoccupation critique avec des implications pour diverses régions et secteurs à travers le monde.

### 1.8. Conclusion

La sécheresse, avec ses impacts multiples et ses origines complexes, constitue un défi redoutable dans notre monde en constante évolution. Comme nous l'avons exploré, ses effets se répercutent sur les écosystèmes, les économies et les sociétés, laissant des marques profondes sur les systèmes naturels et humains. Des pertes agricoles à la rareté de l'eau, du déclin de la biodiversité aux bouleversements socio-économiques, les sécheresses entraînent un lourd tribut, amplifiant les vulnérabilités existantes et exposant les faiblesses systémiques.

13

Il est essentiel de comprendre les causes de la sécheresse qu'il s'agisse de la variabilité naturelle du climat, des changements climatiques d'origine humaine ou d'une combinaison des deux pour assurer une atténuation et une adaptation efficaces. Il est primordial de s'attaquer aux causes profondes, telles que les émissions de gaz à effet de serre et les pratiques de gestion de l'eau non durables, pour renforcer la résilience face aux futures sécheresses.

De plus, la reconnaissance des divers types de sécheresse météorologique, agricole, hydrologique et socioéconomique souligne la nécessité d'interventions personnalisées qui englobent un éventail de secteurs et d'intervenants. Qu'il s'agisse d'améliorer les prévisions et les systèmes d'alerte précoce, de stratégies durables de gestion des terres et des eaux ou de filets de sécurité sociale pour soutenir les communautés vulnérables, des approches holistiques sont essentielles pour atténuer les effets de la sécheresse et favoriser la résilience.

L'utilisation des indices de sécheresse comme concept mathématique de la sécheresse est essentielle pour quantifier, surveiller et analyser les conditions de sécheresse de manière objective et précise. Ces indices, tels que SPI (l'indice de précipitation standardisé), PDSI

(indice de sécheresse de palmer) ..., permettent d'évaluer différents types de sécheresse, leur intensité, leur durée, leur étendue spatiale et leur probabilité de récurrence.

Alors que nous nous tournons vers l'avenir, l'impératif de lutter contre les sécheresses et leurs effets en cascade devient de plus en plus urgent. En favorisant la collaboration, l'innovation et l'action collective, nous pouvons tendre vers un avenir où les sécheresses ne sont plus des catastrophes dévastatrices mais des défis gérables, où les communautés prospèrent face à l'adversité, et où la résilience de notre planète et de ses habitants est préservée pour les générations à venir.

### Chapitre 2. Etat de l'Art sur les Modèles de Préviation de la Sècheresse

#### 2.1.Introduction

L'état actuel de la recherche concernant les modèles de préviation de la sècheresse représente une étude approfondie des progrès, des méthodologies et des utilisations pratiques de ces modèles prédictifs. Compte tenu de l'impact croissant des activités humaines et du changement climatique, la préviation précise des sècheresses est devenue indispensable pour une gestion efficace des ressources en eau, des stratégies agricoles durables et pour minimiser les risques pour les populations touchées. Cette recherche vise à examiner les développements récents dans ce domaine, en mettant en lumière diverses approches, obstacles et perspectives pour améliorer la préviation de la sècheresse à différentes échelles, allant du local au mondial.

15

Ce segment introductif abordera les principaux aspects couverts par les dernières recherches sur les modèles de préviation de la sècheresse. Ces aspects comprennent l'éventail des méthodes de modélisation utilisées, les sources de données exploitées, les techniques de validation, ainsi que les applications pratiques et les limites inhérentes des modèles actuels. En outre, nous identifierons les lacunes existantes en matière de recherche et décrirons les pistes potentielles pour les progrès futurs dans ce domaine crucial de la science du climat et de la gestion des ressources.

#### 2.2.Les Modèles de Préviation de la Sècheresse

Les modèles de préviation des sècheresses sont des outils essentiels utilisés par les scientifiques, les chercheurs, les décideurs et les professionnels de l'agriculture pour prédire et atténuer les impacts des sècheresses. Ces modèles intègrent diverses données environnementales, météorologiques, hydrologiques et parfois socioéconomiques pour fournir des renseignements sur la probabilité et la gravité des conditions de sècheresse dans certaines régions (Das *et al.*, 2022). Voici quelques types de modèles de préviation de la sècheresse couramment utilisés :

### 2.2.1. Les Modèles Stochastiques

Les modèles stochastiques, souvent appelés modèles de séries chronologiques, ont été utilisés dans des applications scientifiques, économiques et techniques pour l'analyse de séries chronologiques. Certaines des littératures traitant de différents types de séries chronologiques où les modèles stochastiques sont aussi bons que les modèles ANN peut être trouvés dans la littérature (Brace *et al.*, 1991 ; De Groot and Wurtz, 1991 ; Caire *et al.*, 1992 ; Foster *et al.*, 1992 ; Gorr *et al.*, 1994). Le modèle ARIMA (Moyenne Mobile Intégrée AutoRégressive) est l'un des modèles stochastiques qui peut fournir une étape de recherche systématique (identification, estimation et vérification diagnostique) pour un modèle approprié (Mishra et Desai, 2005). Le modèle SARIMA (Moyenne Mobile Intégrée AutoRégressive Saisonnalisée) exige seulement une poignée de paramètres pour représenter des séries chronologiques non stationnaires à la fois au cours de saisons individuelles et de plusieurs saisons. Deux catégories importantes et largement utilisées de modèles stochastiques comprennent ARIMA et SARIMA (Mishra *et al.*, 2007).

16

(Mishra et Desai, 2005) (Fernandez-Manso *et al.*, 2011) (Shatanawi *et al.*, 2013) (Alam *et al.*, 2014) (Chen *et al.*, 2012) (Bazrafshan *et al.*, 2015) (Karthika *et al.*, 2017) Ont prouvé la possibilité de l'utilisation des modèles stochastiques linéaires dans des bassins hydrométéorologiques pour prévoir des séries SPI de plusieurs échelles de temps afin de connaître la gravité de la sécheresse à l'avenir.

Cependant, malgré les améliorations continues associées à ce modèle stochastique linéaire bien établi et largement utilisé, il est progressivement supplanté par de nouveaux modèles d'IA. Ces nouveaux modèles possèdent des propriétés non linéaires inhérentes et offrent une plus grande flexibilité pour la modélisation (Mishra *et al.*, 2007). L'identification du modèle approprié à partir d'une gamme de possibilités nécessite des techniques informatiques complexes d'identification. De plus, ces méthodes traditionnelles d'identification des modèles sont difficiles à comprendre, rendant le processus subjectif (Fung *et al.*, 2020). La fiabilité du modèle sélectionné repose largement sur les compétences et l'expertise de l'utilisateur.

### 2.2.2. Les Modèles Probabilistes

La prédiction de la sécheresse repose souvent sur des modèles probabilistes fondés sur des chaînes de Markov, une méthode fréquemment utilisée dans la recherche (Mishra et Singh, 2011 ; Avilés et al., 2016). Une chaîne de Markov est un processus stochastique dépourvu de mémoire, ce qui signifie que compte tenu de l'état présent, les états futurs et passés deviennent indépendants les uns des autres (Chen & Yang, 2012). Il sert d'outil mathématique pour déterminer les probabilités du système en utilisant une série de probabilités de transition entre états. Typiquement, lorsque la probabilité de transition repose sur des conditions dans les périodes  $m$  précédentes, elle est appelée une chaîne de Markov d'ordre  $m$  (Avilés *et al.*, 2016).

17

Sharma & Panu, (2012) ont utilisé la chaîne de Markov pour prévoir la durée des sécheresses hydrologiques dans le cas des prairies canadiennes. D'autre recherche aussi en prouvé la fiabilité de la chaîne de Markov à prévoir la sécheresse peut être trouvés dans la littérature (Chen & Yang, 2012) (Yeh *et al.*, 2015) (Khadr, 2016) (Sun *et al.*, 2016) (Zhang *et al.*, 2017).

Bien que les modèles de chaîne de Markov aient donné des résultats satisfaisants, en particulier lorsqu'ils traitent des ensembles de données complexes, ils sont confrontés à certaines contraintes en raison de la grande quantité d'états nécessaires à la construction. Résoudre des problèmes avec de nombreux états non seulement épuise les ressources informatiques de la mémoire et de la vitesse de traitement fournies par les ordinateurs, mais tente également l'endurance des utilisateurs, compte tenu de la tendance croissante vers l'automatisation et la robotique. En conséquence, cette limitation pourrait finalement contribuer au déclin de l'utilisation de la chaîne de Markov.

### 2.2.3. Les Modèles Dynamiques

Contrairement aux approches traditionnelles basées sur des observations à long terme provenant de jauges pour la prédiction de la sécheresse, la modélisation dynamique de la sécheresse repose largement sur l'utilisation de données de télédétection en temps réel. La télédétection est une méthode qui permet d'acquérir des informations précises sur des

objets, des zones ou des phénomènes à distance, souvent par le biais d'aéronefs ou de satellites (NOAA, 2017). Dans le cadre de l'étude sur les sécheresses, les observations obtenues par télédétection peuvent être exploitées pour surveiller les variables climatologiques associées à la sécheresse et évaluer les impacts de celle-ci d'un point de vue écologique (AghaKouchak *et al.*, 2015).

### 2.2.4. Les Modèles basés sur l'Intelligence Artificielle IA

Ces dernières années, l'utilisation croissante des modèles d'intelligence artificielle pour l'estimation des paramètres hydrologiques, tels que les débits des rivières, le niveau des nappes phréatiques et les précipitations, a attiré l'attention (Apaydin *et al.*, 2021). Cette tendance s'explique par la capacité de ces modèles à améliorer la précision des prévisions et à offrir de nouvelles perspectives sur les processus hydrologiques complexes. La sécheresse, en particulier, se caractérise par sa nature multivariée, non linéaire et imprévisible. De ce fait, de nombreux modèles d'apprentissage automatique ont montré leur potentiel pour prédire efficacement les conditions de sécheresse en s'appuyant sur divers indices. Ces modèles comprennent les réseaux de neurones (ANN) (Hosseini-Moghari et Araghinejad, 2015 ; Mishra et Desai, 2006), la machine à vecteur de soutien (SVM), le système d'inférence floue neuronale adaptative (ANFIS) (Ali *et al.*, 2018), la forêt aléatoire (RF) (Rhee et Im, 2017), les arbres décisionnels (DT) (Gyaneshwar *et al.*, 2023) et soutenir la régression vectorielle (RVS) (Xu *et al.*, 2018), bon nombre de ces modèles ont été appliqués et comparés dans de nombreuses études sur la sécheresse.

M-Erole *et al.*, (2011) ont montré l'application des réseaux de neurone artificielle dans la prédiction de la sécheresse météorologique utilisant le SPI comme une variable quantifiant dans 5 sites de district des Lakes qui se situent au sud de la méditerranée en Turquie.

Afin d'analyser et prévoir la sécheresse dans les régions de Nord-Ouest de l'Algérie, Achour *et al.*, (2020), ont utilisé le SPI pour construire un modèle d'intelligence artificielle performant à une meilleure estimation de sécheresse. L'analyse a été basée sur les données pluviométriques mensuelles collectées durant la période de 1960 à 2010, dans 7

plaines. Cette prévision a été évaluée à l'aide d'un modèle ANN basé sur l'indice SPI à différentes échelles de temps (3, 6, 9 et 12 mois) et avec un délai de 2 mois.

La nouvelle version de modèle logique flou, CANFIS (système d'inférence neuro-flou coactive) a été effectuée pour l'estimation de SPI au niveau de 6 stations météorologique dans Uttarakhand, India par (Anurag *et al.*, 2020). Les résultats obtenus par le modèle CANFIS ont été comparés par les modèles MLPNN (Multilayer Perceptron Neural Network) et MLR (Multiple linear regression) pour chaque station. Une meilleure performance du CANFIS et MLPNN a été montrée pour la prévision de la sécheresse, où le MLR correspond au mauvais modèle pour l'estimation du SPI pour la zone d'étude.

19

Achite *et al.*, (2022) ont utilisé l'indice standardisé de précipitation et de ruissellement (SPI/SRI) pour la prévision des sécheresses météorologique et hydrologique, dans le bassin de Wadi Ouahrane au Nord de l'Algérie. Cette dernière a été construite utilisant les différents modèles d'intelligence artificielle notamment ANN (Réseau de Neurones Artificiels), ANFIS (Système d'Inférence Neuro-Flou Adaptatif), SVM (Machine à Vecteurs de Support) et DT (Arbre de Décision). Ces modèles de ML (machine learning) ont été évalués à l'aide de plusieurs critères de performance. Les résultats trouvés ont montré que tous les modèles ML utilisés ont bien estimé la sécheresse hydrologique, tandis que le modèle SVM a surpassé les autres modèles et la performance des modèles ANFIS et DT a été constatée sur le côté inférieur tout au long de l'analyse.

Une combinaison entre les modèles d'apprentissage automatique et l'indice standardisé de précipitation et d'évapotranspiration a été proposée pour analyser la sécheresse dans les plateaux de Tibetan Chine, pour la période 1980 jusqu'à 2019, par (Mokhtar *et al.*, 2021) différents modèles d'intelligence artificielle ont été appliqués RF (Forêt Aléatoire), XGB XGBoost (Extreme Gradient Boosting), CNN (Réseau Neuronal Convolutif) et LSTM (Mémoire à Long et Court Terme) pour l'estimation de SPEI<sub>3</sub> et SPEI<sub>6</sub>. Plusieurs données climatiques ont été utilisées dans le développement des modèles dont chaque modèle a été basé sur un scénario approprié. XGB et RF étaient les meilleurs modèles pour l'estimation de SPEI<sub>3</sub>, où XGB a été basé sur un scénario de 5 variables climatiques et

le RF avec un scénario 6. Alors que le meilleur modèle pour estimer le SPEI<sub>6</sub> été XGB avec scénario 5 et RF avec scénario 7.

En terme de capacité de prédiction et vitesse d'apprentissage de la prévision, une comparaison a été menée entre l'algorithme ELM (Extreme Learning Machine) et l'ANN (Réseau de Neurones Artificiels) par (Ravinesh& Mehmet, 2014) sur 5 sites de l'Est de l'Australie. L'étude a été faite basée sur les données météorologiques dans la période 1957 jusqu'au 2011. La moyenne de précipitation et les températures moyennes maximale et minimale ainsi que les indices de mode climatique étaient les variables mensuelles utilisées comme données d'entrée pour les deux modèles. Les résultats ont montré une meilleure performance et rapidité d'apprentissage pour le modèle ELM par rapport au modèle ANN traditionnel après l'aide de prévision des indices de performance.

20

Une combinaison de réseau de neurone artificielle et d'indice de sécheresse effective (EDI) a été proposée par (Masinde, 2013) dans le but de prévoir la sécheresse et sa sévérité. Ceci a été démontré utilisant des modèles de prévision basés sur des données météorologiques pendant 30 ans pour quatre stations au Kenya. Les résultats ont montré que la combinaison réalisée à prévoir la sécheresse et sa gravité dans la région de Kenya. Ou la plupart des indices de sécheresse appliqués sur cette région ne fournissent pas la prévision de la sévérité de la sécheresse.

Dans une étude de la prévision de la sécheresse hydrologique dans un temps réel au niveau de bassin du fleuve noir aux Etats-Unis (Dehghani *et al.*, 2017) ont été effectués une application d'un modèle dynamique linéaire spatio-temporelle (DLSTM) et ANN pour prévoir l'indice standardisé de la sécheresse hydrologique (SHDI). Les résultats ont montré l'aptitude des deux modèles de prévision de SHDI à différentes échelles de temps, tandis que le DLSTM a été le meilleur dans la prévision pour des horizons de prévision plus long, ce modèle pourrait prévoir le SHDI jusqu'à 6 mois à l'avance, alors que le modèle ANN n'était en mesure de prévoir le SHDI que pour des pas de temps courts.

Belayneh et Adamowski, (2013) ont choisi le SPI pour représenter l'indice de sécheresse afin d'estimer la sécheresse dans le bassin de fleuve Awash de Ethiopia. Diverses

techniques d'apprentissage automatique ont été développées notamment l'ANN, SVR et le composant wavelet et réseau de neurone (WA-ANN). Les résultats ont prouvé que le complexe Wa-ANN est le plus précis pour la prédiction du SPI<sub>3</sub> et SPI<sub>6</sub> avec un délai de 1 et 3 mois, et un coefficient de détermination entre le SPI observé et estimé par les modèles ANN et SVR.

Pour évaluer l'aptitude des modèles d'ELM (Extreme Learning Machine), OS-ELM (Online Sequential Extreme Learning Machine) et SADE-ELM (Self-Adaptive Differential Evolution Extreme Learning Machine) à la prédiction de la sécheresse Zhen *et al.*, (2017) ont réalisé une étude de modélisation et d'estimation de SPI et SPEI appliquant ces modèles. La base de données pour effectuer cette analyse est les anomalies de température à la surface de la mer au niveau de la zone de Niño-3.4 et Niño-4 dans la province Khanhhoa au Vietnam. L'étude a constaté que SADE-ELM est le modèle le plus précis et stable pour la prédiction de la sécheresse comparé avec les deux autres modèles. En outre le modèle OS-ELM avait une meilleure performance qu'ELM.

21

L'utilisation des modèles ANN, ANFIS et SVM a été aussi menée par (Mokhtarzad *et al.*, 2017) pour la prédiction de la sécheresse et le développement d'un modèle précis et performant. L'analyse a été faite basée sur les variables météorologiques de la station Bojnourd à la province de Khorasan du Nord : température, humidité et précipitation, avec SPI indice de sécheresse. Les résultats ont montré que le modèle SVM est le modèle le plus performant comparé aux autres modèles ANN et ANFIS.

Une corrélation entre les anomalies de la température de surface de la mer ( $SSTA$ ) et les deux SPI et SPEI a été proposée par Nguyen *et al.*, (2015) dans 4 zones au niveau du bassin de Cai-Vietnam. Différents modèles d'ANFIS ont été utilisés pour la prédiction de SPI et SPEI dans différentes échelles de temps. Le modèle le plus performant trouvé pour la prédiction à long terme est le modèle ANFIS (M11) avec SPEI<sub>12</sub>, par contre le SPI est le plus précis pour la prédiction à courte durée. La méthode ANFIS avec des variables d'entrées constituant des événements SSTA peut être appliquée avec succès pour une fiable prédiction de sécheresse.

Bagher *et al.*, (2013) ont évalué la possibilité des modèles d'ondelettes-ANN et ANFIS, de prévoir la sécheresse météorologique au niveau de l'Est de la province Azerbaijan-Iran. Les modèles utilisés ont d'abord été formés par les données observées collectées durant 1952-1992, puis les utilisées pour prévoir la sécheresse au cours de la période 1992 jusqu'au 2011. Il a été démontré que la transformation ondelette peut améliorer la modélisation de la sécheresse météorologique. En outre les modèles ANFIS ont données des meilleures prévisions plus précises que les ANN.

22

Deux indices de sécheresse ont été utilisés, l'indice effective de sécheresse (EDI) et SPI dans différentes échelles de temps (de 1 à 12 mois) base aux données de précipitation, pour la modélisation se sécheresse par le modèle de ANN, par (Morid *et al.*, 2007) dans la province de Tahrán-Iran. La comparaison des résultats à conclure une meilleure performance de modèle de réseau EDI par rapport aux celui de SPI sur tous les délais en termes de critères statistiques utilisée. La méthode proposée à donner une indication explicite de la sévérité de sécheresse.

### 2.3. Variables Indépendantes pour la Prédiction de Sécheresse

Les variables indépendantes de prédiction de la sécheresse (IDFV) sont des facteurs environnementaux, climatiques et géographiques utilisés pour anticiper et prévoir les périodes de sécheresse. Ces variables jouent un rôle crucial dans les modèles de prédiction de la sécheresse, ce qui aide les chercheurs et les organisations de gestion de l'eau à mieux comprendre et surveiller les conditions de sécheresse imminente.

Voici quelques variables indépendantes couramment utilisées dans les modèles de prédiction de la sécheresse :

- Les Précipitations : Quantités totales, accumulées et réparties selon les saisons (Slater *et al.*, 2023). Les précipitations sont l'un des paramètres fondamentaux de la prédiction des sécheresses, car elles ont un impact direct sur la disponibilité de l'eau dans un environnement. Une diminution significative des précipitations sur une période prolongée peut indiquer le début d'une sécheresse.

- La Température : Les températures de l'air, en particulier les valeurs minimales et maximales, affectent les demandes d'évaporation et la croissance potentielle des cultures (Alawsi, 2022). La température contribue à intensifier les sécheresses en augmentant l'évaporation, réduisant ainsi l'humidité du sol et les réserves d'eau de surface. Il est crucial de surveiller de près l'évapotranspiration, qui est le résultat de la perte d'eau causée par l'évaporation du sol et de la transpiration des plantes, car elle est étroitement liée aux conditions de chaleur et d'humidité.
- L'Humidité : Humidité relative, indiquant la quantité d'eau présente dans l'atmosphère et sa capacité à supporter la condensation. L'humidité du sol joue également un rôle essentiel, car les sols secs peuvent entraîner des conditions de sécheresse plus sévères et prolongées.
- Le vent : Les directions et les vitesses des vents influent sur les mouvements de l'air et le transport de l'humidité.
- La Pression atmosphérique : Variations de la pression atmosphérique pouvant entraîner des changements dans la configuration des vents et des précipitations.
- Les Indices climatiques : Mesures telles que PDSI ou SPI dérivées des données climatiques.

### 2.4. Variable Dépendante De Prédiction De La Sécheresse

La variable dépendante dans les modèles de prédiction de la sécheresse varie selon l'orientation spécifique de la recherche, allant des stratégies d'adaptation et des indicateurs économiques aux facteurs environnementaux et aux impacts socio-économiques. Cependant, voici quelques exemples de variables dépendantes couramment utilisées pour prédire la sécheresse :

- L'Indice de sécheresse standardisé (SPI) : L'IS est une mesure statistique utilisée pour caractériser la sévérité de la sécheresse sur une région donnée. Il est calculé à partir de données de précipitations et de températures ;
- Le Déficit de précipitations (PDSI) : Le PDSI est un indice qui mesure les écarts entre les précipitations et les besoins en eau des plantes. Il est basé sur un modèle d'équilibre d'eau du sol ;

- Le Débit des cours d'eau : Les débits des rivières et des cours d'eau peuvent être utilisés comme indicateurs de la sécheresse, car une diminution du débit peut indiquer des conditions de sécheresse ;
- Le Niveau des nappes phréatiques : La baisse du niveau des nappes phréatiques peut également être un indicateur de la sécheresse, car elle reflète une diminution de la recharge des eaux souterraines due à un manque de précipitations ;
- L'Indice de végétation (NDVI) : Le NDVI est un indice calculé à partir des données satellitaires qui mesure la quantité de végétation présente sur une zone. Une baisse du NDVI peut indiquer une sécheresse, car elle reflète un stress hydrique sur la végétation ;
- Le Rendement des cultures : Le rendement des cultures peut être utilisé comme indicateur indirect de la sécheresse, car les cultures peuvent être affectées négativement par le manque d'eau.

Selon le contexte et la disponibilité des données, différentes combinaisons de ces variables peuvent être utilisées pour prévoir la sécheresse. Les modèles prédictifs peuvent être basés sur des techniques statistiques, des modèles climatiques ou des techniques d'apprentissage automatique pour estimer les conditions futures de sécheresse.

### 2.5.L'Histoire de la Prédiction par les Modèles d'IA

Les prévisions de l'intelligence artificielle (IA) ont une histoire riche qui a évolué au fil des ans. Au départ, dans les années 1950, les premières tentatives de prévision par l'IA étaient limitées par la puissance de calcul et la disponibilité des données. Les années 1980 et 1990 ont vu le développement de systèmes experts, qui codifiaient les connaissances des experts dans un logiciel, montrant le potentiel de l'IA pour faire des prédictions basées sur des règles. Cependant, la véritable percée s'est produite dans les années 2000 avec l'essor des algorithmes d'apprentissage automatique tels que l'analyse de régression, les arbres de décision et les machines à vecteurs de support. Ces algorithmes ont permis aux ordinateurs d'apprendre des modèles et des relations à partir

de données, ce qui a conduit à des modèles de prédiction plus automatisés et fondés sur des données.

Aujourd'hui, les modèles de prédiction de l'IA tirent parti de vastes quantités de données, de puissantes ressources informatiques et d'algorithmes avancés pour prédire avec précision les événements futurs. Les prévisions de l'IA transcendent les limites des méthodes traditionnelles en utilisant des modèles d'apprentissage automatique et d'apprentissage profond pour analyser rapidement et avec précision des ensembles de données massifs. Cette technologie est devenue indispensable pour diverses industries, en optimisant la logistique de la chaîne d'approvisionnement, en prédisant le comportement des clients et en prévoyant les marchés financiers. Les prévisions de l'IA n'augmentent pas seulement la précision, mais améliorent également l'efficacité, fournissent des informations en temps réel et réduisent les dépenses en minimisant les inefficacités et en optimisant l'allocation des ressources.

25

### 2.6. Conclusion

La modélisation stochastique offre une alternative en prédisant l'indice de sécheresse par la détermination de paramètres élémentaires tels que l'autorégressif (AR), la différenciation (I) et la moyenne mobile (MA). Les modèles ARIMA/SARIMA ont démontré leur aptitude à prédire des échelles de temps plus élevées pour les indices de sécheresse (par exemple, des périodes de 12 ou 24 mois) avec des pas de temps plus courts. Néanmoins, cette approche linéaire peut ne pas capturer complètement les composants non linéaires dans les données de séries chronologiques, conduisant à un glissement progressif vers les modèles d'IA.

La modélisation probabiliste, comme l'analyse de la chaîne de Markov, a été utilisée pour prévoir les sécheresses futures en se basant sur la théorie des probabilités. Comme le modèle ARIMA, le modèle de chaîne de Markov s'est révélé prometteur pour prévoir raisonnablement des séries temporelles avec des horizons de prédiction courts. De plus en plus, les modèles d'IA, y compris les réseaux de neurones artificiels (ANN), la logique floue (FL) et la régression vectorielle de soutien (SVR), ont pris de l'importance dans les récentes études de prédiction de la sécheresse. Ces modèles excellent dans la prédiction

des événements de sécheresse qui manquent de solutions mathématiques simples et démontrent la capacité de capturer le bruit blanc, la non-stationarité et la non-linéarité dans les données de séries chronologiques.

### Chapitre 3. Zone d'Etude & Base de Données

#### 3.1.Introduction

La gestion des ressources en eau et la compréhension des dynamiques hydrologiques sont essentielles pour assurer la durabilité des écosystèmes et des sociétés humaines. Dans ce contexte, le bassin de la rivière Hodna représente un cas d'étude crucial en raison de sa diversité géographique et climatique. Ce chapitre se propose de jeter un éclairage sur les caractéristiques spécifiques de cette région en analysant la base de données météorologiques qui sous-tend notre recherche.

27

À travers une évaluation détaillée de cette base de données, nous mettons en lumière les défis et les opportunités liés à la collecte et à l'interprétation des données climatiques. Nous expliquons également la méthodologie employée pour le calcul de l'indice normalisé des précipitations (SPI), un outil fondamental pour mesurer et comprendre la variabilité des précipitations dans le temps. En établissant ces fondations méthodologiques, nous visons non seulement à clarifier les processus hydrologiques en jeu mais aussi à préparer le terrain pour des analyses plus poussées sur les tendances de sécheresse. Ces analyses sont essentielles pour les développements futurs de modèles d'intelligence artificielle destinés à prédire les conditions de sécheresse et à mieux gérer les ressources en eau dans le bassin de Hodna. Ce chapitre, en posant les bases nécessaires, s'inscrit ainsi dans un objectif plus vaste de prévision et de gestion proactive des conditions climatiques extrêmes.

#### 3.2.Présentation de la Zone d'Etude

Dans cette étude, les valeurs SPI ont été calculées à partir des données mensuelles de précipitations des stations météorologiques du bassin Hodna en Algérie entre 1981 et 2020. Ce bassin présente un climat méditerranéen distinct qui tend à être aride dans la nature. La superficie de ce bassin est de 26 000 km<sup>2</sup> au sud-est de la capitale Alger, et situé entre 36°11' et 34°29' de latitude Nord et entre 3°2' et 6°11' de longitude Est. Le bassin Hodna est délimitée au nord par les chaînes de montagnes de Bibans et le plateau

Sétifien, à l'ouest par les hautes plaines d'Algérie, et au sud et à l'est par l'Atlas saharien. L'élévation des sommets de Hodna diminue progressivement d'est en ouest, ils alternent entre 1900 et 1000 mètres. La position géographique de ce bassin, situé entre deux chaînes de montagnes au nord et au sud, l'organise comme un bassin endoréique entourant un bol presque plat situé à une altitude de 400 mètres. Au cœur de cette région particulière, le lac salé aride appelé « Chott El Hodna » recueille tous les cours d'eau de la région. Le bassin de Hodna présente les caractéristiques typiques d'un climat semi-aride, avec des précipitations limitées et des températures élevées, y compris une variabilité spatio-temporelle élevée. L'examen des données disponibles montre que six stations sont fiables : station Ain El hadjel, station Msaad, station Boussaada, station Elkantara, station M'sila et station M'doukel. Le Tableau 1 représente les Coordonnées, élévation et l'ID de ces stations. La Figure 2 illustre l'emplacement géographique de ces stations.

28

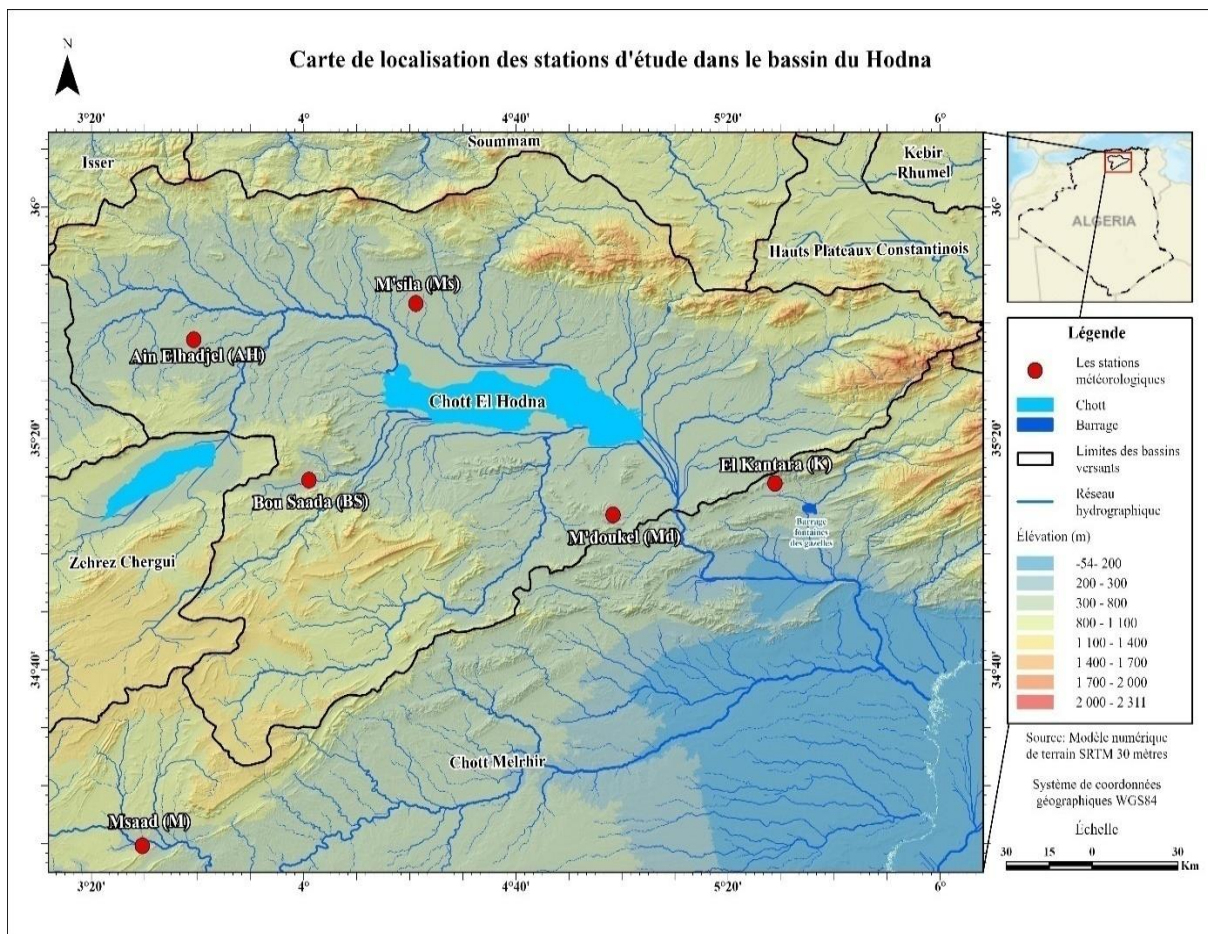
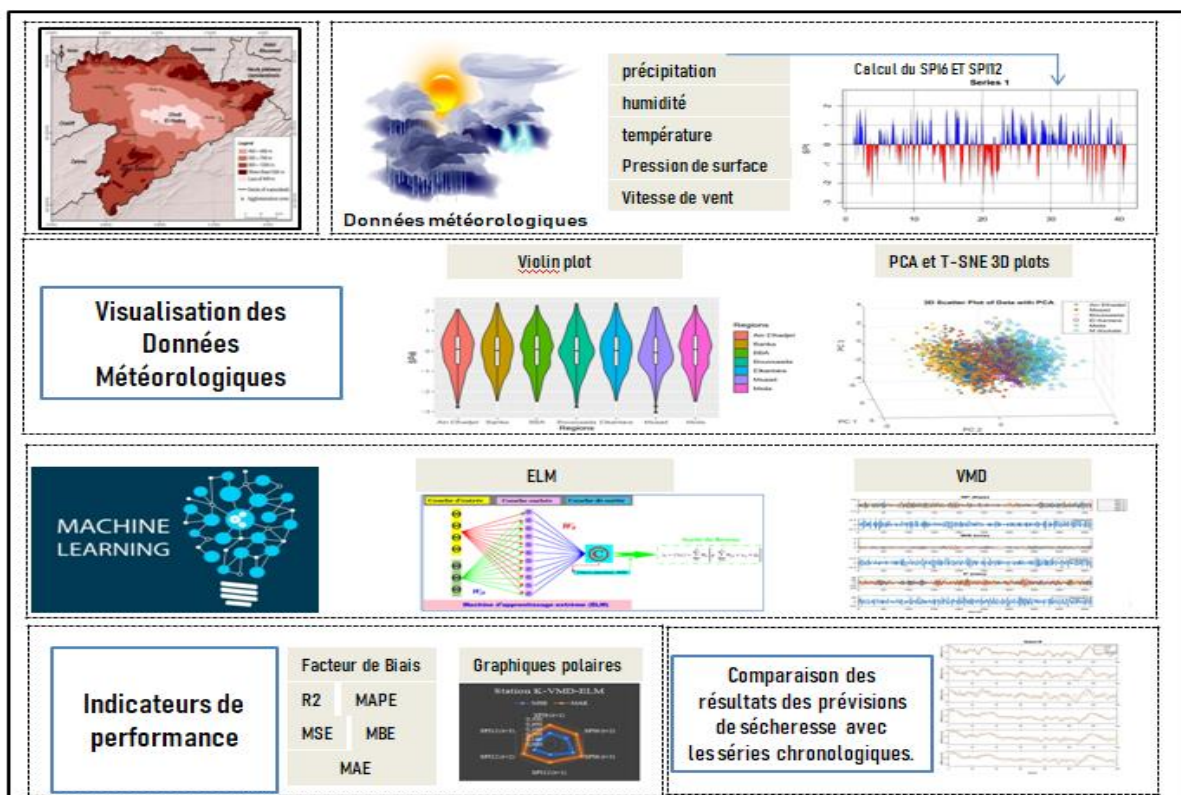


Figure 2. Carte de localisation des stations d'étude dans le bassin du Hodna

### 3.3. Processus de Collecte et Analyse des Données Météorologiques pour la Prédiction de la Sécheresse

La collecte des données météorologiques inclut divers paramètres : les précipitations, l'humidité, la température, la pression de surface et la vitesse du vent. Les précipitations ont été utilisées pour le calcul du SPI<sub>6</sub> et SPI<sub>12</sub> pour les six stations d'étude. Ces données sont ensuite visualisées à l'aide de méthodes graphiques : les plots en violon, les analyses en composantes principales (PCA) et t-SNE en 3D, permettant une compréhension approfondie des tendances et anomalies climatiques. L'application des techniques d'apprentissage automatique l'ELM (Extreme Learning Machine) et la décomposition en modes empiriques (VMD), permet d'améliorer la précision des prévisions. Enfin, les indicateurs de performance comme le R<sup>2</sup>, le MAPE, le MSE, et le MAE sont utilisés pour évaluer la qualité des modèles prédictifs, facilitant ainsi la comparaison des résultats avec les séries chronologiques historiques pour une meilleure anticipation des périodes de sécheresse (Figure 3).

29


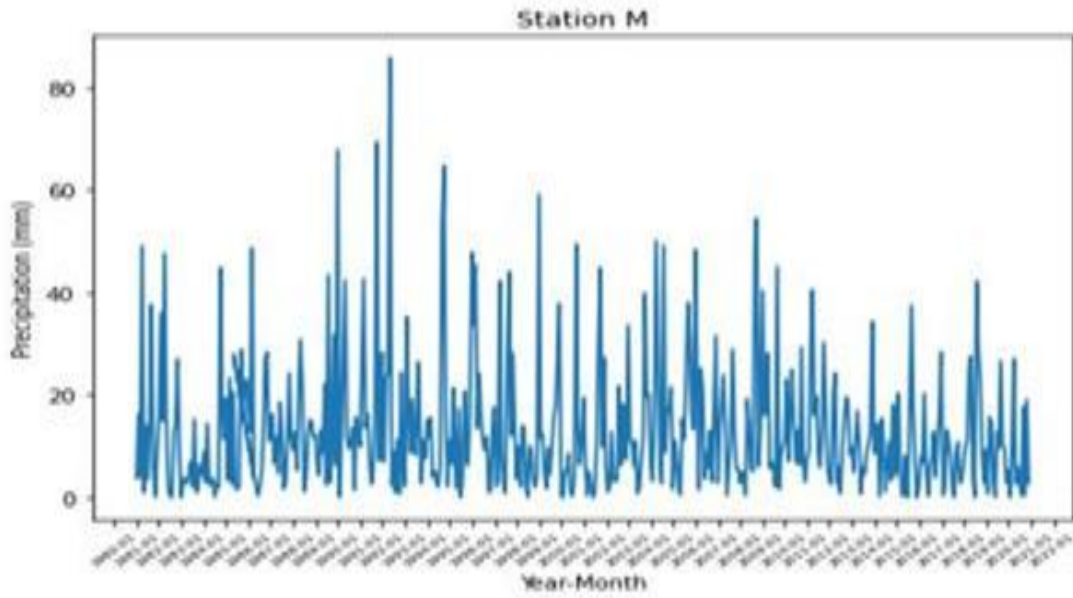



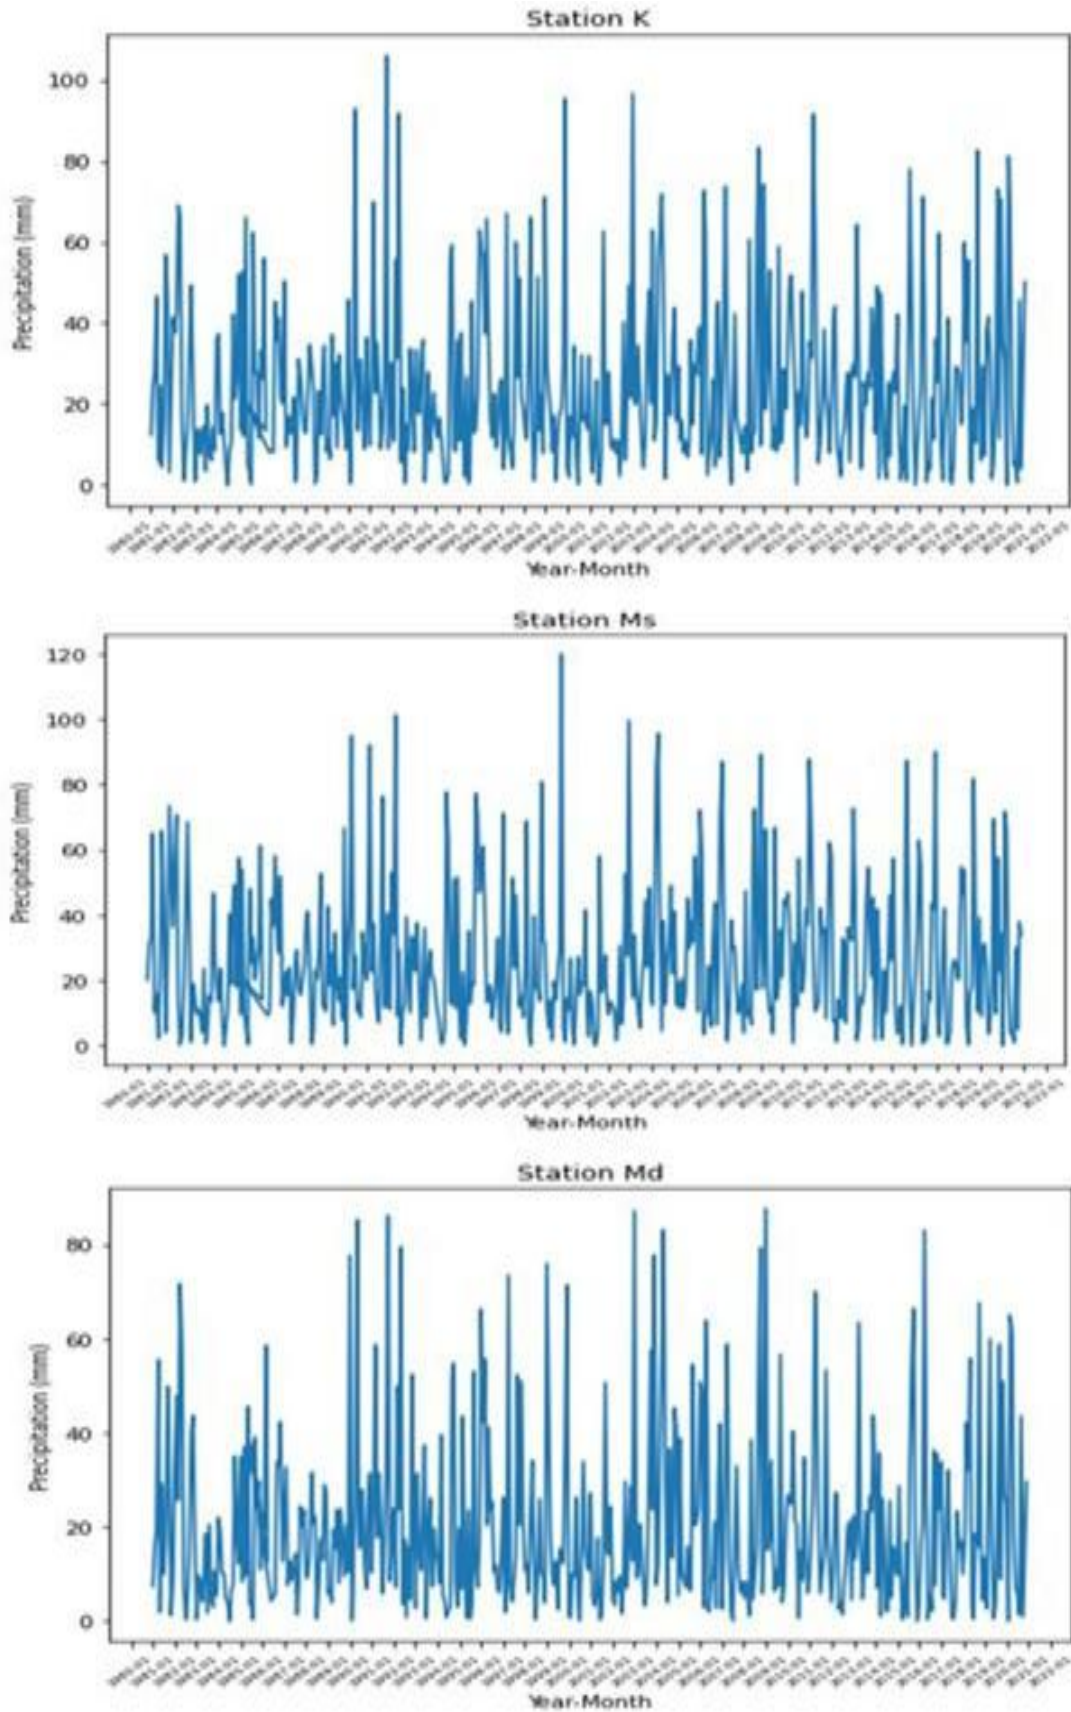
**Figure 3.** Flowchart de la Collecte, Visualisation et Analyse des Données Météorologiques.

### 3.4. Présentation & Critique de la Base de Données

Les données météorologiques des stations ultérieures sont utilisées pour modéliser et prévoir l'indice de sécheresse dans le bassin de Hodna. La température annuelle moyenne dans toutes les stations est de 24,6 °C. Le mois décembre est le plus froid, tandis que mai est le mois le plus chaud. Chaque saison connaît des précipitations et la moyenne mensuelle des précipitations est de 23,9 mm. Les précipitations totales quotidiennes maximales ont été enregistrées en mai 2004 à 132,5 mm. La Figure 4 montre la variation des précipitations totales au cours des années 1981 à 2020. Le Tableau 2 fournit plus de statistiques sur l'humidité relative (HR en %), la pression standard (SP en Kpa), la vitesse du vent (WS en m/s), la température relative (RT en C), et les précipitations (P en mm).

30





**Figure 4.** Tendances des précipitations mensuelles pour six stations (1981-2020)

**Tableau 1.** Coordonnées, Elévation et ID des stations Sélectionnées

Station N°	Station name	Station Abrev	Station ID	Coordinates		Elevation (m)
				Latitude	Longitude	
1	Ain Elhadjel	AH	116063919	35.6173389	3.6544501	564
2	Msaad	M	x	34.159213	3.497482	750
3	Bou Saada	BS	60515	35.2125133	4.016485	461
4	ElKantara	K	2497976	35.2036679	5.4806869	560
5	M'sila	Ms	60467	35.7217889	4.3525362	471
6	M'doukel	Md	117400	35.1131928	4.97184	379

33

**Tableau 2.** Statistiques des facteurs recueillis pour six stations (1981-2020)

Statistiques	Station	Station	Station	Station K	Station	Station
	AH	M	BS		Ms	Md
	RH (%)					
Minimum	23.620	17.000	22.250	22.120	22.880	21.750
Maximum	83.190	77.690	83.250	80.940	80.500	77.690
Moyenne	56.751	46.009	55.342	52.739	54.393	50.459
Médiane	58.310	45.285	56.410	53.120	55.625	50.620
Écart-type	14.937	15.478	15.344	14.743	14.909	14.722
Kurtosis	-1.020	-1.155	-1.021	-1.113	-1.087	-1.149
Coefficient de variation	0.263	0.336	0.277	0.280	0.274	0.292
	SP (Kpa)					
Minimum	92.540	92.660	90.030	94.530	94.540	95.620
Maximum	94.460	94.540	91.830	96.470	96.500	97.610
Moyenne	93.260	93.357	90.745	95.236	95.233	96.331
Médiane	93.230	93.320	90.740	95.195	95.180	96.270
Écart-type	0.280	0.283	0.262	0.297	0.298	0.312
Kurtosis	1.573	1.388	1.216	1.550	1.564	1.417
Coefficient de variation	0.003	0.003	0.003	0.003	0.003	0.003
	WS (m/s)					
Minimum	2.480	2.510	2.810	2.200	2.020	1.940
Maximum	6.350	6.160	7.040	5.390	5.770	6.050
Moyenne	4.010	4.221	4.505	3.915	3.879	4.043

Statistiques	Station	Station	Station	Station K	Station	Station
	AH	M	BS		Ms	Md
Médiane	3.930	4.210	4.405	3.910	3.860	4.020
Écart-type	0.639	0.598	0.757	0.458	0.545	0.597
Kurtosis	0.738	-0.090	0.156	0.379	0.419	0.136
Coefficient de variation	0.159	0.142	0.168	0.117	0.141	0.148
RT (°C)						
Minimum	16.050	16.500	14.770	16.170	15.330	15.230
Maximum	36.530	36.510	36.200	37.340	37.770	36.950
Moyenne	24.956	24.828	24.362	24.491	25.176	24.003
Médiane	25.140	24.540	24.440	24.380	25.400	23.715
Écart-type	3.583	3.332	3.473	3.531	3.685	3.583
Kurtosis	-0.158	0.030	-0.056	-0.083	-0.136	-0.101
Coefficient de variation	0.144	0.134	0.143	0.144	0.146	0.149
P (mm)						
Minimum	0.050	0.000	0.020	0.010	0.030	0.000
Maximum	132.150	85.840	132.470	106.010	119.990	87.660
Moyenne	30.662	13.128	28.461	24.337	26.355	20.307
Median	24.685	9.880	22.385	18.745	20.185	14.945
Écart-type	24.270	12.864	23.322	20.034	21.573	18.689
Kurtosis	0.896	4.403	1.637	1.476	1.400	1.814
Coefficient de variation	0.792	0.980	0.819	0.823	0.819	0.920

### 3.4.1. Visualisation des Données Météorologiques : Violin Plots, 3D PCA Scatter Plot, et 3D t-SNE Plot :

Cette section présente une visualisation complète des données météorologiques recueillies auprès des stations étudiées. Pour mieux comprendre la distribution et les relations au sein des données, nous utilisons trois techniques de visualisation distinctes :

- *Le Diagramme de Violin* est un graphique statistique utilisé pour comparer les distributions de probabilité, montrant la distribution complète des données plutôt que de simples statistiques récapitulatives comme les moyennes et les intervalles interquartiles

(Figure 5). Dans le contexte des données sur la vitesse du vent pour les stations AH, BS, K, M, Md et Ms de 1981 à 2020 :

Ain Elhadjel : La vitesse médiane du vent est d'environ 3,9, avec un maximum de 6,3 et un minimum de 2,4. Le premier quartile est à 3,6, et le troisième quartile est à 4,3.

Bou Saada : La vitesse médiane du vent est de 4,4, avec un maximum de 7,0 et un minimum de 2,8. Le premier quartile est à 4,0 et le troisième quartile est à 4,9.

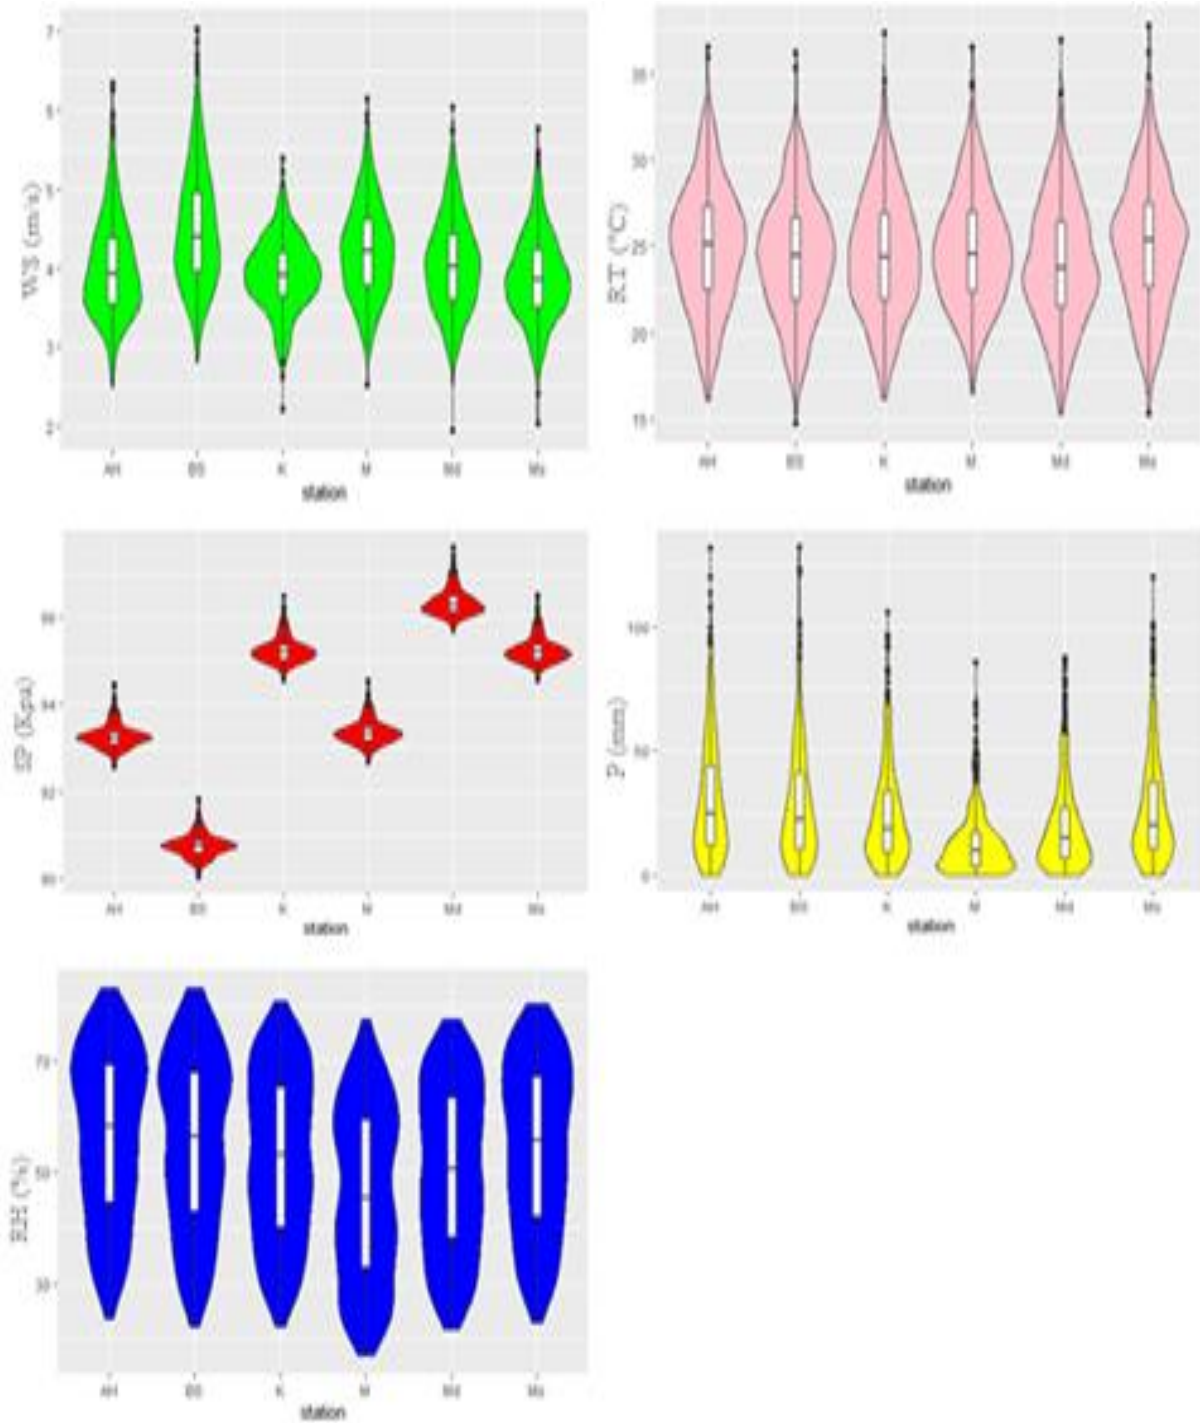
El Kantara : La vitesse médiane du vent est de 3,9, avec un maximum de 5,3 et un minimum de 2,2. Le premier quartile est à 3,7 et le troisième quartile est à 4,2.

Msaad : La vitesse médiane du vent est de 4,2, avec un maximum de 6,1 et un minimum de 2,5. Le premier quartile est à 3,8 et le troisième quartile est à 4,5.

M'doukel : La vitesse médiane du vent est de 4,0, avec un maximum de 6,0 et un minimum de 1,9. Le premier quartile est à 3,5 et le troisième quartile est à 4,4.

M'sila : La vitesse médiane du vent est de 3,8, avec un maximum de 5,7 et un minimum de 2,0. Le premier quartile est à 3,4 et le troisième quartile est à 4,3.

Les observations pour la vitesse du vent sont conformes à celles présentées au Tableau 2, lequel résume les paramètres statistiques des facteurs recueillis pour les six stations. Cette concordance s'étend à l'ensemble des paramètres étudiés, attestant de la cohérence et de la représentativité des données collectées pour chaque station. Ces observations fournissent un aperçu détaillé de la distribution des vitesses du vent à travers les stations spécifiées, mettant en évidence des différences dans les médianes, les maximums, les minimums et les quartiles, aidant à comprendre la variabilité et les tendances des données au cours de la période spécifiée.



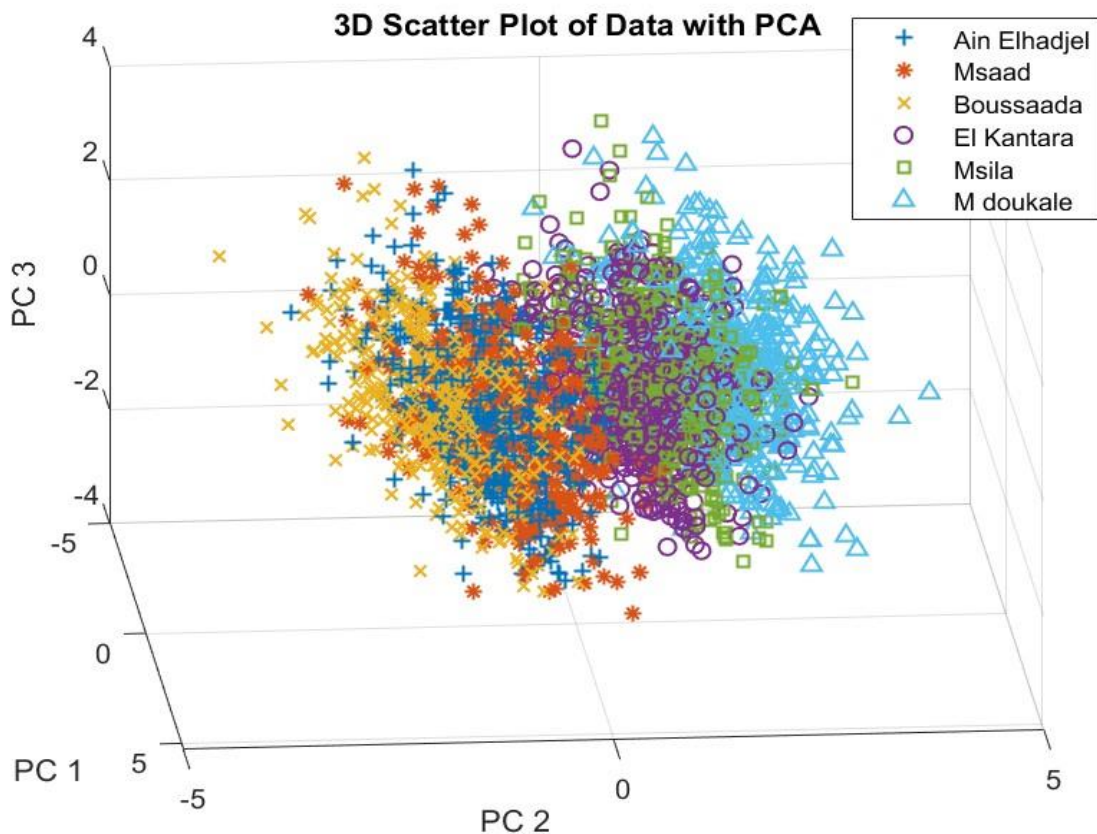
**Figure 5.** Diagrammes en violon de divers paramètres de données météorologiques des stations.

- *Analyse en Composantes Principales (PCA)* : Le diagramme de dispersion 3D de l'ACP est un outil très utilisé pour la visualisation des données à haute dimension, car il réduit la dimensionnalité des données tout en préservant le maximum de variance. Dans ce diagramme, chaque point correspond à une observation et la position du point sur les

axes  $x$ ,  $y$  et  $z$  correspondent aux valeurs des première, deuxième et troisième composantes principales, respectivement (Figure 6).

Le graphique montre la distribution des données pour chaque station (Ain Elhadjel, Msaad, Boussaada, Elkantara, Msila, Mdoukel). Les différents symboles de la légende représentent les différentes stations, ce qui permet de comparer la distribution des observations pour chaque station. Les variables de l'ACP sont distribuées entre -5 et 5, ce qui indique que les données ont une large gamme de valeurs. Les observations de chaque station sont regroupées, cela peut indiquer que les variables sont fortement corrélées.

37



**Figure 6.** Nuage de points 3D des données avec ACP.

- *t-Intégration de Voisinage Stochastique Distribuée (t-SNE)* : Les graphes 3D en t-SNE sont un type d'outil de visualisation de données utilisé pour réduire la dimensionnalité des données à haute Dimension et visualiser les relations entre les différents points de données. Les points de données représentent des observations provenant de différentes

stations autour de bassin de Hodna, et les différents symboles de la légende correspondent à chaque station (Figure 7).

L'algorithme t-SNE minimise la divergence entre deux distributions : une distribution qui mesure les similarités par paire des points de données à haute dimension et une distribution qui mesure les similarités par paire des encastrement à basse dimension. Le résultat est un graphique en 3D où les points de données similaires sont regroupés et les points de données dissemblables sont plus éloignés les uns des autres.

38

Les dimensions 3 et 2 du t-SNE se situent entre -50 et 50, tandis que la dimension 1 du t-SNE se situe entre -40 et 40. Cela indique que les données présentent un large éventail de valeurs et que l'algorithme t-SNE a préservé la structure des données à haute dimension dans le graphique 3D. Les points de données de toutes les stations sont regroupés, cela peut indiquer que les variables des stations sont fortement corrélées.

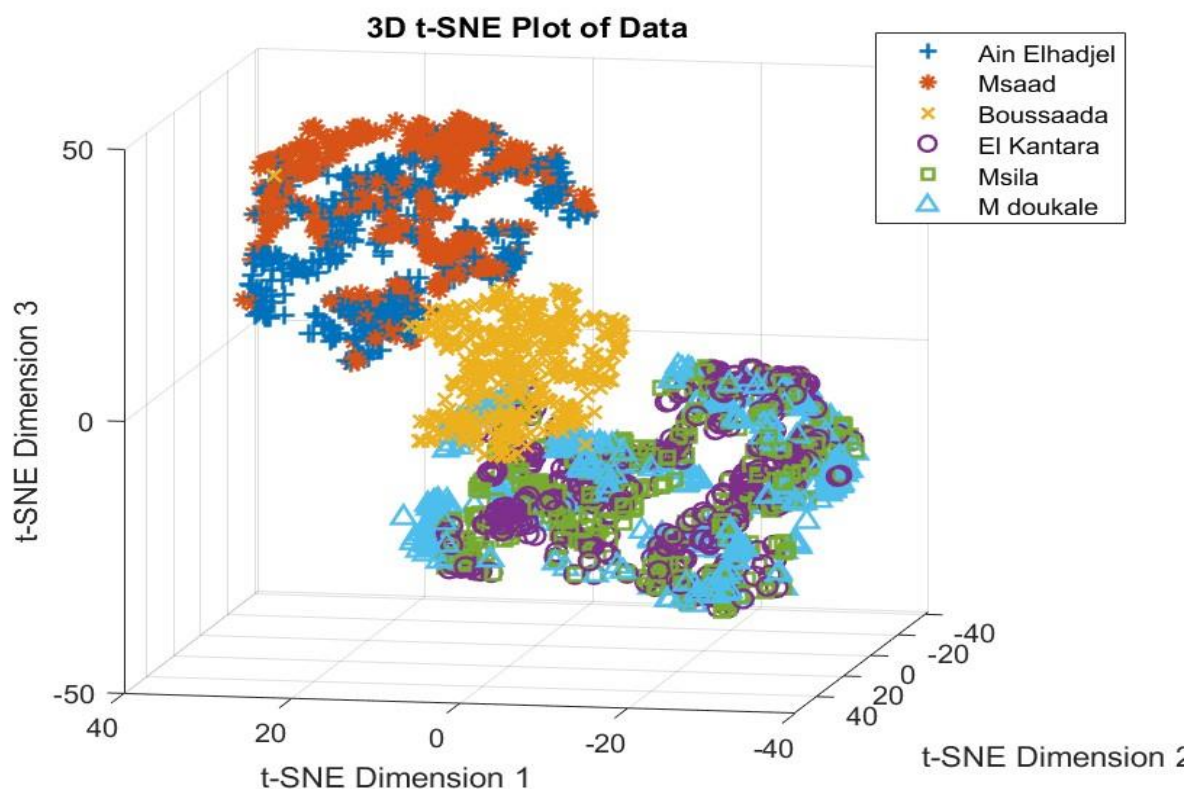


Figure 7. Graphique 3D t-SNE des données.

### 3.4.2. Comblement des lacunes de la Base de Données :

Dans notre ensemble de données météorologiques, des valeurs manquantes étaient présentes en raison de divers facteurs tels que des défaillances d'équipement et des erreurs de transmission de données. Étant donné que la proportion de valeurs manquantes était relativement faible, nous avons choisi d'utiliser l'imputation médiane pour régler ce problème.

L'imputation médiane consiste à remplacer les valeurs manquantes par la médiane des données disponibles pour chaque paramètre. Cette méthode a été choisie pour sa simplicité et son efficacité à préserver la tendance centrale des données, en particulier dans les cas où les données ne suivent pas une distribution normale. Le choix de l'imputation médiane était fondé sur les considérations suivantes :

39

***Robustesse aux valeurs aberrantes*** : Contrairement à l'imputation moyenne, la médiane est moins affectée par les valeurs extrêmes, ce qui en fait une mesure plus fiable de la tendance centrale en présence de valeurs aberrantes.

***Simplicité et efficacité*** : L'imputation médiane est simple à mettre en œuvre et efficace sur le plan informatique, ce qui garantit une solution rapide et efficace au problème des valeurs manquantes.

***Distorsion minimale*** : Étant donné la faible proportion de valeurs manquantes, l'imputation médiane introduit une distorsion minimale à l'ensemble des données, conservant ses propriétés statistiques originales.

L'imputation médiane a été appliquée comme suit :

***Identification des valeurs manquantes*** : L'ensemble de données a été analysé pour identifier toutes les instances de données manquantes pour chaque paramètre.

***Calcul des médianes*** : La valeur médiane de chaque paramètre a été calculée à l'aide des points de données disponibles.

***Imputation*** : Les valeurs manquantes ont été remplacées par les valeurs médianes correspondantes.

Pour valider l'efficacité de l'imputation médiane, l'ensemble de données imputées a été comparé aux données originales, ce qui a permis de s'assurer que les propriétés statistiques, comme la moyenne, la variance et la distribution, demeuraient cohérentes. Cette validation a confirmé que l'imputation médiane était une méthode appropriée pour traiter les valeurs manquantes dans notre ensemble de données, améliorant ainsi l'exhaustivité et la fiabilité des données pour une analyse ultérieure.

### 3.5. Indice de Précipitation Standardisée SPI

L'indice de précipitation standardisée (SPI) est un indice simple qui peut être facilement calculé et statistiquement lié à la probabilité de propagation pour n'importe quelle période. C'est un indice largement reconnu pour caractériser les sécheresses météorologiques et peut aider à évaluer la gravité de la sécheresse pour n'importe quel endroit et n'importe quelle période en raison de sa distribution normale et de fréquences prolongées (McKee *et al.*, 1993). Le SPI peut être calculé à différentes échelles de temps et peut fournir une alerte précoce de la sécheresse. L'Organisation Météorologique Mondiale (OMM) a recommandé le SPI comme principal indice de sécheresse météorologique que les pays devraient utiliser pour surveiller et enquêter sur les situations de sécheresse (Hayes *et al.*, 2011). Le SPI utilise uniquement les prélèvements et peut caractériser la sécheresse ou l'humidité anormale à différentes échelles de temps, le rendant plus comparable entre les régions ayant des climats différents que l'indice de gravité de la sécheresse de Palmer (PDSI). Le SPI est moins complexe à calculer que le PDSI et peut être calculé sur aussi peu que 20 ans de données, mais idéalement, la série chronologique devrait avoir un minimum de 30 ans de données.

40

#### 3.5.1. Méthodes de Calcul du SPI

Le SPI a été utilisé pour quantifier le déficit pluviométrique au sein du bassin Hodna. Pour calculer le SPI, des données à long terme sur 40 ans (1981-2020) ont été utilisées. La procédure standard consistait d'abord à ajuster le pluviomètre donné dans une fonction de distribution de probabilité comme décrit par McKee *et al.*, (1993).

Dans cette étude, un ensemble de données couvrant trois mois a été utilisé. Par la suite, les valeurs SPI ont été calculées et utilisées pour évaluer et catégoriser les sécheresses. La préférence pour la fonction de distribution Gamma dans cette recherche était basée sur son intégration efficace avec les données de séries chronologiques de précipitations (Bordi & Sutera, 2007). La distribution Gamma est exprimée en termes de sa fonction de densité de probabilité comme :

$$g(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-x/\beta} \text{ for } x > 0(1)$$

Dans cette expression,  $\alpha$  représente le paramètre de forme,  $\beta$  est le paramètre d'échelle,  $x$  représente la quantité de pluie en millimètres,  $\Gamma(\alpha)$  est la valeur résultante de la fonction gamma, et  $-x$  correspond aux précipitations moyennes en millimètres.

La valeur  $\Gamma(\alpha)$  est déterminée par une équation mathématique standard connue sous le nom de fonction Gamma. Ce calcul est dérivé en employant une fonction intégrale selon l'approche décrite par (Cacciamani et al., 2007) exprimé comme suit :

$$\Gamma(\alpha) = \int_0^{\infty} y^{\alpha-1} e^{-y} dy \quad (2)$$

41

Dans ce contexte,  $y$  représente le résultat obtenu à partir de l'équation 1, indiquant qu' $y$  est équivalent à  $g(x)$ . La fonction Gamma fournie dans l'équation 2 a été évaluée par une approche numérique, en utilisant des valeurs tabulées dépendant du paramètre de forme  $\alpha$ . La détermination des valeurs optimales pour  $\alpha$  et  $\beta$  impliquait l'application d'une approche de probabilité maximale, comme décrit dans les équations 3 et 4 :

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

$$\beta = \frac{\bar{x}}{\alpha} \quad (4)$$

Où ;  $\alpha$ ,  $\beta$  et  $x$  conservent la même signification que celle définie dans l'équation (1), et  $A$  représente un échantillon de statistique. Le calcul de la statistique de l'échantillon est établi à travers la relation :

$$A = \ln(\bar{x}) = \frac{\ln(x)}{n} \quad (5)$$

Où ;  $n$  représente le nombre d'observations. La fonction de densité de probabilité  $g(x)$  dans l'équation 1 est intégrée par rapport à  $x$  pour obtenir une expression de la probabilité cumulée  $G(x)$ . Cette fonction est applicable lorsqu'une quantité particulière de pluie est reçue au cours d'un mois et d'une durée spécifiques. Par conséquent, les valeurs calculées de probabilité cumulée pour des précipitations non nulles sont déterminées grâce à l'utilisation des équations 6 et 7, respectivement.

$$g(x) = \int_0^x x^{\alpha-1} e^{-\frac{x}{\beta}} dx \quad (6)$$

Où;  $g(x)$  représente la probabilité cumulée de précipitations non nulles. L'application de la fonction gamma est valable pour les valeurs de précipitations  $x > 0$  dans la série temporelle considérée du bassin. Pour les valeurs non nulles, les probabilités cumulatives nulles et non nulles sont calculées. Cette probabilité est représentée par la fonction  $H(x)$ , définie comme :

$$H(x) = q + (1 + q)F(x, \alpha, \beta)(7)$$

Où ;  $H(x)$  représente la probabilité cumulative et  $q$  est la probabilité d'une précipitation nulle. Dans ce cas, en prenant  $m$  comme le nombre d'occurrences nulles dans la série chronologique des données de précipitations, le rapport  $nm$  a été utilisé pour évaluer la probabilité  $q$ . Ensuite, la probabilité cumulative a été convertie en une distribution normale standard, de telle sorte que la moyenne et la variance des valeurs SPI soient nulles et unes respectivement. Pour réaliser cette transformation, une approximation basée sur la méthode de Mishra et Desai a été adoptée utilisant les équations suivantes :

$$SPI = - \left( K - \frac{c_0 + c_1 k + c_2 k^2}{1 + d_1 k + d_2 k^2 + d_3 k^3} \right) \text{ for } 0 < H(x) \leq 0.5(8)$$

$$SPI = + \left( K - \frac{c_0 + c_1 k + c_2 k^2}{1 + d_1 k + d_2 k^2 + d_3 k^3} \right) \text{ for } 0.5 < H(x) \leq 1(9)$$

La valeur de  $k$  a été déterminée en utilisant les équations 10 et 11 formulées comme suit :

$$k = \sqrt{\ln\left(\frac{1}{H(x)^2}\right)} \text{ for } 0 < H(x) \leq 0.5(10)$$

$$k = \sqrt{\ln\left(\frac{1}{1-H(x)^2}\right)} \text{ for } 0.5 < H(x) < 1(11)$$

Dans cette étude, les valeurs SPI ont été exploitées en utilisant un pas de temps mensuel et le critère de seuil présenté dans le Tableau 3 ont été utilisés pour définir les conditions de sécheresse (Mckee *et al.*, 1993).

Le Tableau présente les diverses conditions avec les valeurs de l'SPI. Les valeurs supérieures à zéro indiquent un surplus d'eau, tandis que les valeurs inférieures à zéro indiquent un déficit hydrique.

**Tableau 3.** Tableau de SPI

Valeurs de SPI	Condition de sécheresse et d'inondation
2.0+	Extrêmement humide
1.5à1.99	Très humide
1.0à1.49	Modérément humide
-0.99à 0.99	Près de la Normale
-1.0à-1.49	Modérément sec
-1.5à-1.99	Sévèrement sec
-2et moins	Extrêmement sec

### 3.5.2. Les Choix des Echelles Temporelles du SPI

Dans cette section, nous discutons des raisons pour lesquelles nous avons choisi les échelles temporelles spécifiques de SPI<sub>6</sub> et SPI<sub>12</sub> pour notre analyse de la sécheresse dans le bassin de la rivière Hodna. L'utilisation de ces deux échelles temporelles distinctes permet de capturer différentes facettes des conditions de sécheresse : la sécheresse météorologique à court terme (SPI<sub>6</sub>) et la sécheresse hydrologique à plus long terme (SPI<sub>12</sub>).

Le SPI<sub>6</sub> est particulièrement adapté pour évaluer la sécheresse météorologique, qui reflète les déficits de précipitations sur une période de six mois et peut affecter rapidement les sols et les cultures (Sécheresse Agricole). En revanche, le SPI<sub>12</sub> est utilisé pour évaluer la sécheresse hydrologique, qui s'intéresse aux impacts à plus long terme sur les ressources en eau telles que les niveaux des rivières, des lacs et des aquifères, sur une période de douze mois.

En combinant ces deux échelles temporelles, nous sommes en mesure de fournir une analyse plus complète et nuancée des conditions de sécheresse dans le bassin de Hodna, ce qui est essentiel pour une gestion efficace des ressources en eau et une planification de l'adaptation au changement climatique.

### 3.5.3. Calcul des SPI

Pour démontrer la variation temporelle de la sécheresse à différentes échelles de temps (6 et 12 mois) dans le bassin de Hodna, les SPI<sub>s</sub> pour les différentes stations ont été générés et présentés dans la Figure 6.

Les valeurs de l'SPI renvoient les périodes humides et sèches, les valeurs positives indiquant des précipitations supérieures à la médiane et les valeurs négatives indiquant des précipitations inférieures à la médiane. Les classes de gravité pour les valeurs de l'SPI sont catégorisées en fonction de l'écart-type par rapport aux médianes. Ces informations sont cruciales pour évaluer et surveiller les conditions de l'eau à différentes échelles de temps.

44

La variabilité des sécheresses peut être attribuée au fait que tous les stations connaissent une variabilité naturelle élevée dans le climat est caractéristique de bassin de Hodna. La série temporelle de l'indice de SPI présente une variabilité significative avec des fluctuations fréquentes sur les échelles de temps plus courtes. Cette forte variabilité est liée aux périodes plus courtes, ce qui peut refléter des conditions de précipitations changeantes à court terme.

Avec l'augmentation des pas de temps, les fluctuations du SPI ont eu tendance à être faibles, ce qui a entraîné une diminution de la volatilité. Les caractéristiques des changements interannuels et interdécadaux sont devenues évidentes, reflétant les caractéristiques à long terme de la sécheresse. Ce phénomène saisit clairement les variations subtiles du bilan hydrique à des intervalles mensuels et trimestriels.

Toutes les stations ont eu marqué des épisodes fréquents de sécheresse extrême qui peuvent atteindre même 9 épisodes dans les stations d'Ain Elhadjel et Boussaâda.

Dans la plupart des stations, les périodes les plus longues des événements secs ont été marquées dans la 3ème lag de la période d'étude, que pour la station de Msaad a été marquées dans la 4ème lag avec la plus longue période sèche marquée.

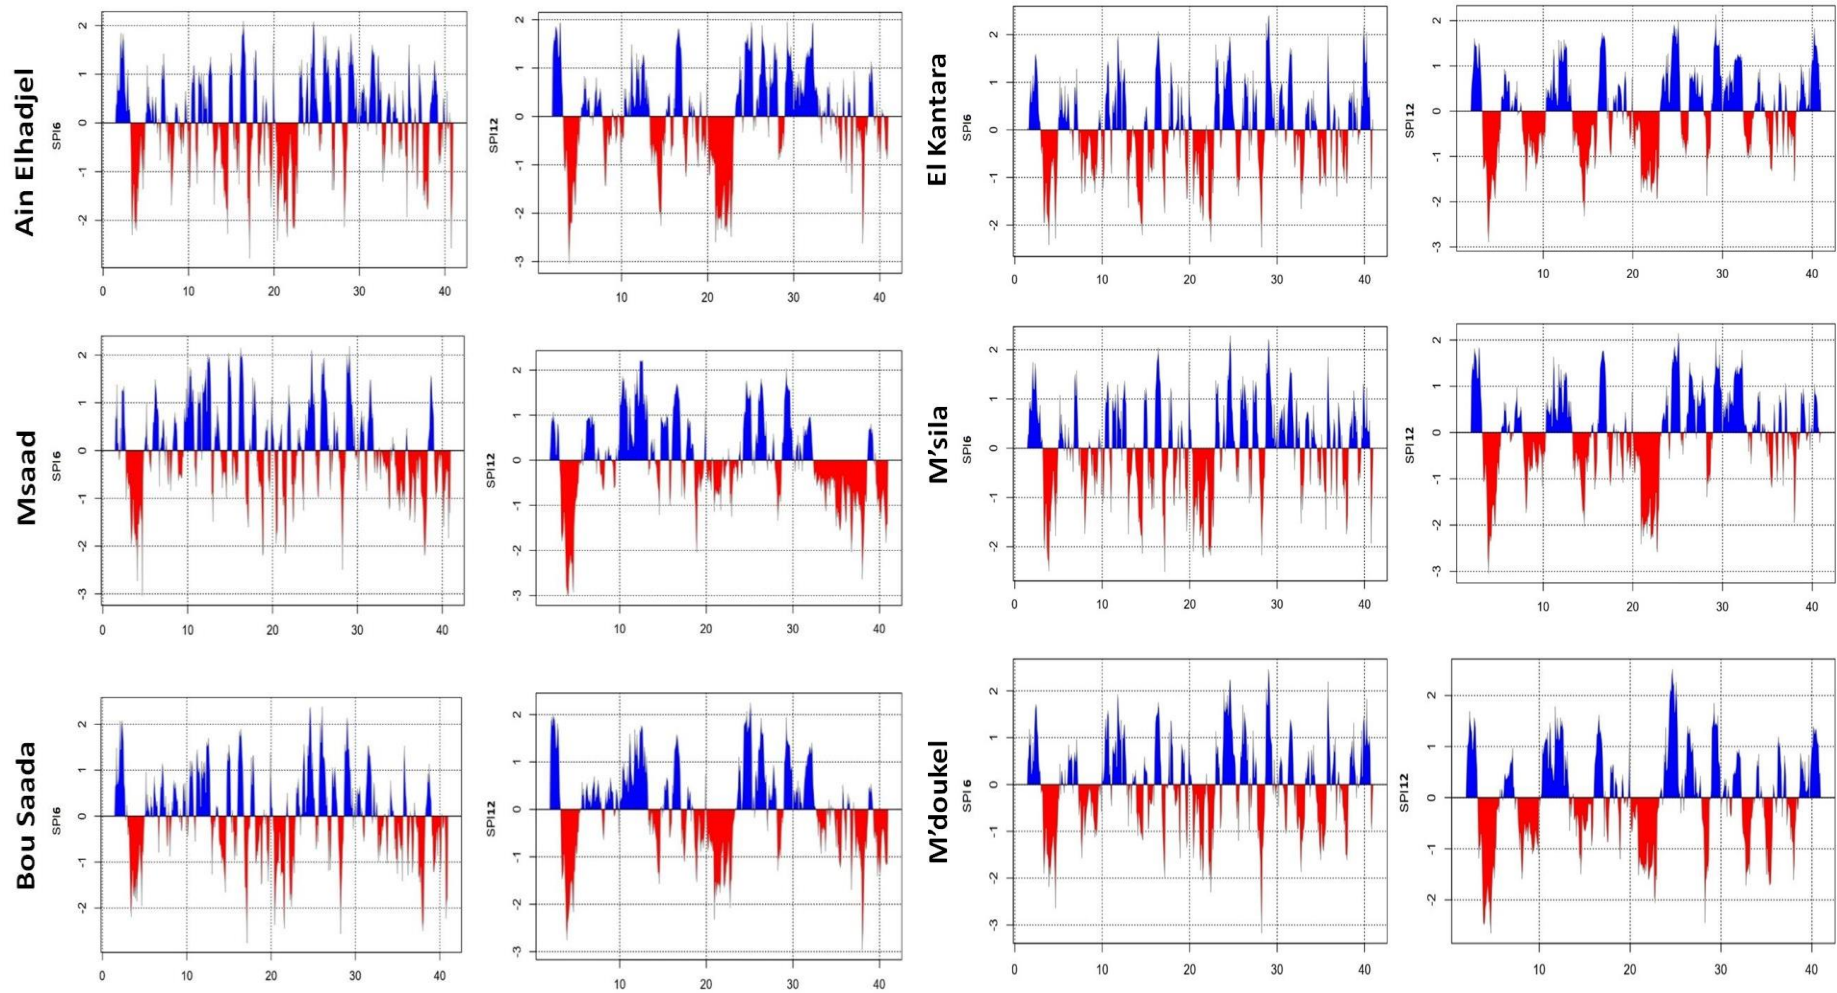


Figure 8. SPI time séries à 6-et 12-mois.

### 3.6. Conclusion

Dans ce chapitre, nous fournissons un aperçu détaillé du bassin Hodna et examinons de manière critique la base de données météorologiques complète utilisée pour notre étude. De plus, nous présentons la méthodologie de calcul de l'indice normalisé des précipitations (SPI), un outil clé pour analyser la variabilité des précipitations. En jetant ces bases, nous visons à faciliter une compréhension approfondie des modèles hydrologiques et de leurs implications dans la zone d'étude. Cette base est essentielle pour les analyses approfondies et les discussions qui suivent dans les chapitres suivants, contribuant ainsi à l'objectif plus large de prévoir les conditions de sécheresse à l'aide de modèles d'IA.

46

## Chapitre 4. Prédiction de la Sécheresse par les techniques de L'IA

### 4.1. Introduction

L'estimation précise et immédiate de la sécheresse est essentielle pour améliorer notre compréhension de ses variations dans le temps et l'espace, ce qui est crucial pour les études hydrologiques et la gestion des ressources en eau. Les mesures directes de la sécheresse, obtenues par des indices comme l'Indice de Sécheresse Normalisé (SPI), fournissent des données réelles et instantanées. Cependant, ces indices ne sont pas toujours disponibles en nombre suffisant et, dans certains cas, les données peuvent être incomplètes. Bien que la prévision de la sécheresse à différents pas de temps soit bien documentée, il est nécessaire d'améliorer la précision de ces prévisions à l'aide de nouvelles méthodes. Cela a motivé le développement de nouveaux algorithmes de modélisation capables de surmonter les limites de certains modèles autonomes, en particulier en ce qui concerne l'amélioration des capacités de généralisation et l'estimation précise des événements de sécheresse extrêmes.

47

Dans ce chapitre, nous présentons et discutons les résultats de la prévision de l'indice de la sécheresse pour six stations : station Ain El hadjel, station Msaad, station Boussaada, station Elkantara, station M'sila et station M'doukel, dans le bassin du Hodnaen Algérie, en utilisant deux types différents d'approches d'apprentissage automatique efficaces évoluant en apprentissage machine extrême (ELM) et en décomposition en mode variationnel (VMD-ELM).

### 4.2. Extrême Learning Machine (ELM)

La machine d'apprentissage extrême (ELM) est un algorithme d'apprentissage automatique nouvellement proposé pour les réseaux neuronaux à simple couche (SLFN) a été introduit par Huang et al. (2006). Il a été largement appliqué pour résoudre des problèmes de prédiction dans divers domaines et est actuellement le centre d'intérêt parmi le changement climatique et les applications d'ingénierie (Acharya et al., 2013 ; Sahin et al., 2014). Des études basées sur l'ELM ont montré que les modèles ELM sont utilisables et efficaces par rapport aux schémas de classification vectorielle ou aux

réseaux de neurones conventionnels. En outre, cet algorithme ne nécessite aucun ajustement de paramètres autres que l'architecture réseau prédéfinie, surmontant ainsi de nombreuses difficultés rencontrées par les algorithmes à base de gradient. Rajesh et Prakash (2011) ont déclaré que le modèle est un algorithme plus rapide par rapport à d'autres algorithmes d'apprentissage traditionnels tels que la rétropropagation (BP) et la machine vectorielle de support (SVM). D'après les études d'Acharya et al. (2013) et de Deo et Sahin (2015), on peut conclure que l'algorithme ELM effectue la majeure partie de la formation en secondes ou en minutes pour les grandes applications compliquées qui ne peuvent pas être réalisées avec des modèles de réseaux neuronaux traditionnels. Şahin (2012), Şahin et al. (2014) et Deo & Şahin (2015) ont déclaré que le modèle ELM réalise des performances de généralisation similaires pour la catégorisation et la prédiction des données que les algorithmes BP et SVM et la décomposition par valeur singulière (SVD). Ainsi, il peut être considéré comme un algorithme de calcul optimal pour la prévision des paramètres météorologiques et atmosphériques.

48




Figure 9. Structure du modèle d'une machine d'apprentissage extrême (ELM)

Selon la théorie du modèle ELM, les SLFN standard avec des nœuds cachés  $M$  et une fonction d'activation  $g(\cdot)$  sont formulés comme suit :

$$\sum_{i=1}^M \beta_i g(x_k; c_i, a_i) = y_k \quad k = 1, 2, 3, \dots, N \quad (12)$$

Dans lequel  $w_i \in R$  est le vecteur de poids d'entr ee reliant le n oeud d'entr ee et  $i^{th}$ ,  $c_i \in R$  est un biais con u al eatoirement pour  $i^{th}$  et  $\beta_i$  est le vecteur de poids reliant le n oeud cach e  $i^{th}$  au n oeud de sortie.  $g(x_k; c_i, w_i)$  est la sortie du  $i^{th}$  li e   l' chantillon d'entr ee  $x_k$ . Chaque entr ee est con ue pour les n oeuds cach es pour ELM comme al eatoire. L' quation (12) est r ecrite comme suit:

$$H\beta = Y \quad (13)$$

$$H = \begin{bmatrix} g(x_1; c_1, w_1) & \dots & g(x_1; c_M, w_M) \\ g(x_N; c_1, w_1) & \dots & g(x_N; c_M, w_M) \end{bmatrix}_{N \times M} \quad (14)$$

$$H\beta = (\beta_1^T, \beta_2^T, \dots, \beta_L^T)_{m \times M}^T \quad (15)$$

$$H\beta = (t_1^T, t_2^T, \dots, t_L^T)_{m \times M}^T \quad (16)$$

$$\beta = H^+ Y \quad (17)$$

Dans lequel  $H^+$  d esigne l'inverse g en eralis e de Moore-Penrose de la matrice H.

L'algorithme ELM diff ere de la m ethodologie traditionnelle des r eseaux de neurones en ce que les poids d'entr ee et les biais de couche cach es des r eseaux d'alimentation directe ne doivent pas  tre d efinis au d ebut. Huang (2003) a prouv e que les PNLS avec des poids d'entr ee choisis au hasard peuvent identifier efficacement divers exemples de formation avec le moins d'erreur.  tant donn e que les biais de couche cach es et les poids d'entr ee sont choisis au hasard, les PNLS peuvent  tre consid er es comme un syst eme lin aire simple. Les poids de sortie reliant la couche cach ee de ce syst eme lin aire   la couche de sortie peuvent  tre identifi es analytiquement par une simple op eration inverse normalis ee des matrices de sortie de couche cach ee. Une telle approche simplifi ee rend l'ELM beaucoup plus rapide que les algorithmes d'apprentissage par anticipation traditionnels (Acharya et al., 2013 ;  ahin et al., 2014).

#### 4.3. Variable Mode Decomposition (VMD)

La d ecomposition en mode variable divise r ecursivement un signal multicomposant  $f$   a valeur r eelle en sous-signaux quasi-verticaux limit es  a la bande. De plus, les modes sont tous compacts autour d'une vibration centrale. Ainsi, on peut formuler l' equation du probl eme variationnel born e comme suit :

$$\left\{ \begin{array}{l} \min \left\{ \sum_1^K \left\| \partial t \left[ \left( \delta(t) + \frac{i}{\pi t} \right) u_k(t) \right] e^{-jw_k t} \right\|_2^2 \right\} \\ \{u_k\}, \{w_k\} \\ s. t \sum_{k=1}^K u_k = f \end{array} \right. \quad (18)$$

50

Dans lequel  $u_k$  se r ef ere au FMI d ecompos e  a bande limit ee,  $w_k$  d emontre le centre de fr equance de chaque FMI,  $\{w_k\} = \{w_1, w_2, \dots, w_k\}$  ;  $\{u_k\} = \{u_1, u_2, \dots, u_k\}$  (Wang et Markert, 2016).

#### 4.4. Indicateurs de performance :

Le facteur de biais, le coefficient de d etermination ( $R^2$ ), l'erreur quadratique moyenne (MSE), l'erreur absolue moyenne en pourcentage (MAPE), l'erreur absolue moyenne (MAE) et l'erreur de biais moyenne (MBE) ont  et e calcul es pour  evaluer les r esultats.

$$\text{Coefficient de d etermination } (R^2): \quad R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (19)$$

O u  $n$  est le nombre de mesures,  $y_i$  la valeur de la  $i^{\text{ eme}}$  mesure,  $\hat{y}_i$  la valeur pr edite correspondante et  $\bar{y}$  la moyenne des mesures.

$$\text{l'erreur quadratique moyenne (MSE)} : \quad MSE = \frac{1}{n} \sum_{i=1}^n (SPI_{sim,i} - SPI_{obs,i})^2 \quad (20)$$

$$\text{l'erreur absolue moyenne (MAE)} : \quad MAE = \frac{1}{n} \sum_{i=1}^n |SPI_{sim,i} - SPI_{obs,i}| \quad (0 < MAE < \infty) \quad (21)$$

l'erreur absolue moyenne en pourcentage (MAPE) :

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{SPI_{sim,i} - SPI_{obs,i}}{SPI_{sim,i}} \right| \times 100 \quad (22)$$

$$\text{l'erreur de biais moyenne (MBE)} : \quad MBE = \frac{1}{n} \sum_{i=1}^n (SPI_{sim,i} - SPI_{obs,i}) \quad (23)$$

Où  $SPI_{sim,i}$  correspond à la valeur SPI simulé de la  $i^{\text{ème}}$  mesure, et  $SPI_{obs,i}$  correspond à la valeur SPI observée de la  $i^{\text{ème}}$  mesure.

$$\text{Facteur bias} = \frac{\text{valeur réelle}}{\text{valeur mesurée ou estimée}} \quad (24)$$

### 4.5. Sélection des Variables Indépendantes et Description de la Base des Données

#### 4.5.1. Sélection des Variables Indépendantes

Dans le cadre de cette étude visant à prévoir l'indice de sécheresse, les variables indépendantes ont été soigneusement sélectionnées pour leur pertinence et leur impact potentiel sur les conditions de sécheresse. Les variables retenues sont : la température, vitesse de vent, précipitation, humidité relative, pression de surface, SPI<sub>6</sub> (Cet indice permet d'évaluer les anomalies de précipitations sur une période de six mois, fournissant un aperçu des conditions de sécheresse à court terme), SPI<sub>12</sub> (De manière similaire, l'indice SPI<sub>12</sub> mesure les anomalies de précipitations sur une période de douze mois, offrant une perspective plus longue sur les tendances des sécheresses). Ces variables ont été choisies en raison de leur impact potentiel sur l'indice de sécheresse et de leur capacité à fournir une vue d'ensemble complète des conditions climatiques influençant la sécheresse.

51

#### 4.5.2. Description de la Base de Données

La base de données utilisée dans cette étude couvre la période de 1981 à 2020 dans les six stations d'étude, offrant ainsi une série temporelle étendue pour une analyse approfondie. Les données proviennent de sources reconnues et sont décrites comme suit :

- Sources des données : Les informations ont été recueillies auprès de l'organisation météorologique nationale (ONM)
- Fréquence des mesures : Les données ont été enregistrées à une fréquence mensuelle, ce qui permet d'analyser en détail les variations temporelles et saisonnières des variables étudiées.

- Qualité des données : Un processus rigoureux de vérification a été mis en place pour garantir la précision des données. La proportion de valeurs manquantes était relativement faible, nous avons choisi d'utiliser l'imputation médiane pour régler ce problème.
- Format des données : Les données sont disponibles au format Excel, ce qui facilite leur utilisation dans les outils d'analyse et les modèles prédictifs.
- Prétraitement des données : Les données ont été traitées en vérifiant leur distribution à l'aide de diverses techniques. Une analyse en composantes principales (ACP) a été réalisée pour réduire la dimensionnalité tout en préservant les informations essentielles. De plus, des diagrammes de violon ont été utilisés pour visualiser la répartition des données, tandis que la méthode t-SNE (t-distributed Stochastic Neighbor Embedding) a permis d'explorer la structure complexe et les regroupements dans les données en trois dimensions.

### 4.6. Résultats

La prévision des sécheresses futures est essentielle pour la gestion des risques de sécheresse et l'alerte précoce à la sécheresse. Par conséquent, l'estimation des sécheresses avec diverses valeurs de délai est une tâche cruciale. Cette étude compare la performance d'estimation des valeurs SPI 6 et 12 avec un délai de 1, 2 et 3 mois avec l'ELM autonome en utilisant l'approche hybride établie en salissant les algorithmes ELM et VMD. Les variables d'entrée sont présentées au modèle ELM séparément pour sélectionner le modèle hybride VMD-ELM. Dans la configuration des modèles, les valeurs pression de surface (Kpa), humidité relative (%), vitesse de vent (m/s), température relative (°C), précipitation (mm) et  $SPI_{(t)}$  sont utilisées comme entrées, et les prochaines sécheresses de 1, 2 et 3 chevaux sont prédites. Les données ont été divisées en 70% pour la formation et 30% pour les tests. Au cours de la modélisation, les données ont été standardisées et la transformation inverse a été appliquée après la prédiction.

La Figure 10 présente les sous-composantes des variables météorologiques dans la station AH, séparées par VMD, à titre d'exemple. En présentant ces variables à

l'algorithme ELM, une nouvelle approche hybride a  t e propos ee et visait   evaluer son potentiel dans la pr evision de la s echeresse.

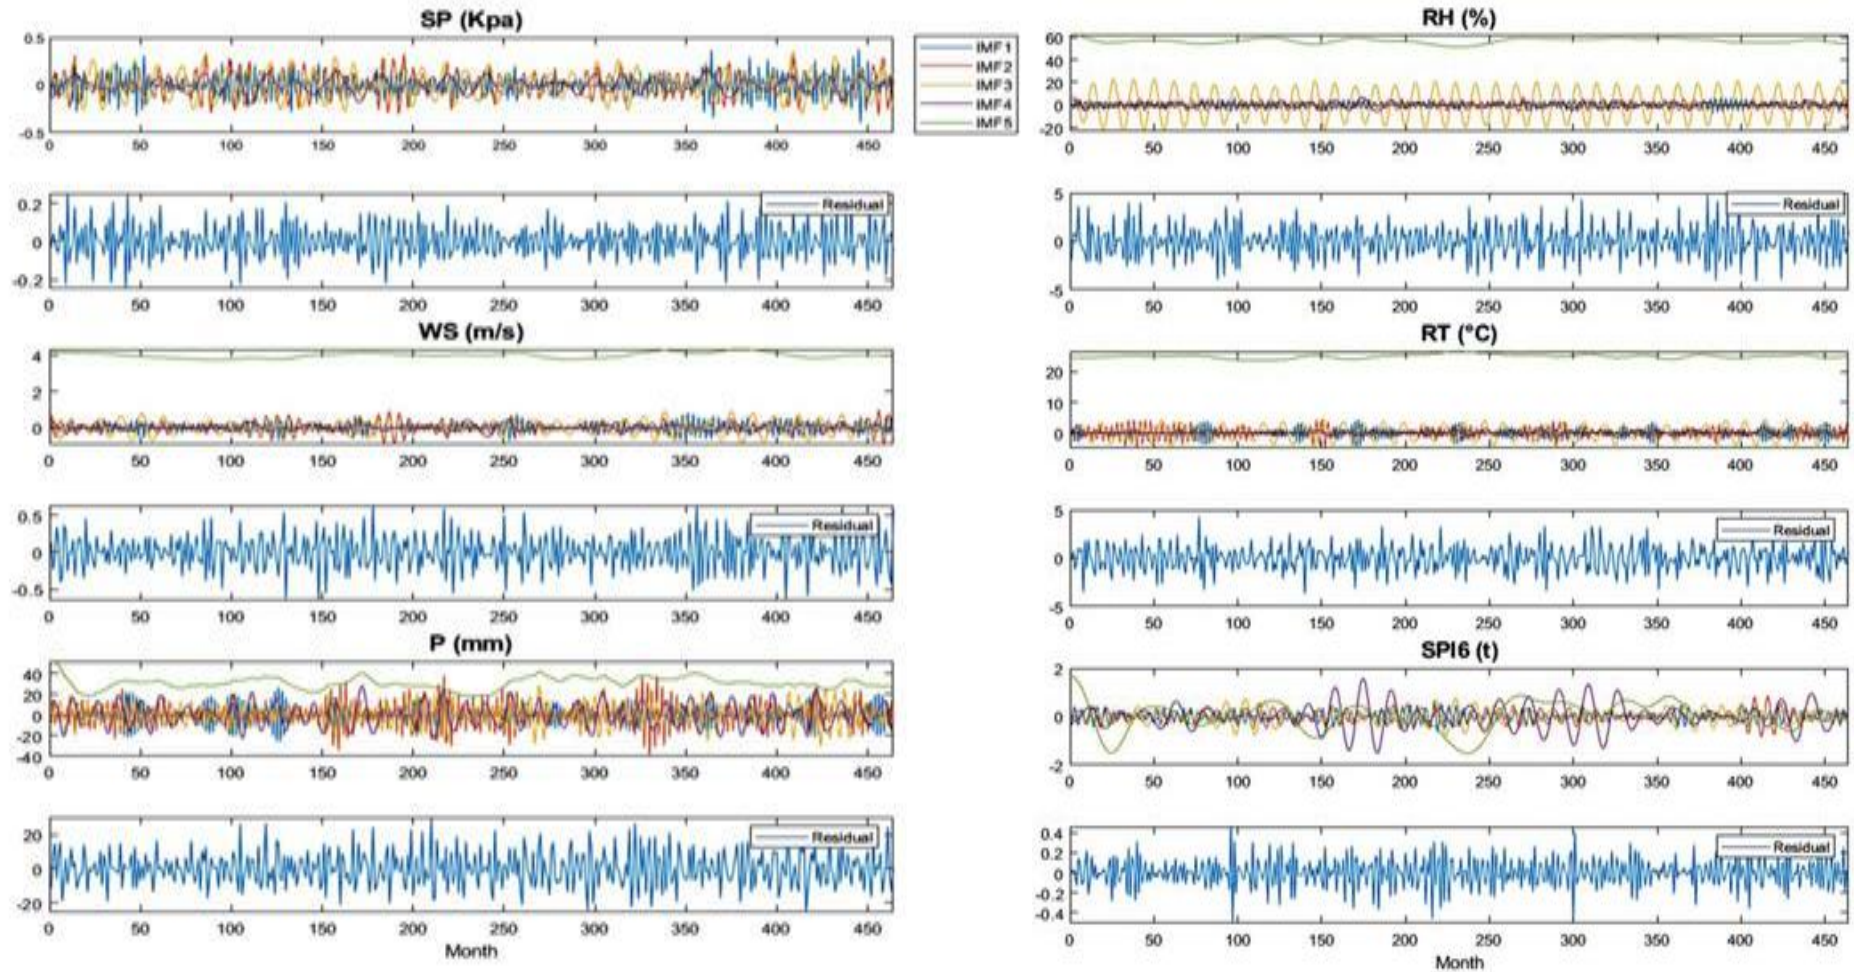


Figure 10. Décomposition de certaines variables d'entrée dans la station Ain Elhadjel avec VMD.

Le Tableau 4 présente la performance d'estimation de la phase des essais des approches ELM et VMD-ELM hybrides utilisées pour estimer les valeurs SPI selon divers critères statistiques. Selon ces critères, le modèle présentant l'erreur la plus faible et les valeurs R<sup>2</sup> les plus élevées a été choisi comme optimal. À la station Ain Elhadjel, le modèle VMD-ELM présente les meilleures performances de prévision pour les périodes de 6 mois et de 12 mois dans tous les pas de temps. De plus, les résultats de prédiction les plus précis ont été obtenus pour prédire les valeurs de l'SPI<sub>6(t+1)</sub> (R<sup>2</sup> : 0,745). Bien que des résultats de prédiction supérieurs soient généralement obtenus avec le modèle hybride VMD-ELM à la station Msaad, les résultats les plus précis ont été produits pour prédire les valeurs SPI<sub>12(t+1)</sub> (R<sup>2</sup> : 0,879) en utilisant le modèle ELM unique. À la station Bou Saada, des résultats de prédiction supérieurs ont été obtenus pour prédire les valeurs SPI<sub>12(t+1)</sub> (R<sup>2</sup> : 0,754) en utilisant le modèle VMD-ELM. Les résultats de prédiction optimale ont été trouvés à la station El-Kantara pour prédire les valeurs SPI<sub>12(t+1)</sub> en utilisant le modèle ELM unique. À la station M'sila, le succès de prédiction le plus élevé a été déterminé pour prédire les valeurs SPI<sub>6(t+1)</sub> (R<sup>2</sup> : 0,706) en utilisant le modèle hybride VMD-ELM. En utilisant le modèle hybride VMD-ELM, les résultats les plus réussis ont été obtenus à la station M'doukel pour prédire les valeurs SPI<sub>12(t+3)</sub> (R<sup>2</sup> : 0,809).

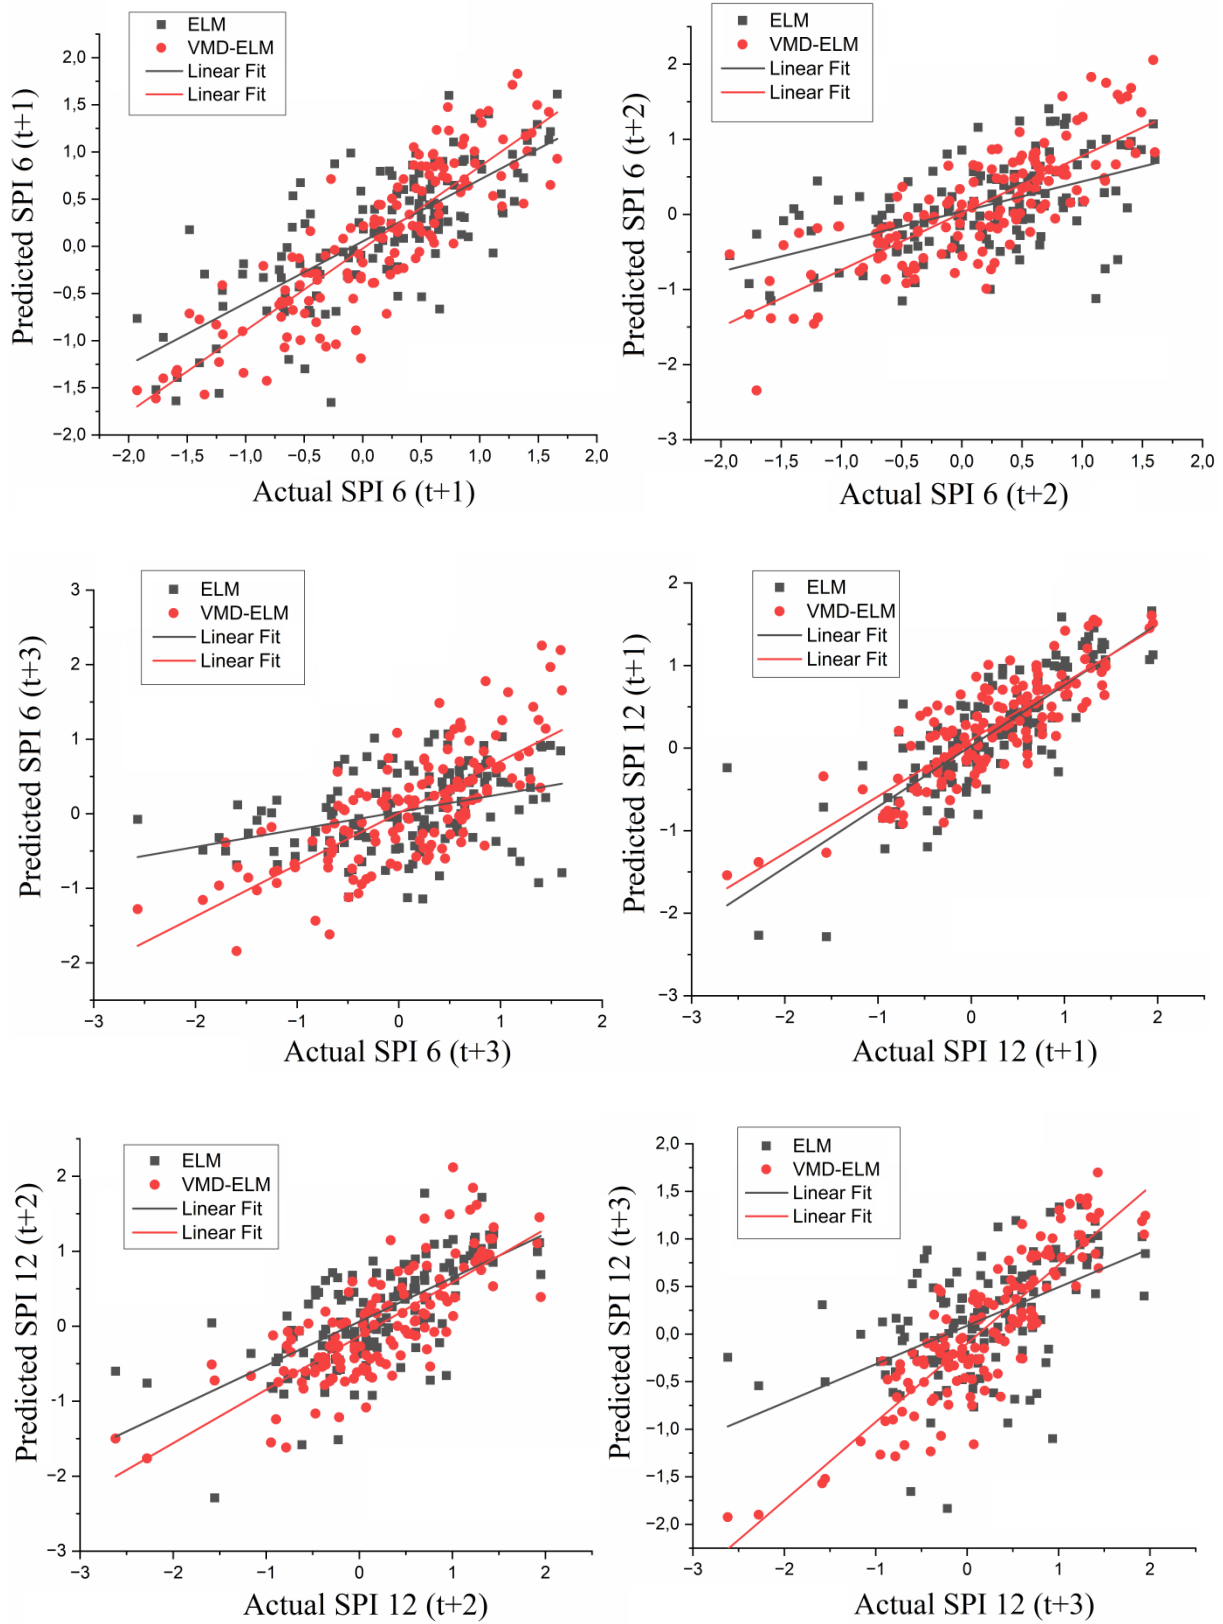
**Tableau 4.** Résultats des essais des modèles ELM

Metrics	ELM unique						VMD-ELM					
	MSE	MA	MAP	MBE	Bias	R <sup>2</sup>	MSE	MA	MAP	MBE	Bias	R <sup>2</sup>
Station Ain Elhadjel												
SPI <sub>6</sub> (t+1)*	0.27	0.404	6.601	0.008	7.487	0.56	0.17	0.339	2.528	-	-0.839	0.74
SPI <sub>6</sub> (t+2)	0.45	0.514	14.817	-	15.704	0.29	0.23	0.399	2.967	-	2.163	0.63
SPI <sub>6</sub> (t+3)	0.61	0.608	8.358	-	-8.639	0.13	0.32	0.481	2.318	-	3.071	0.53
SPI <sub>12</sub>	0.20	0.327	0.091	-	0.772	0.66	0.18	0.335	0.384	0.035	0.687	0.69
SPI <sub>12</sub> (t+2)	0.33	0.434	0.032	-	0.656	0.46	0.30	0.455	0.457	-	0.393	0.58
SPI <sub>12</sub> (t+3)	0.47	0.518	0.277	-	-0.106	0.27	0.16	0.325	0.718	-	0.296	0.75
Station Msaad												
SPI <sub>6</sub> (t+1)	0.19	0.345	-1.270	0.057	2.054	0.69	0.22	0.364	-1.119	0.010	1.617	0.67
SPI <sub>6</sub> (t+2)*	0.33	0.452	-1.020	0.089	1.084	0.45	0.14	0.307	-0.264	-	1.143	0.76
SPI <sub>6</sub> (t+3)	0.52	0.566	-1.101	0.195	-0.379	0.21	0.25	0.413	-0.494	-	1.229	0.63
SPI <sub>12</sub>	0.09	0.226	-8.277	0.034	8.903	0.87	0.21	0.366	-1.038	-	-0.022	0.72
SPI <sub>12</sub> (t+2)	0.22	0.373	-7.682	0.109	8.449	0.71	0.22	0.363	-1.436	-	2.114	0.71
SPI <sub>12</sub> (t+3)	0.31	0.432	-5.093	0.151	5.686	0.60	0.17	0.326	-1.913	-	-0.500	0.78
Station Bou Saada												

## Chapitre 4. Prédiction de la Sècheresse par les techniques de L'IA

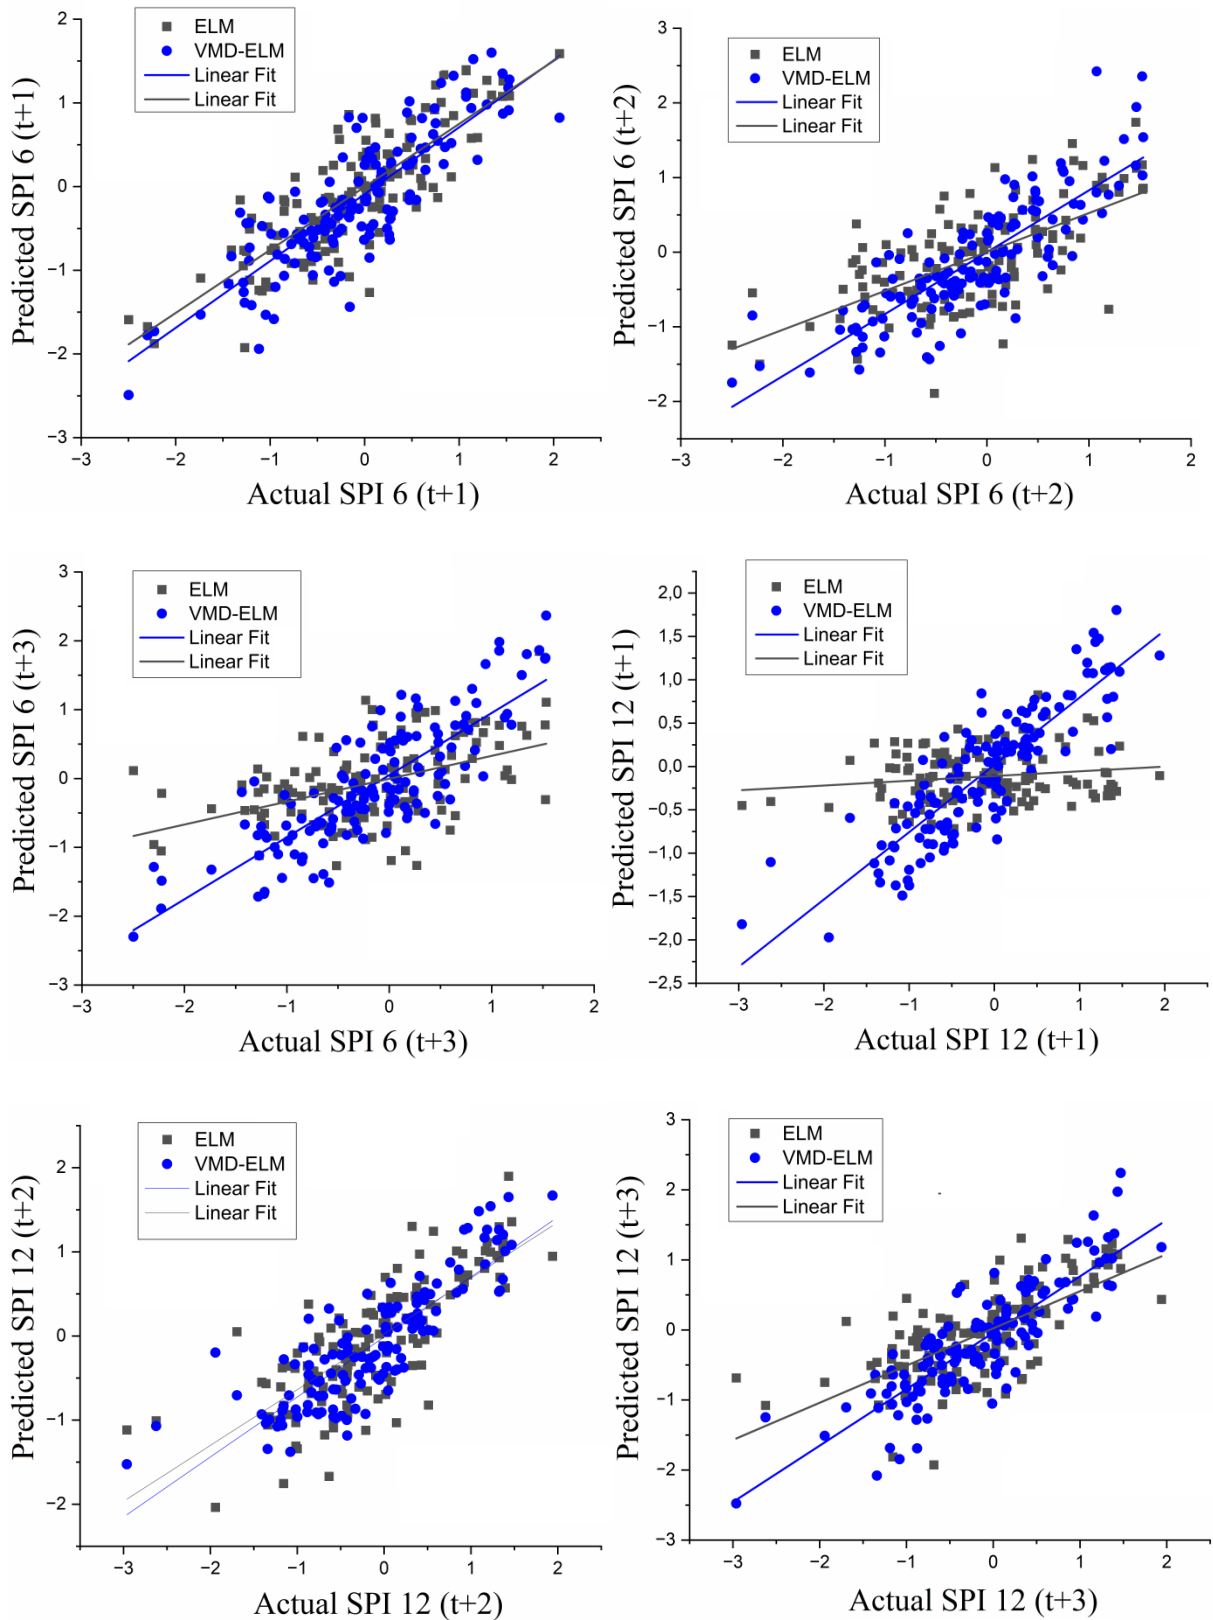
SPI6 (t+1)*	0.20	0.357	0.231	0.024	0.702	0.70	0.20	0.348	-5.839	-	-4.097	0.71
SPI6 (t+2)	0.39	0.508	-2.266	0.067	-1.277	0.41	0.20	0.361	-4.819	0.022	-3.386	0.69
SPI6 (t+3)	0.54	0.583	-8.607	0.103	-8.352	0.22	0.25	0.405	-7.572	0.066	9.747	0.68
SPI12 (t+1)	0.69	0.654	0.474	0.014	-0.377	0.02	0.17	0.318	0.265	0.048	0.747	0.75
SPI12	0.28	0.412	0.574	0.074	0.720	0.60	0.19	0.327	-0.021	0.029	1.256	0.72
SPI12 (t+3)	0.37	0.465	0.658	0.099	0.943	0.47	0.18	0.339	0.357	-	1.169	0.73
Station El Kantara												
SPI6 (t+1)*	0.24	0.386	1.284	-	0.835	0.66	0.22	0.383	1.501	-	-0.124	0.72
SPI6 (t+2)	0.41	0.508	0.892	-	-0.172	0.40	0.24	0.396	0.940	-	0.529	0.66
SPI6 (t+3)	0.59	0.618	1.237	-	-0.374	0.18	0.35	0.476	1.362	-	1.008	0.53
SPI12	0.14	0.287	-6.504	-	-5.460	0.76	0.21	0.359	-1.528	-	-0.627	0.74
SPI12 (t+2)	0.30	0.402	-3.364	-	-2.981	0.54	0.22	0.387	-7.301	-	-6.943	0.65
SPI12 (t+3)	0.41	0.500	-5.291	-	-5.288	0.39	0.16	0.312	-1.396	-	-0.604	0.76
Station M'sila												
SPI6 (t+1)*	0.26	0.397	0.961	0.003	3.190	0.56	0.18	0.333	-0.595	-	1.890	0.70
SPI6 (t+2)	0.47	0.538	2.898	-	-2.427	0.26	0.23	0.402	-1.741	-	-0.273	0.62
SPI6 (t+3)	0.57	0.620	0.185	-	0.827	0.12	0.30	0.430	-1.260	0.016	4.277	0.52
SPI12 (t+1)	0.21	0.357	1.206	-	0.054	0.62	0.23	0.391	1.860	-	1.663	0.64
SPI12 (t+2)	0.33	0.436	2.220	-	1.413	0.39	0.23	0.398	1.363	-	0.445	0.60
SPI12	0.45	0.521	1.140	-	0.043	0.24	0.18	0.348	1.457	-	1.101	0.69
Station M'doukel												
SPI6 (t+1)*	0.26	0.399	-0.080	-	0.561	0.66	0.21	0.353	0.013	-	0.395	0.73
SPI6 (t+2)	0.40	0.503	0.245	-	0.646	0.46	0.24	0.409	-0.066	-	0.678	0.67
SPI6 (t+3)	0.55	0.596	0.064	-	0.144	0.27	0.35	0.466	0.219	0.004	0.791	0.54
SPI12 (t+1)	0.14	0.274	2.626	-	2.453	0.79	0.14	0.307	3.744	-	3.044	0.81
SPI12 (t+2)	0.27	0.416	1.433	0.009	1.583	0.59	0.17	0.339	3.417	-	1.794	0.77
SPI12	0.32	0.455	0.892	-	1.449	0.52	0.13	0.295	2.532	-	1.724	0.80

Le symbole \* représente l'échelle de temps et le délai avec la plus grande précision de prévision pour la sécheresse.



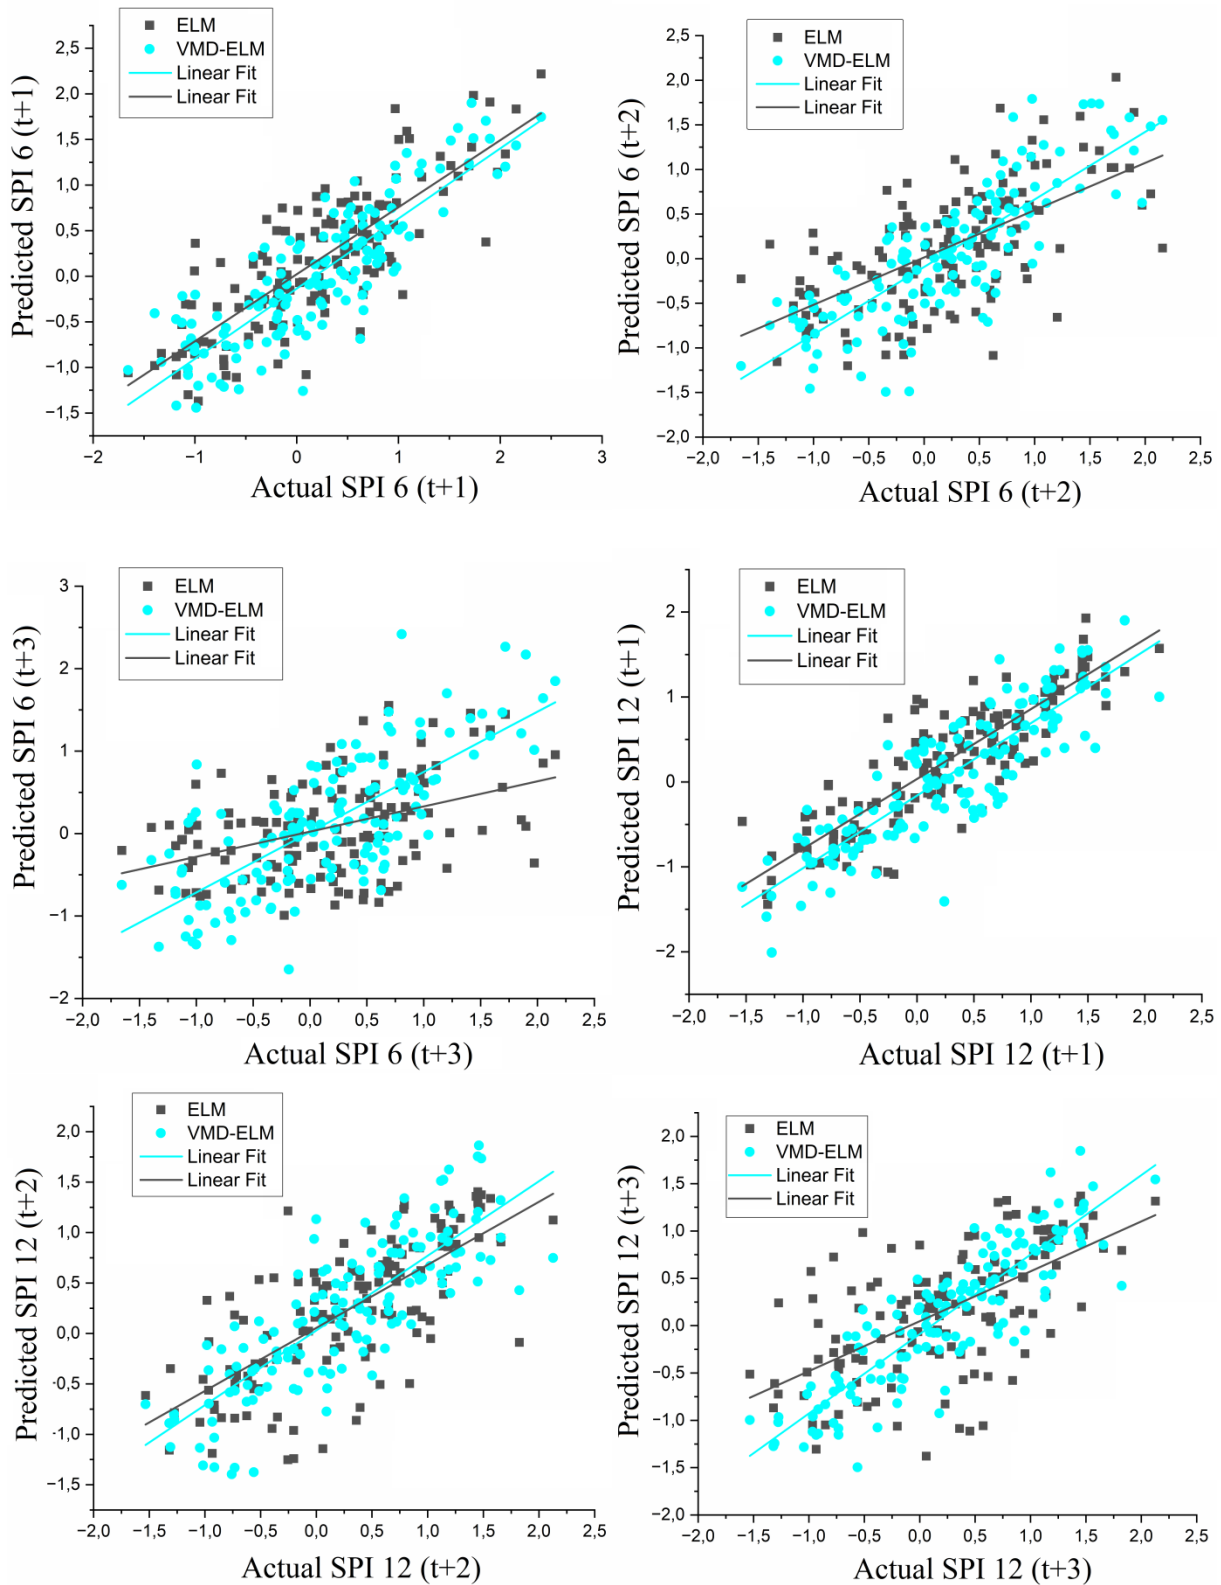
**Figure 11.** Comparaison de l'SPI prévue et mesurée à l'aide des modèles ELM et VMD-ELM pour la station Ain Elhadjel.

Une comparaison de l'SPI pr edite et mesur ee  a l'aide de mod eles ELM simples et hybrides VMD-ELM sur des  echelles de temps de 6 et 12 mois est pr esent ee  a la Figure 11 pour la station Ain Elhadjel. Selon les r esultats, la pr ecision du mod ele VMD-ELM dans la pr ediction des valeurs SPI est  elev ee en raison de la proximit e de ses lignes ajust ees avec la ligne 1:1 et des valeurs  elev ees du coefficient de d etermination. Ce mod ele a notamment d emontr e de meilleurs r esultats sur une  echelle de 6 mois. Mais la pr ecision du mod ele ELM n'est pas bonne, sauf pour  $SPI_{12(t+1)}$ , en raison de la dispersion des points et de la distance de la ligne ajust ee par rapport  a la ligne 1:1.



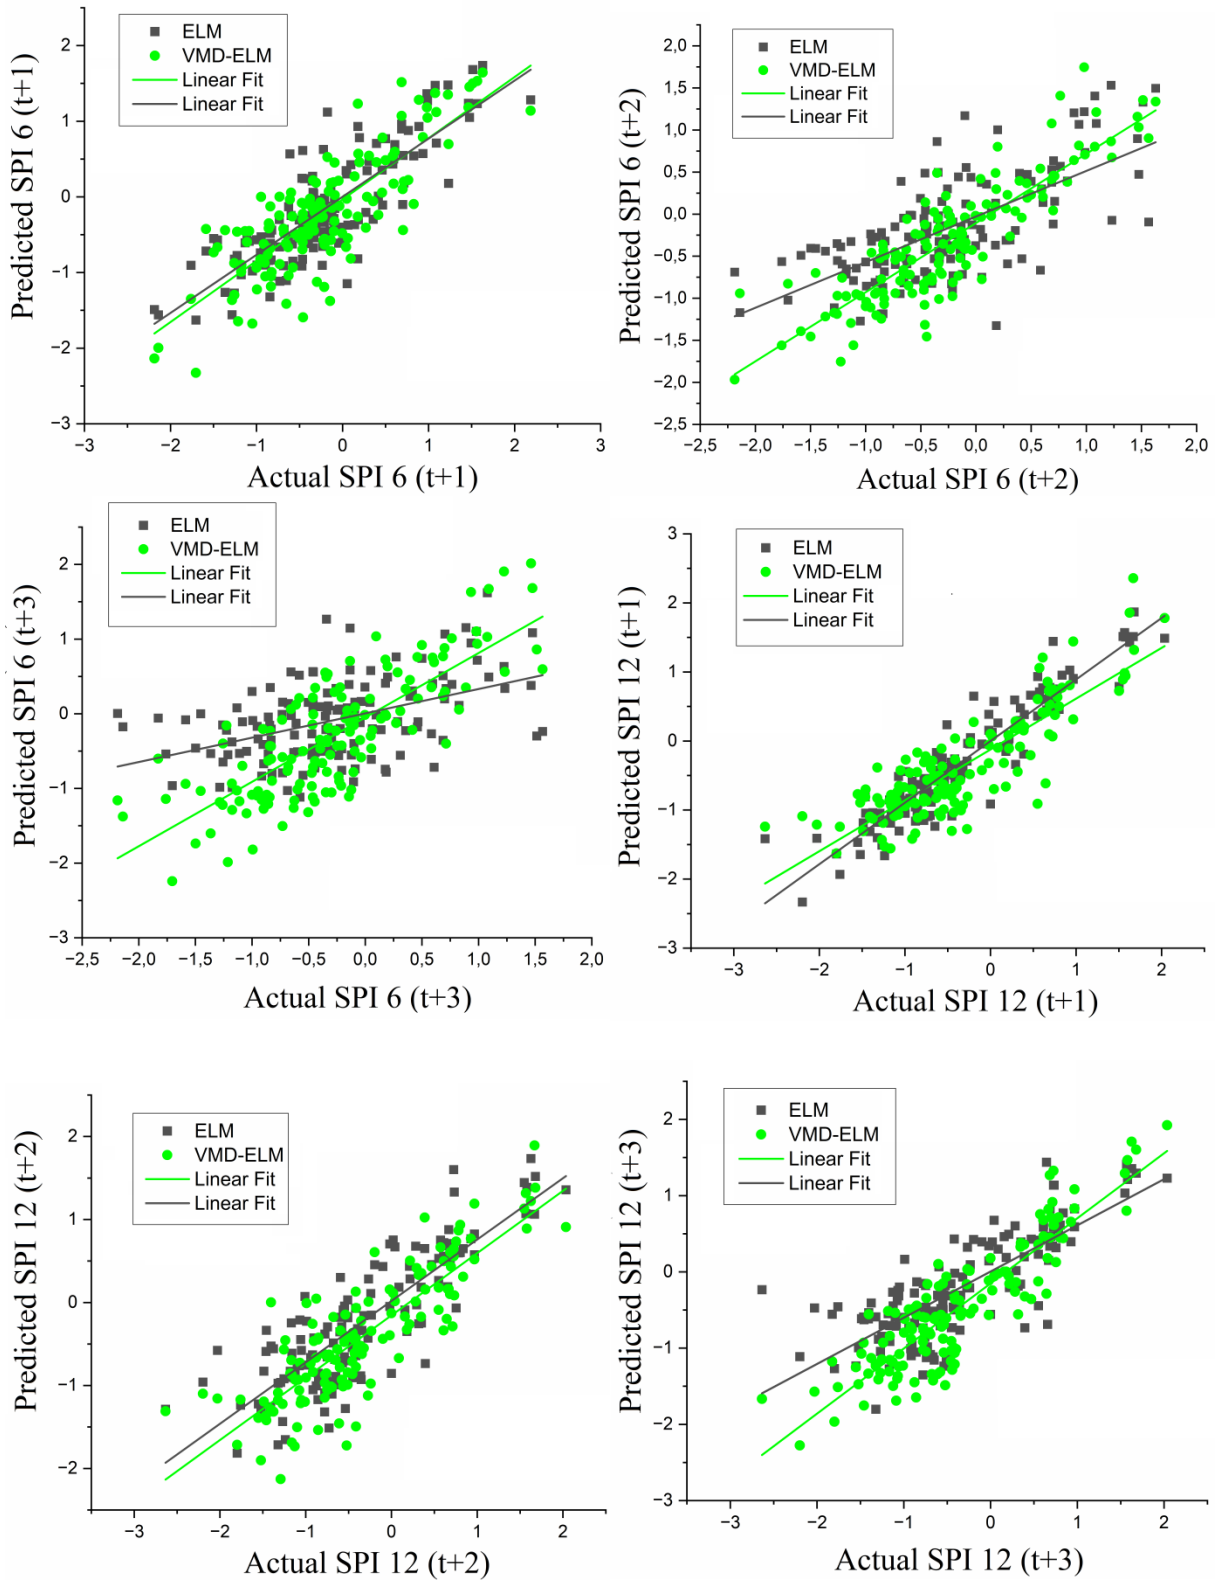
**Figure 12.** Comparaison du SPI prévue et mesuré à l'aide des modèles ELM et VMD-ELM pour la station Bou Saada.

Selon les r esultats de l'efficacit e des mod eles ELM et VMD-ELM dans la pr ediction de SPI pour la station Bou Saada repr esent ee sur la figure 12, la pr ecision du mod ele VMD-ELM est  lev ee en raison de la proximit e de ses lignes ajust ees avec la ligne 1:1 et des valeurs  lev ees du coefficient de d etermination. Contrairement   la station Ain Elhadjel, ce mod ele hybride avait une grande pr ecision de pr ediction dans presque toutes les  chelles de temps de cette station.   l'exception de  $SPI_{6(t+1)}$  et  $SPI_{12(t+2)}$ , dans lesquels la pr ecision du mod ele ELM  tait  lev ee en raison de la proximit e de la ligne ajust ee avec la ligne 1:1 et du manque de diffusion des points, il n'a pas  t  possible de pr edire les autres.



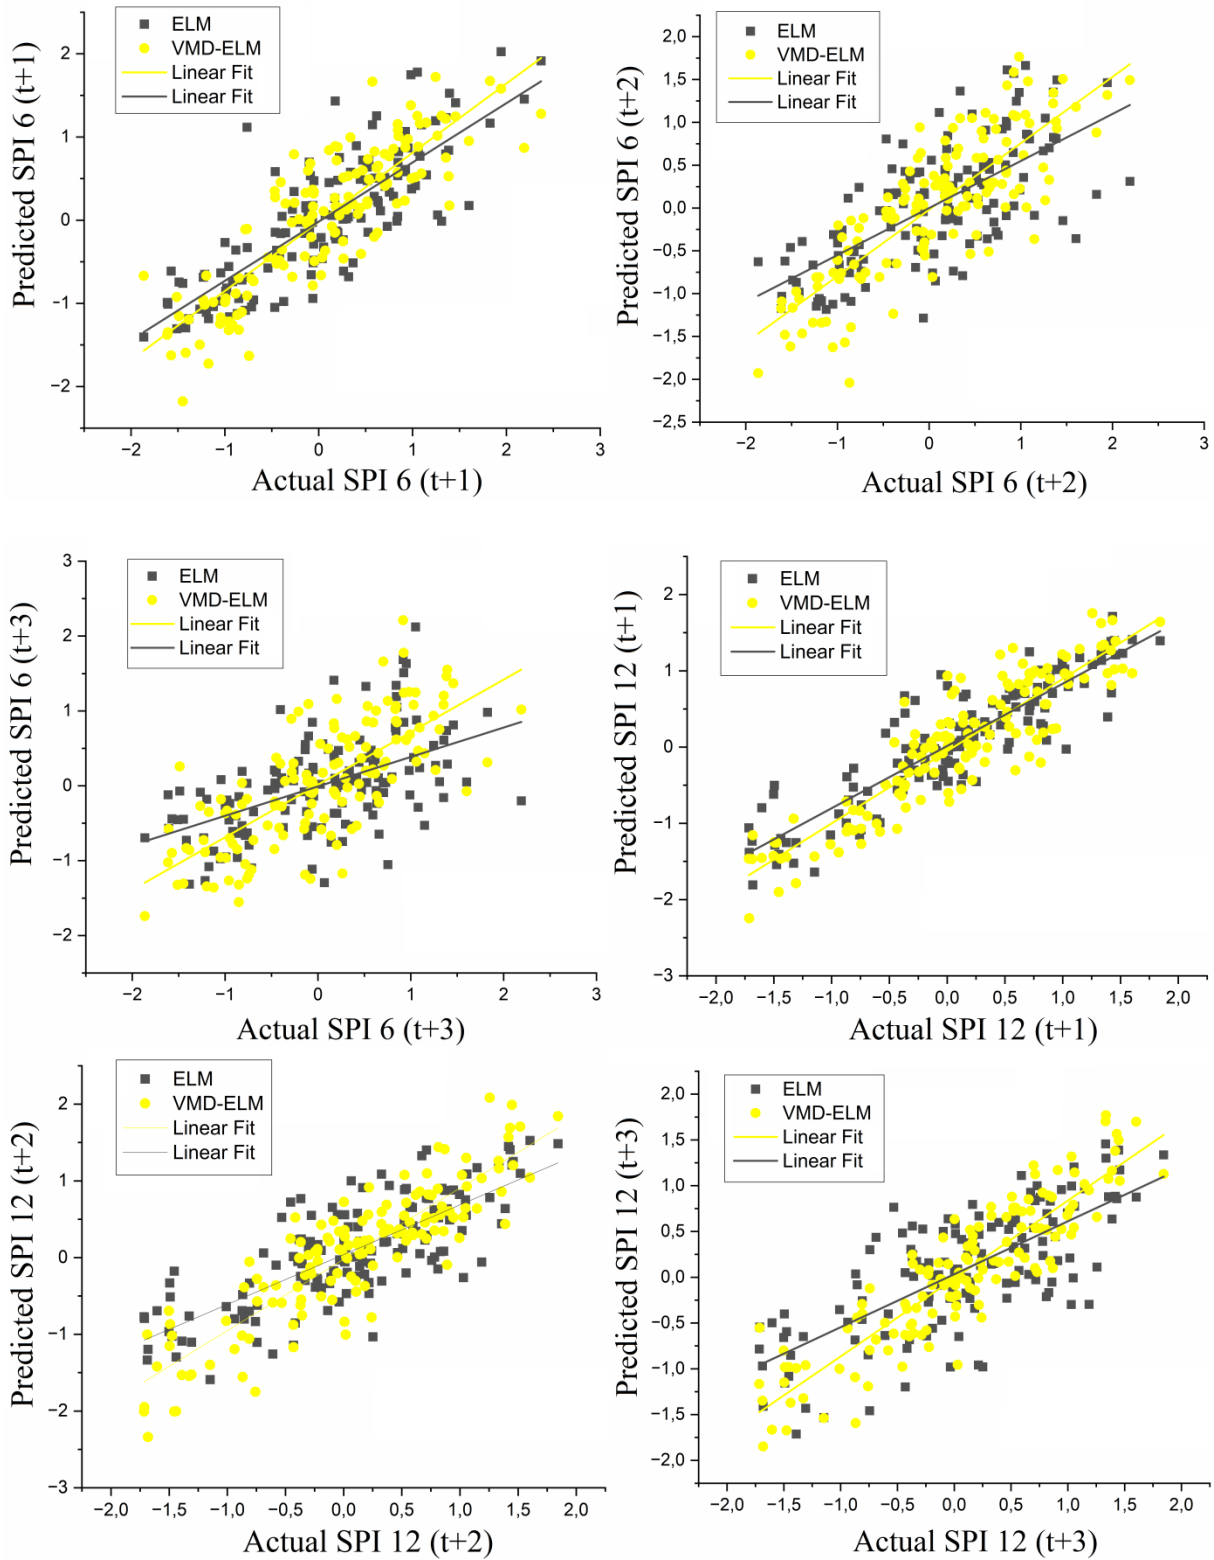
**Figure 13.** Comparaison de l'SPI prévue et mesurée à l'aide des modèles ELM et VMD-ELM pour la station El Kantara.

La Figure 13 compare les SPI pr edits par les mod eles ELM simples et hybrides VMD-ELM pour la station El Kantara sur 6 et 12 mois. Les r esultats r ev elent que le mod ele VMD-ELM est tr es pr ecis pour pr edire les valeurs SPI dans la plupart des cas. Ce mod ele fonctionne particuli erement bien sur  $SPI_{6(t+1)}$ . Cependant, la pr ecision du mod ele ELM est faible, sauf pour  $SPI_{6(t+1)}$ , en raison de la dispersion des points et de la distance de la ligne ajust ee de la ligne 1:1.



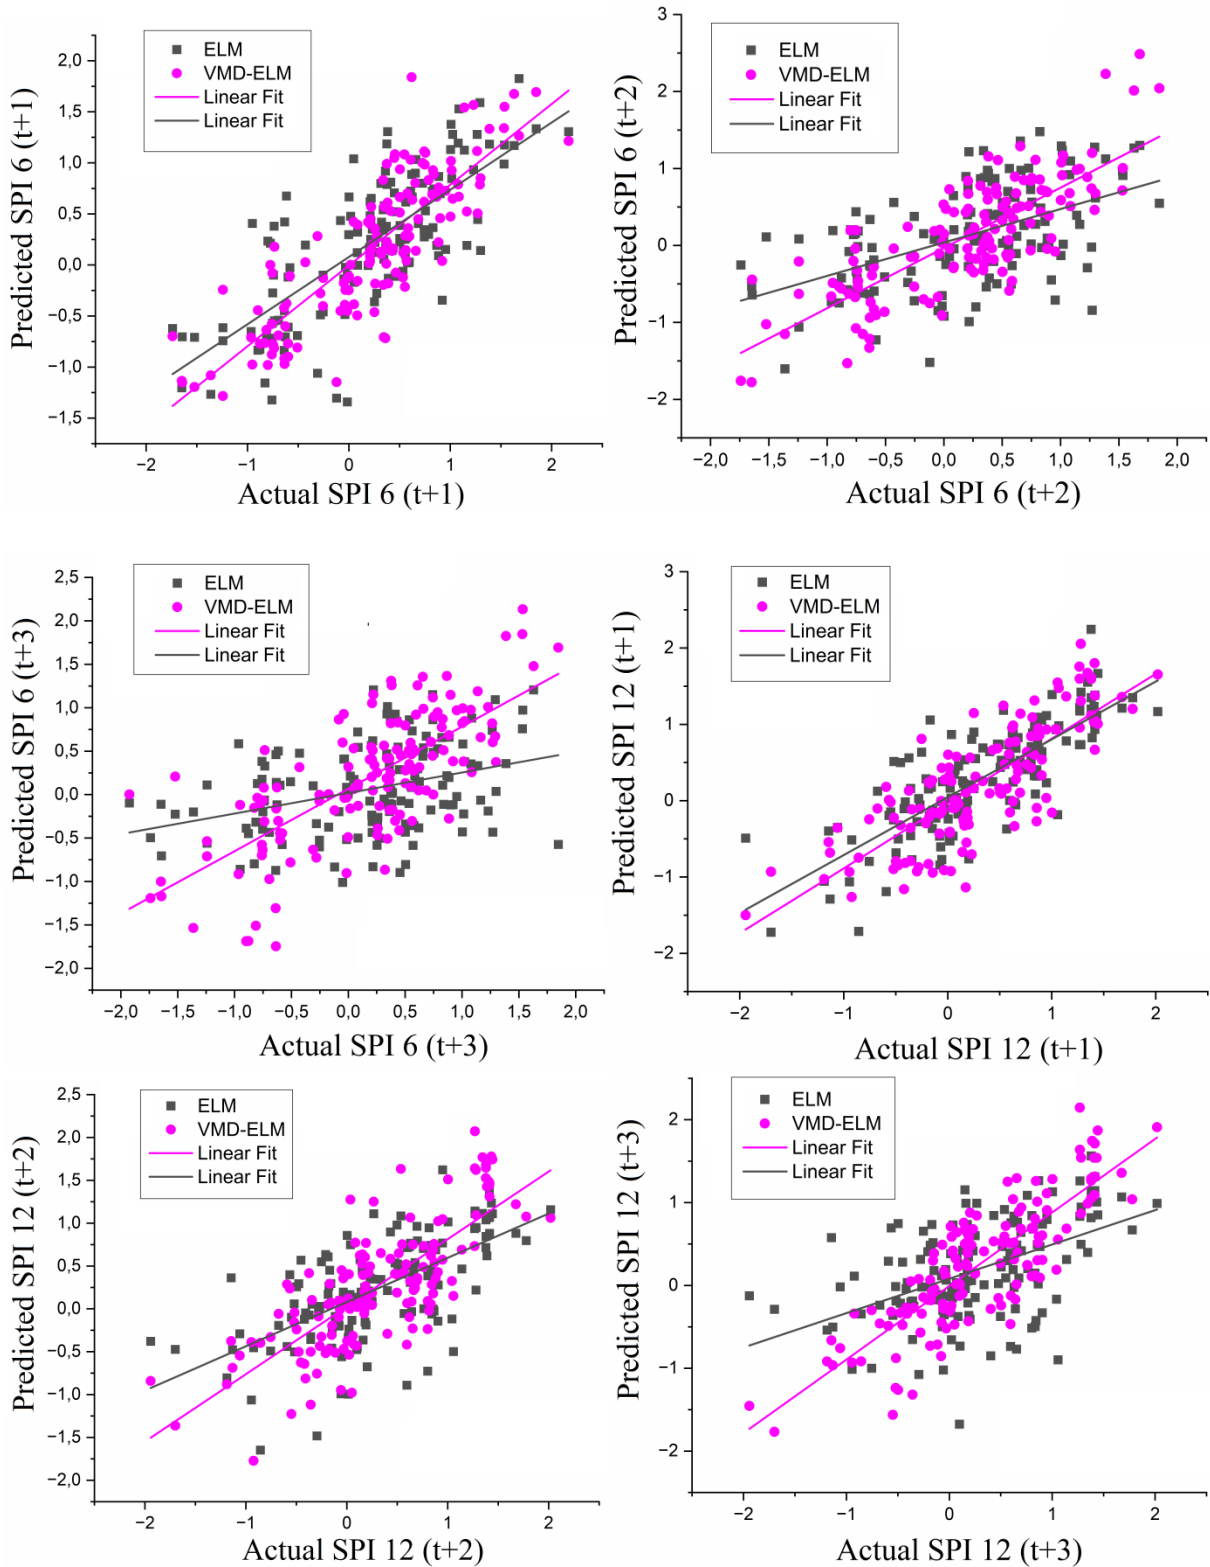
**Figure 14.** Comparaison de l'SPI prévue et mesurée à l'aide des modèles ELM et VMD-ELM pour la station Msaad.

D'apr es les r esultats des mod eles ELM et VMD-ELM utilis es pour pr edire le SPI pour la station Msaad, comme le montre la Figure 14, il semble que la pr ecision du mod ele VMD-ELM soit faible. La raison est que les lignes ajust ees sont significativement  eloign ees de la ligne 1:1 et que les coefficients de d etermination sont faibles. N eanmoins, le mod ele hybride a montr e une pr ecision de pr ediction  elev ee pour  $SPI_{6(t+1)}$  et  $SPI_{12(t+3)}$  dans cette station. Dans le cas de  $SPI_{12(t+1)}$ , le mod ele ELM a r eussi car la ligne ajust ee correspondait  etroitement au manque de points dispers es. Cependant, le mod ele  etait inefficace pour pr edire d'autres cas.



**Figure 15.** Comparaison de l'SPI prévue et mesurée à l'aide des modèles ELM et VMD-ELM pour la station M'doukel

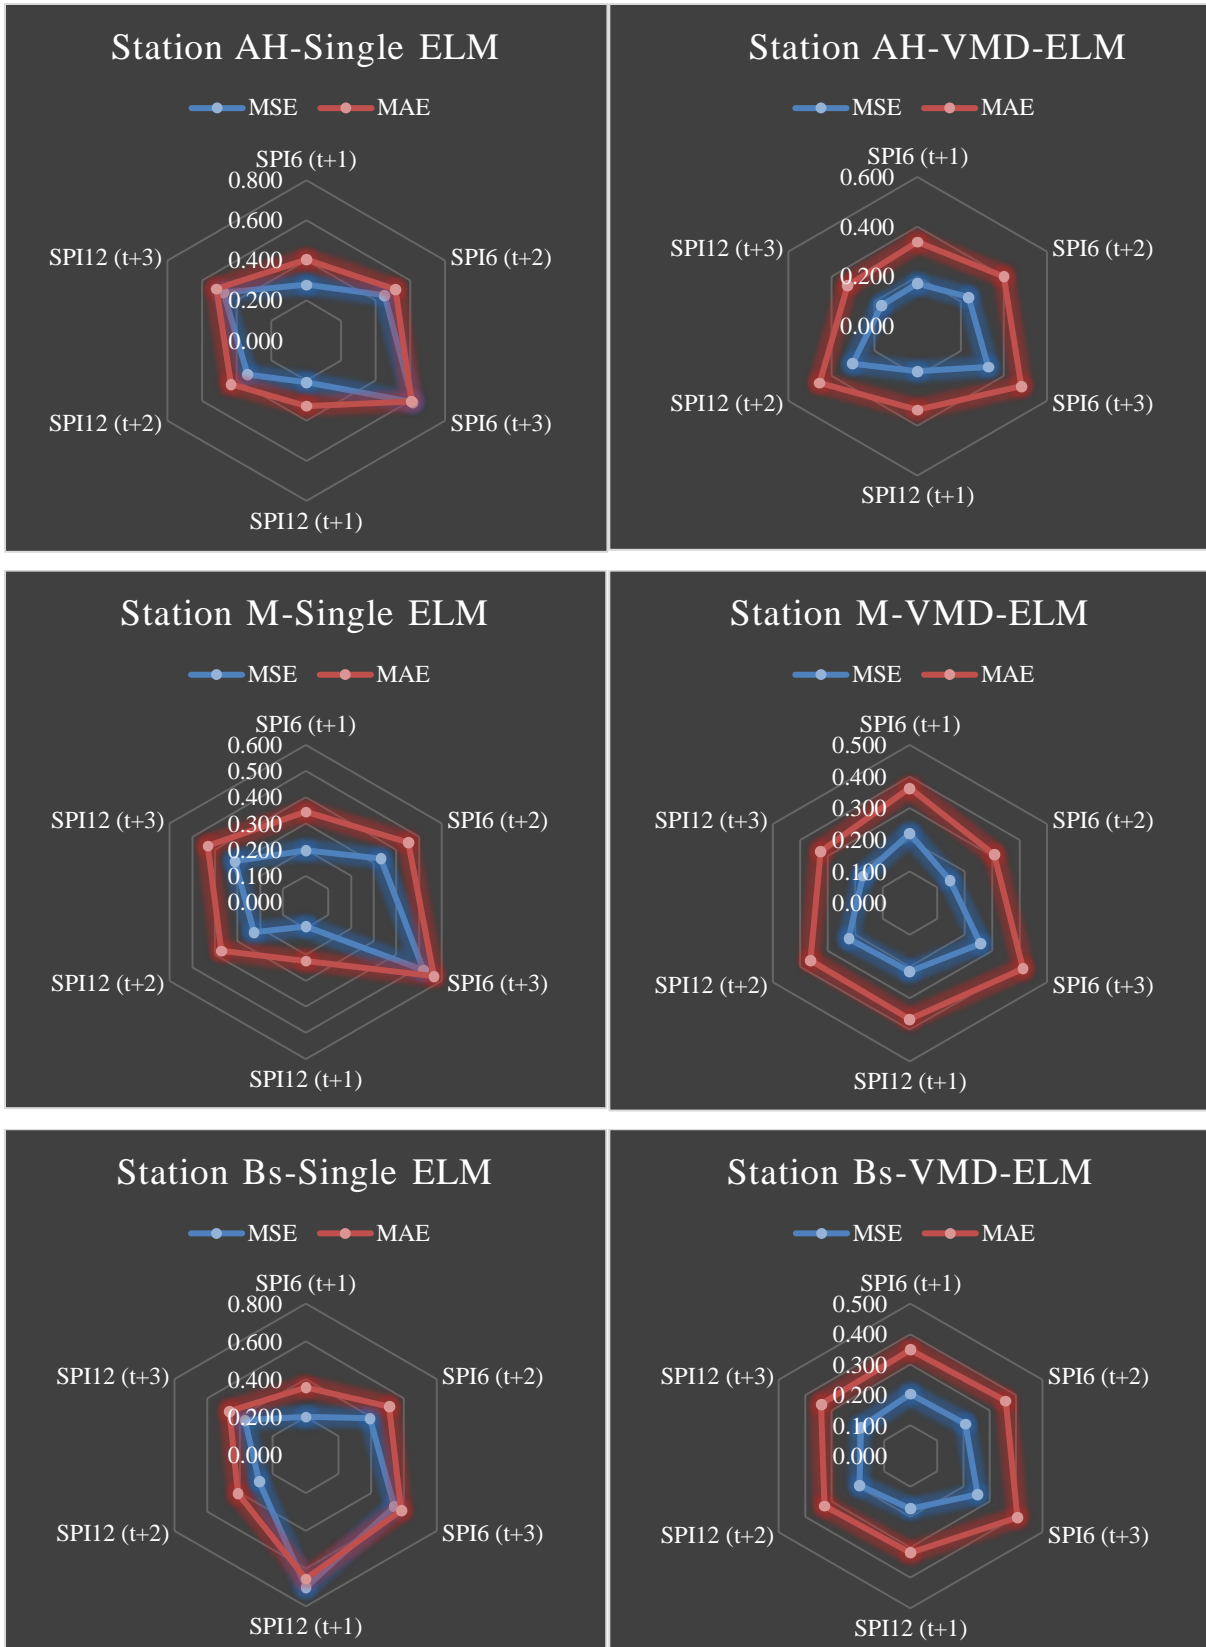
Pour la station M'doukel, la Figure 15 fournit une repr esentation visuelle des valeurs SPI pr edites par les mod eles ELM simple et hybride VMD-ELM. Il est int eressant de noter que cette comparaison est pr esent ee pour les  echelles de temps de 6 et 12 mois. Il est  evident  a partir de la distance de ses lignes ajust ees de la ligne 1:1 et de la dispersion  elev ee des points que le mod ele VMD-ELM a une faible pr ecision dans la pr evision des valeurs SPI, selon les r esultats. Les r esultats obtenus par ce mod ele  etaient uniquement satisfaisants pour l'SPI<sub>12(t+3)</sub>. En raison de la dispersion des points et de la distance consid erable de la ligne ajust ee par rapport  a la ligne 1:1, la pr ecision du mod ele ELM est insatisfaisante sur toutes les  echelles de temps.



**Figure 16.** Comparaison de l'SPI prévue et mesurée à l'aide des modèles ELM et VMD-ELM pour la station M'sila.

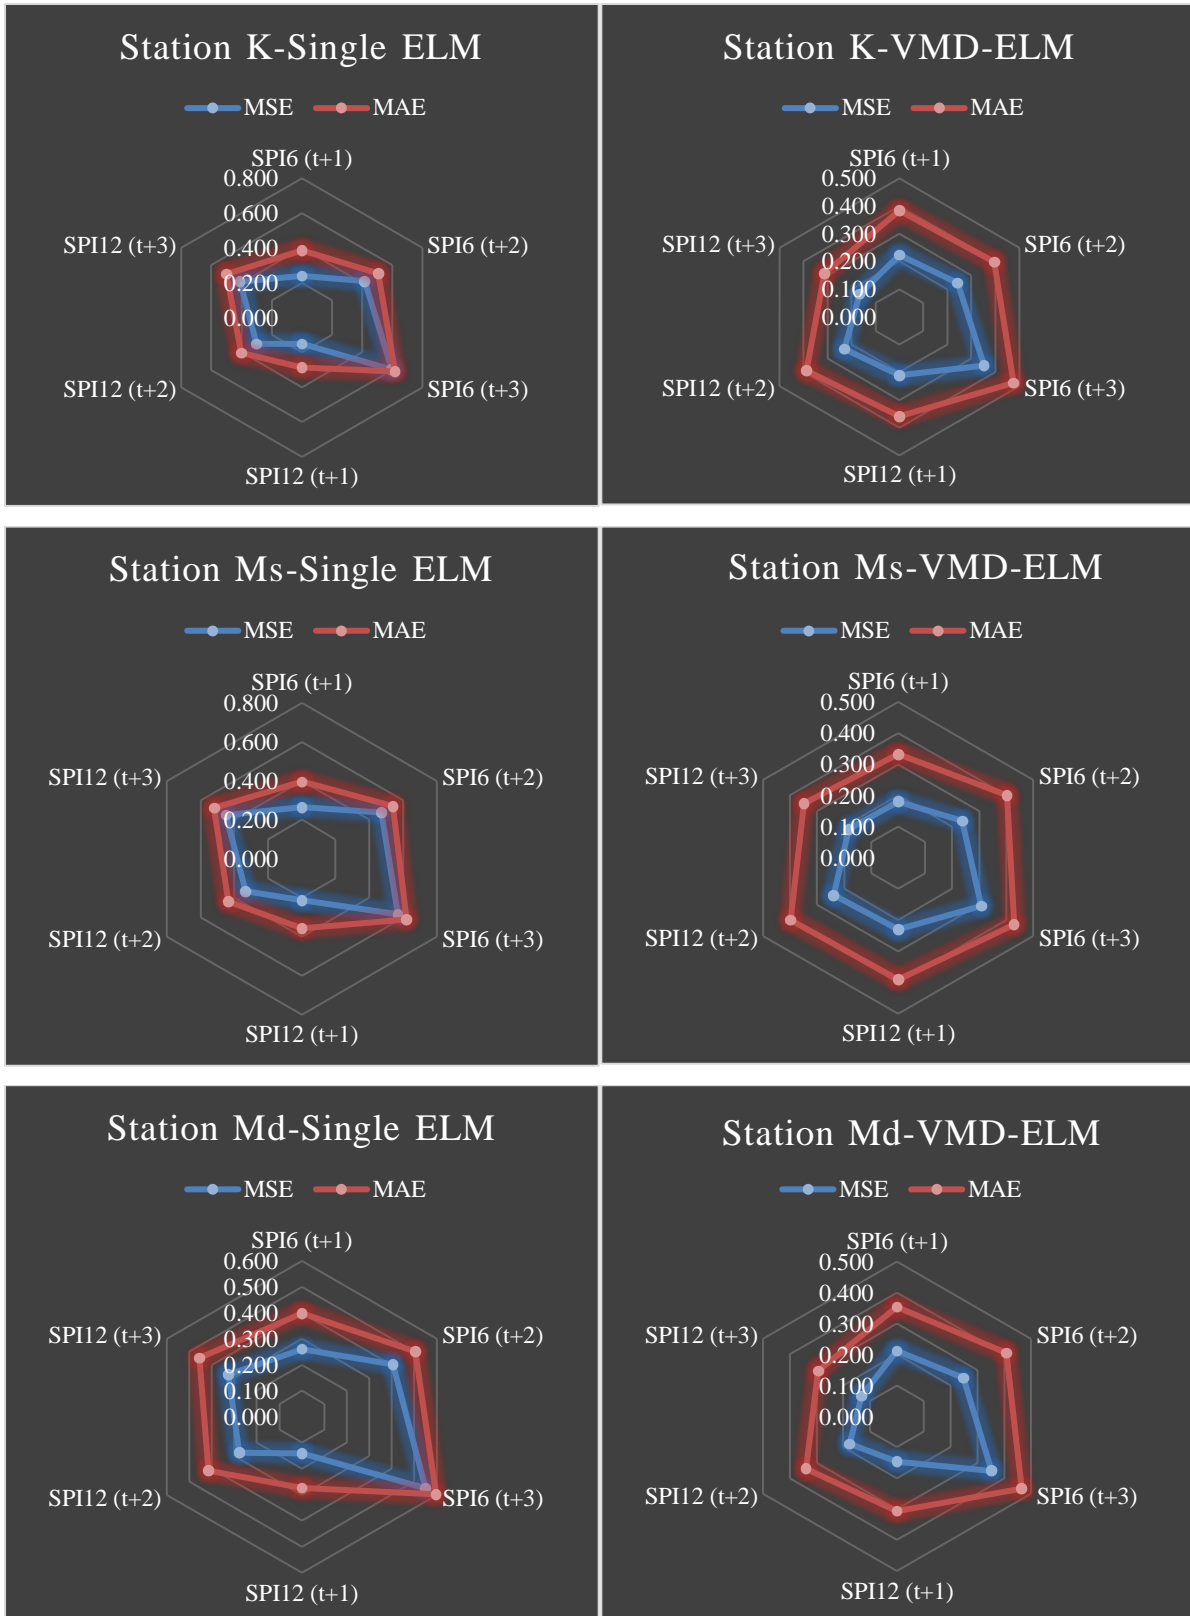
La Figure 16 compare le SPI prédit par les modèles ELM simple et hybride VMD-ELM pour la station M'sila sur 6 et 12 mois. Les resultants indiquent que le modèle VMD-ELM est exact dans la prévision des valeurs SPI uniquement pour l'échelle de 12 mois. Cependant, son efficacité dans l'échelle à 6 mois, ainsi que la précision du modèle ELM dans tous les cas, est considérablement faible.

La figure 17 illustre les cartes polaires d'entraînement et de test des écarts d'estimation pour les valeurs  $SPI_6$  et  $SPI_{12}$ , prévoyant 1, 2 et 3 mois pour les stations Ain Elhadjel, Msaad et Bou -Saada. Le modèle avec la moindre valeur d'erreur a été choisi car il affichait les résultats les plus précis. Le modèle hybride VMD-ELM a démontré la plus grande précision prédictive dans toutes les stations dans cette direction. De plus, les stations Ain Elhadjel, Msaad et Bou -Saada.ont montré les résultats prévisionnels les plus précis pour les prévisions de sécheresse de  $SPI_{12(t+1)}$ ,  $SPI_{12(t+1)}$  et  $SPI_{6(t+1)}$ , respectivement.



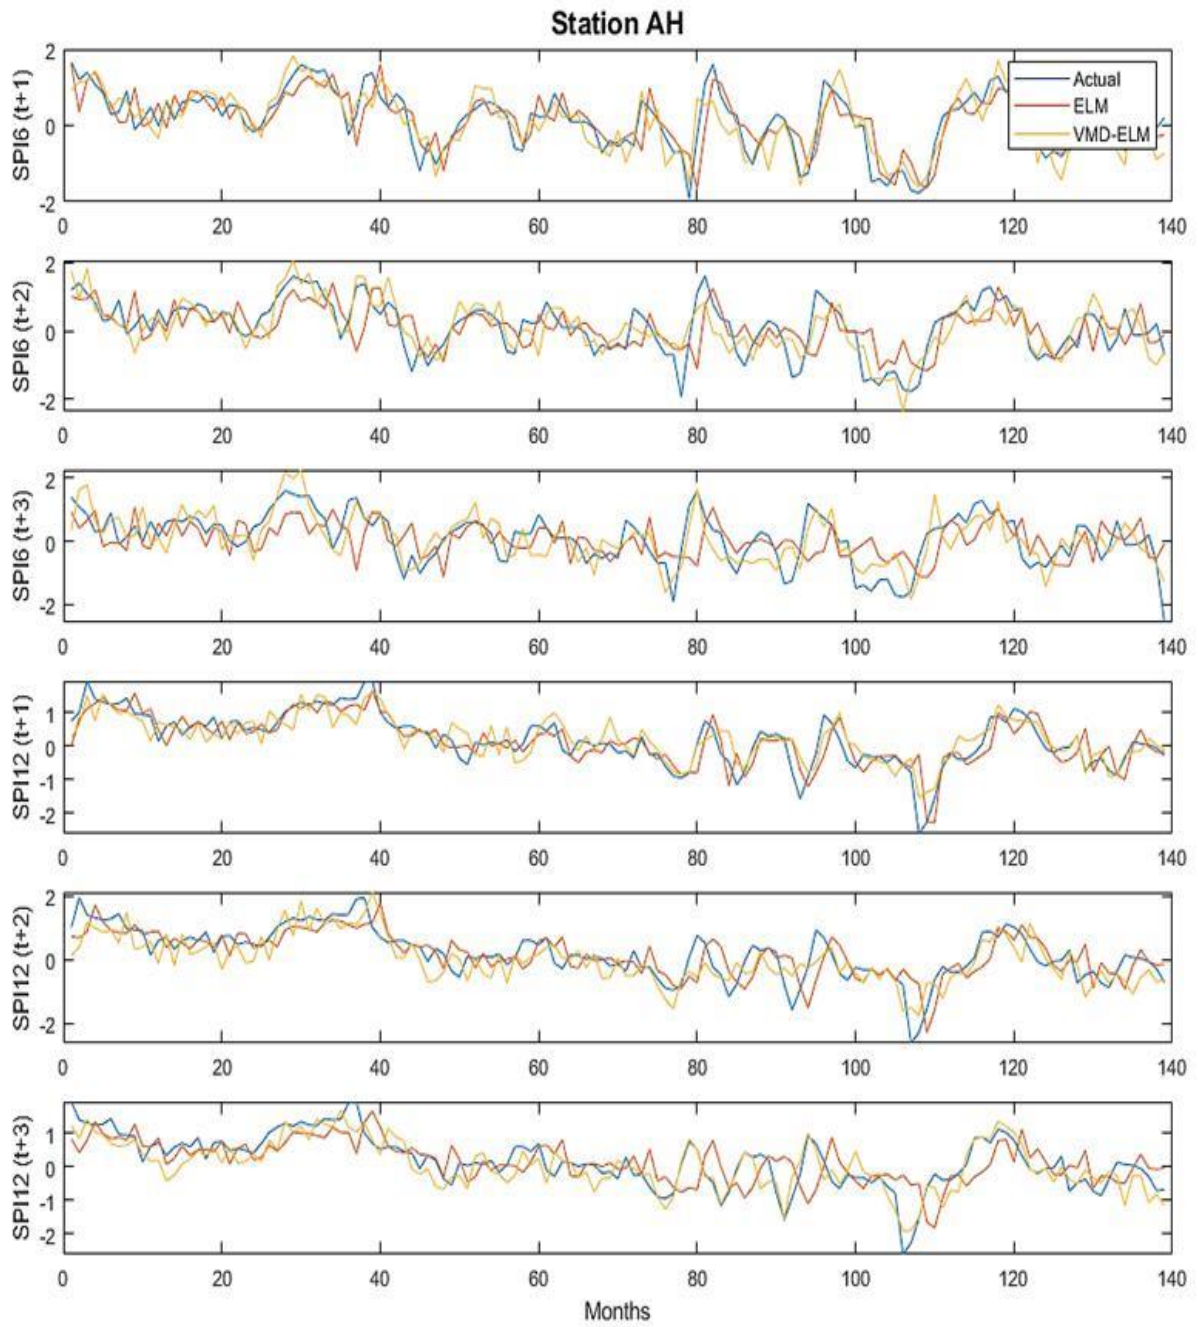
**Figure 17.** Graphiques polaires de l'estimation de l'SPI des stations Ain Elhadjel, Msaad et Bou Saada.

La Figure 18 montre la formation et l'essai de trac s polaires d'erreurs d'estimation de 1, 2 et 3 mois   l'avance pour les valeurs  $SPI_6$  et  $SPI_{12}$  des stations Ain Elhadjel, Msaad et Bou Saada. En cons quence, le mod le avec la plus faible valeur d'erreur a  t  choisi comme optimum. Dans cette direction, le mod le hybride VMD-ELM montre g n ralement les r sultats les plus pr cis   toutes les stations. En outre, les r sultats d'estimation les plus pr cis des stations El-Kantara, M'sila et Bou Saada ont  t  obtenus dans les pr visions de s cheresse  $SPI_{12(t+1)}$ ,  $SPI_{6(t+1)}$  et  $SPI_{12(t+3)}$ , respectivement.

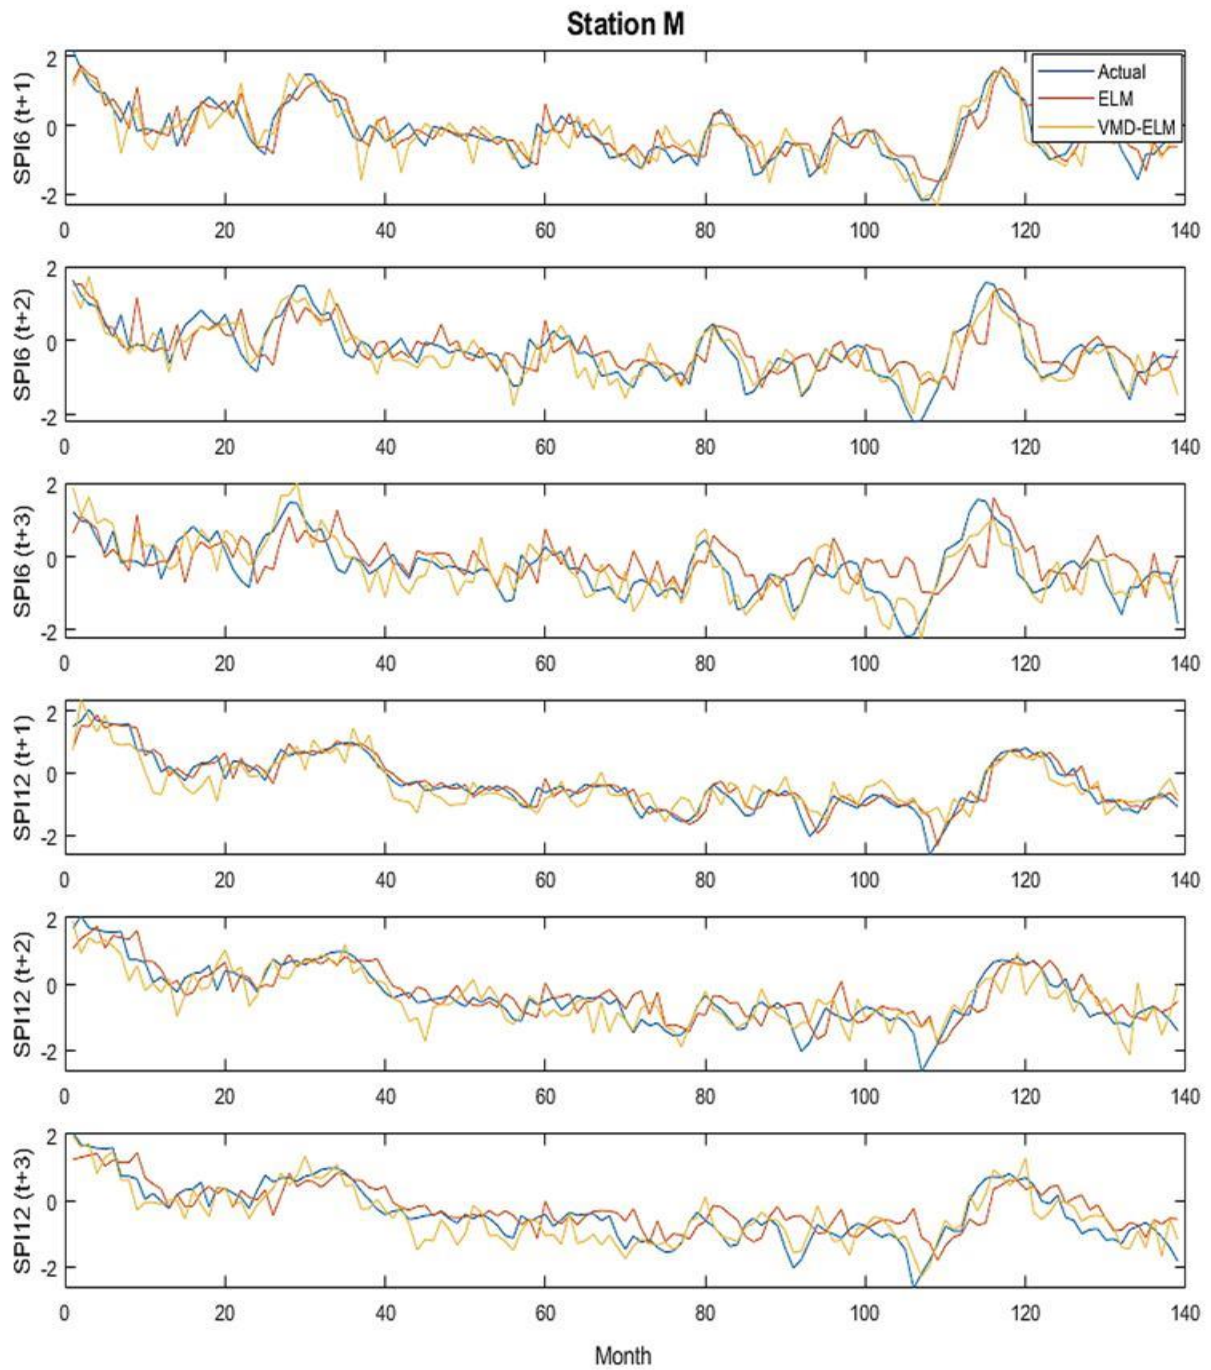


**Figure 18.** Graphiques polaires de l'estimation SPI des stations El Kantara, M'sila et M'doukel.

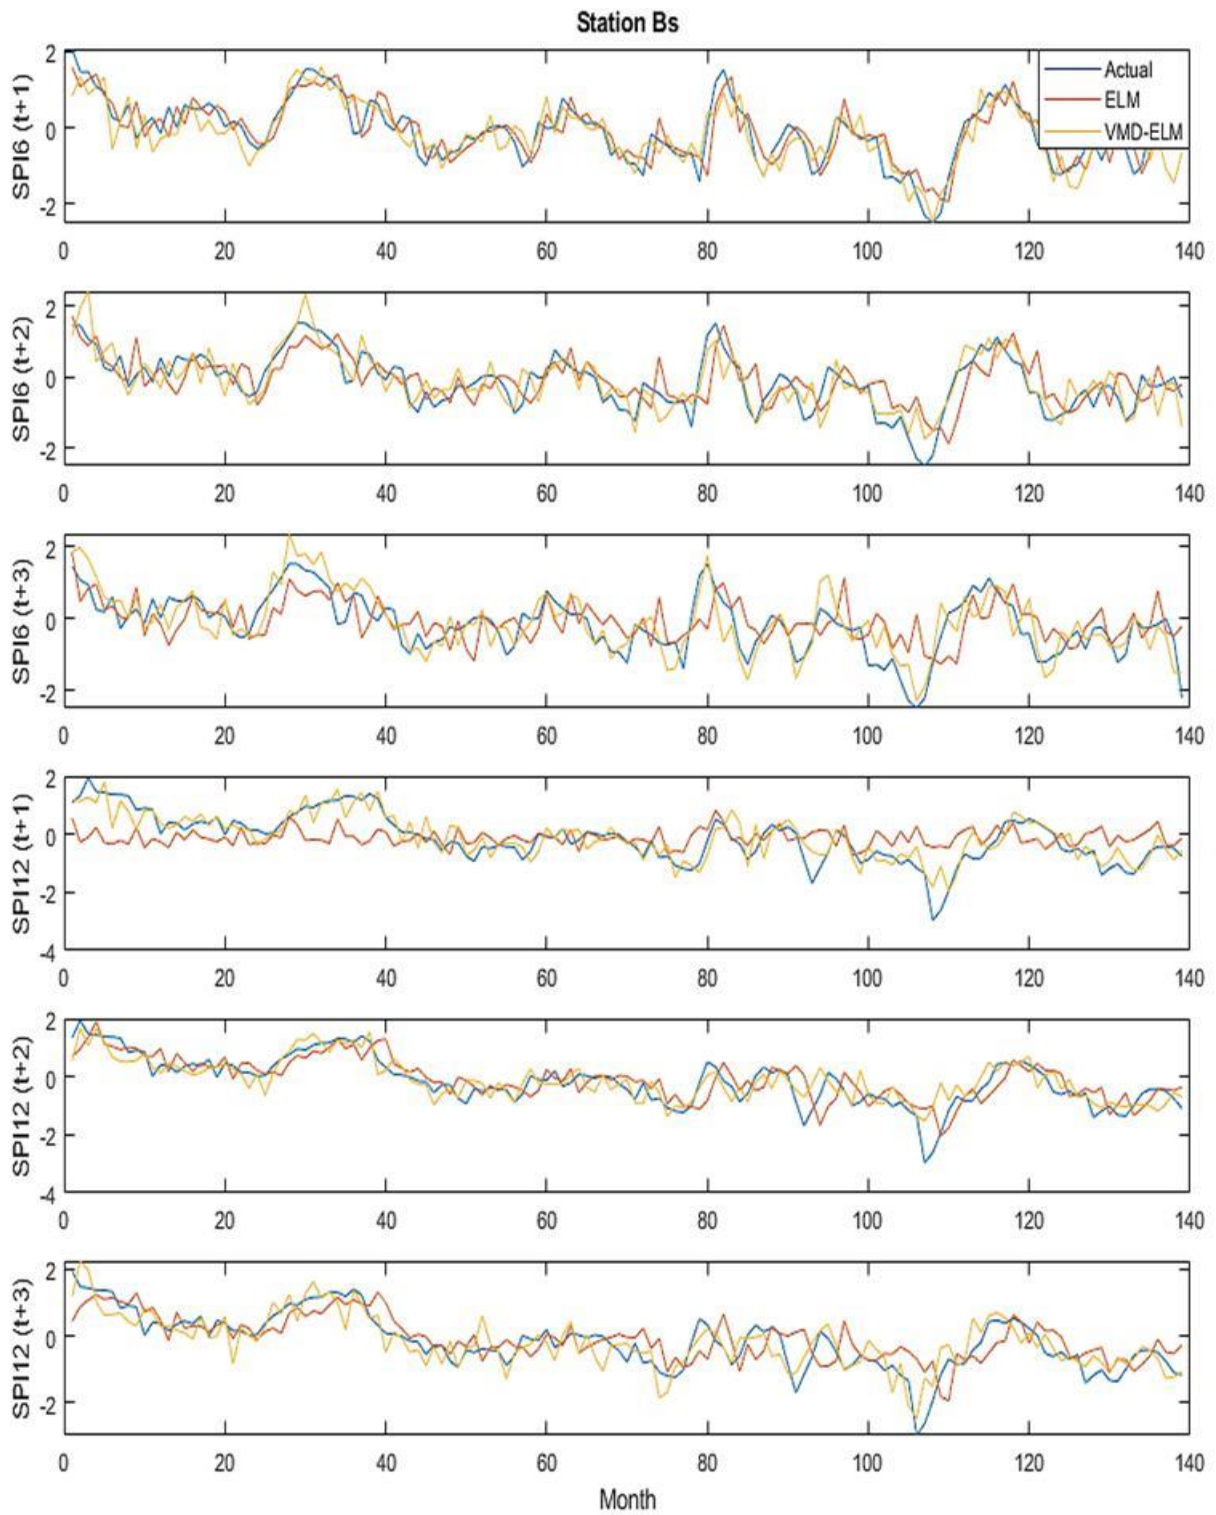
Les graphiques des séries chronologiques d'un mois, de deux mois et de trois mois précédant l'SPI<sub>6</sub> et l'SPI<sub>12</sub> sont présentés à la figure 19. Ces graphiques comparent les valeurs SPI réelles avec les sorties de prédiction générées par les modèles. Il est indiqué que lorsque les valeurs prévues et réelles présentent des oscillations parallèles, la précision de prédiction est élevée. Les modèles ELM et VMD-ELM établis à la suite de la comparaison des séries chronologiques se sont avérés avoir une précision satisfaisante dans la prédiction de la sécheresse. Cependant, selon ces renseignements, le modèle hybride VMD-ELM a démontré des performances supérieures au modèle ELM unique dans toutes les stations. Cependant, le modèle ELM unique se distingue pour les prévisions de sécheresse SPI<sub>6(t+1)</sub> dans les stations Msaad et Bou Saada et SPI<sub>12(t+1)</sub> dans les stations Msaad, El Kantara et M'sila.



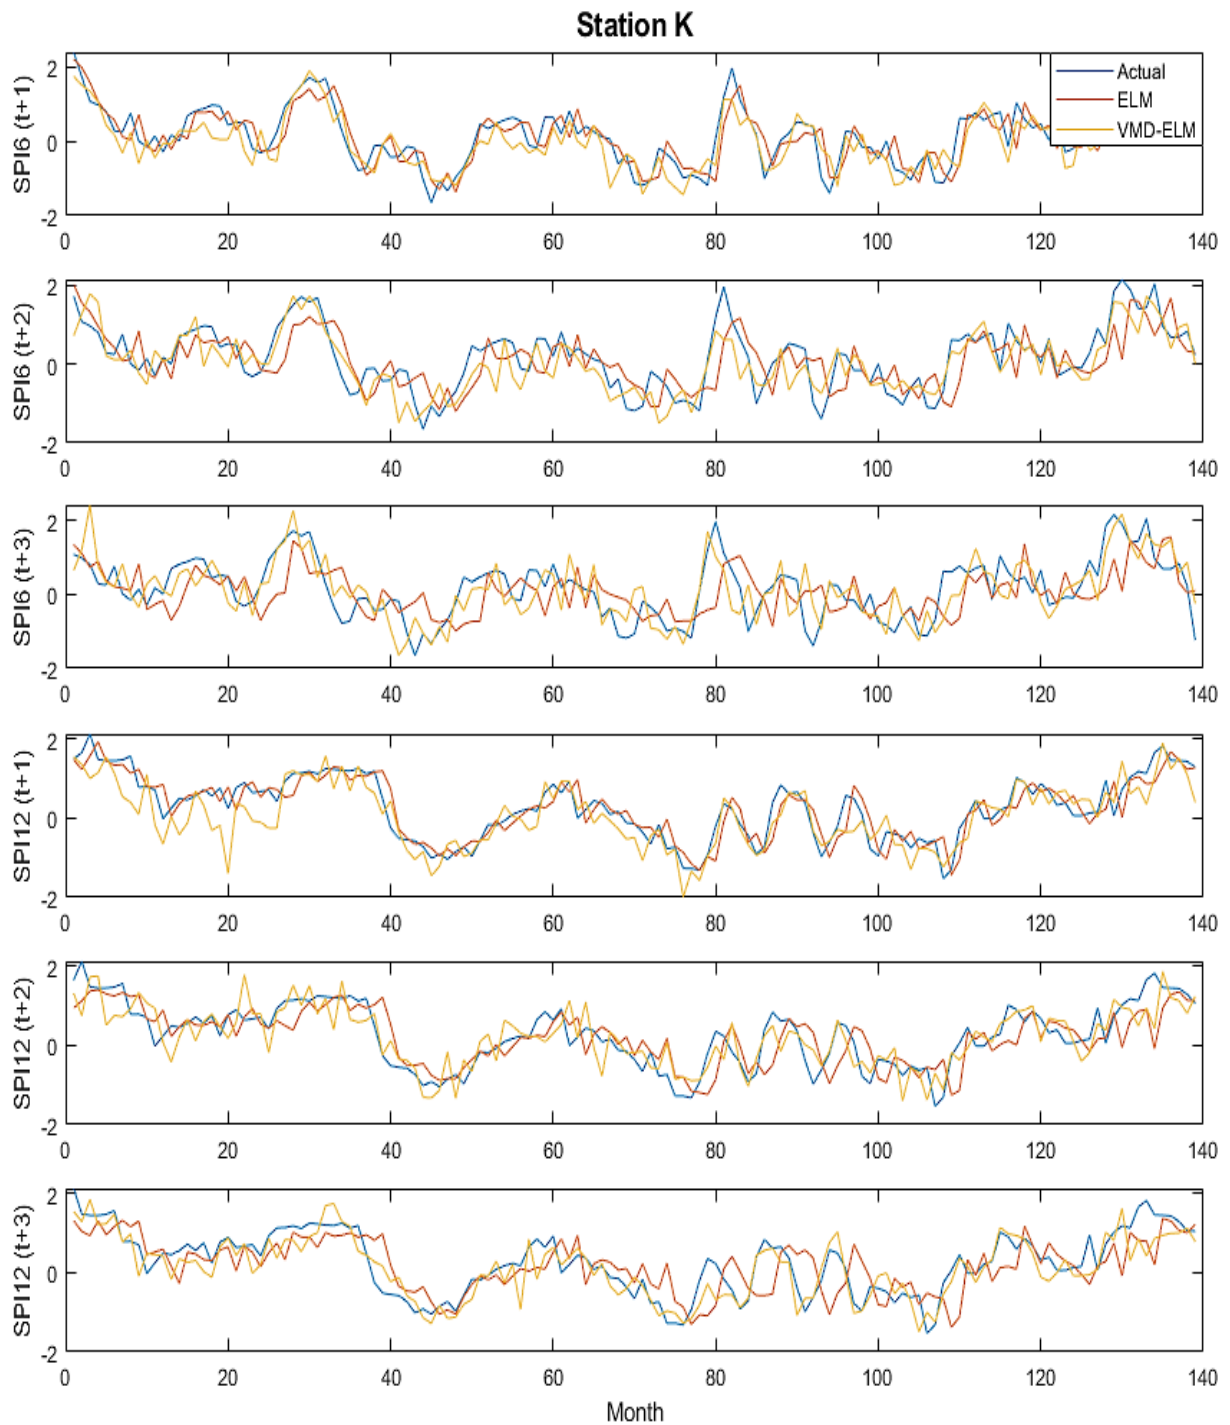
à suivre



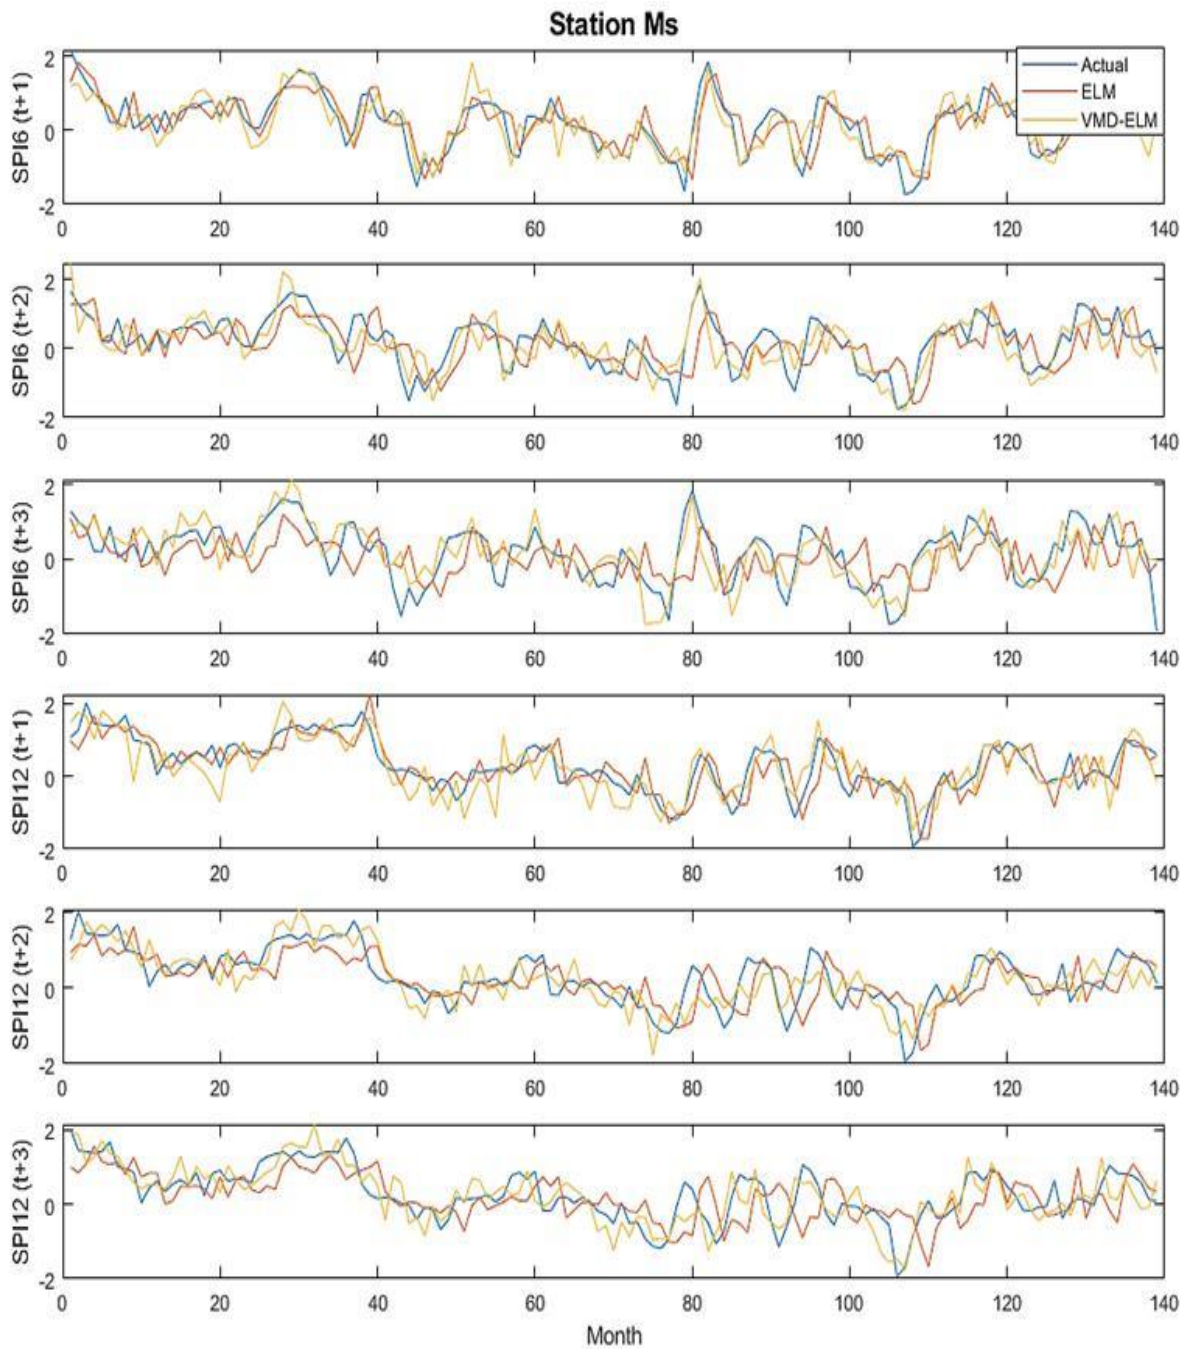
à suivre



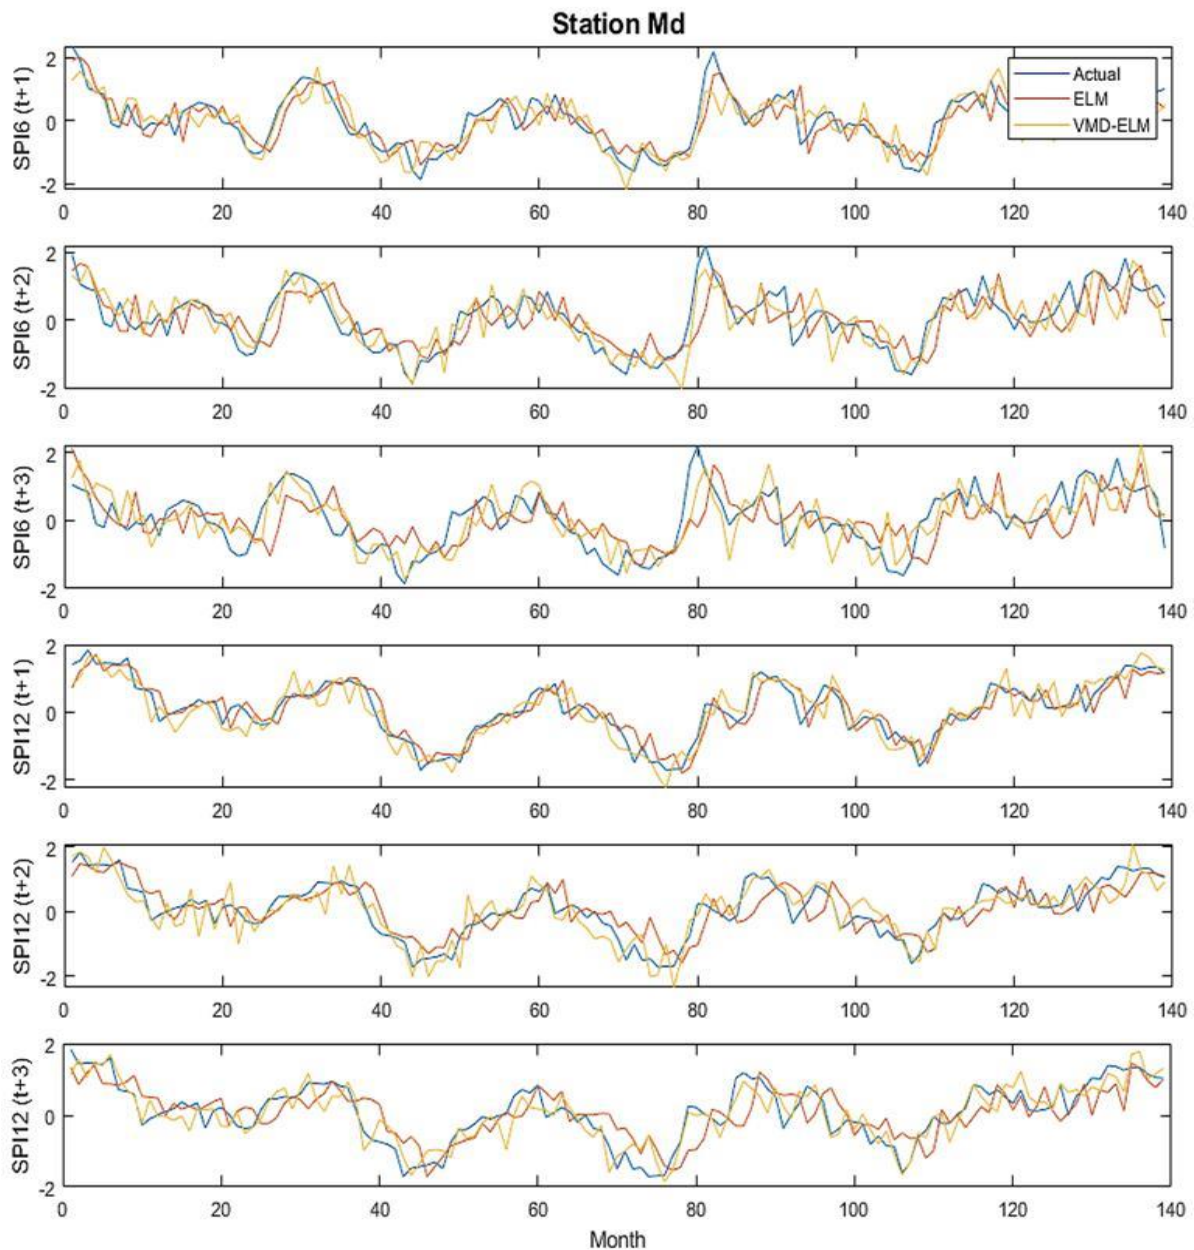
à suivre



à suivre



à suivre



**Figure 19.** Comparaison des résultats des prévisions de l'indice de sécheresse avec les séries chronologiques.

#### 4.7. Discussion

L'efficacité des algorithmes ELM simple et hybride VMD-ELM a été évaluée pour l'estimation des sécheresses en tant que SPI à 6 et 12 mois avec des pas de temps de 1, 2 et 3 mois. En comparant les erreurs et le coefficient de détermination pour l'estimation de la sécheresse à l'aide des SPI dans six stations différentes, le modèle hybride a été plus performant que le modèle unique. Le modèle hybride a également fourni les prévisions les plus précises pour les valeurs de l'indice SPI<sub>12</sub>, bien que le modèle unique ait été plus

précis pour les stations Msaad et El Kantara. Coşkun et Citakoglu (2023) ont obtenu des résultats comparables lors de la prédiction de l'indice standardisé des précipitations (SPI) à 6 mois pour la province de Sakarya, dans le nord-ouest de la Turquie, en utilisant un modèle hybride combinant la mémoire à long terme (LSTM) et la décomposition en mode empirique (EMD). Ils sont notamment constatés que le modèle LSTM unique était plus performant que les autres lorsqu'il s'agissait de prévoir l'indice SPI à des échéances d'un mois et de trois mois. Ces résultats suggèrent que les techniques de prétraitement ne sont peut-être pas essentielles pour l'analyse des séries temporelles de la sécheresse. Mais plusieurs études ont prouvé la priorité des modèles basés sur des méthodes de prétraitement pour la simulation des phénomènes hydrologiques (Sibtain et al. 2021 ; Feng et al. 2022 ; Liu et al. 2023). Ömer Ekmekcioglu.2023 a intégré la technique de décomposition variationnelle des modes (VMD) récemment introduite pour le traitement des signaux. Le modèle hybride VMD-XGBoost (Variational Mode Decomposition-Extreme Gradient Boosting) a été comparé à la fois à un modèle XGBoost (Extreme Gradient Boosting) autonome et à un modèle XGBoost hybride combiné à la transformée en ondelettes discrète (DWT). Les résultats démontrent que le modèle VMD-XGBoost surpasse ses homologues en termes de performance de prédiction. Guonhui et al., (2022) ont également montré une meilleure performance du modèle VMD-ELM pour les prévisions de précipitations mensuelles que le modèle ELM.

79

Mehmet Özger et al 2020 ont évalué l'efficacité de techniques hybrides pour la prédiction de la sécheresse, en utilisant des modèles de régression linéaire multiple (MLR), des réseaux de neurones artificiels (ANN) et des techniques d'ondelettes (DWT et WPT). Les valeurs de l'indice de gravité de la sécheresse de Palmer auto-calibré (sc-PDSI) ont été prédites pour des pas de temps de 1, 3 et 6 mois dans les villes d'Adana et d'Antalya en Turquie. Les résultats montrent que les modèles hybrides surpassent les modèles autonomes, en particulier pour les prévisions à moyen terme. Agana et Homaifar (2018) ont développé un modèle hybride qui combine les réseaux de croyance profonds (DBN), SVR (Support Vector Regression) et MLP (Multilayer Perceptron) avec la décomposition en mode empirique (EMD) pour prévoir l'indice normalisé du débit des cours d'eau (SSI) à la fois pour les échelles de temps à une étape et à deux étapes. Leurs conclusions ont

révélé que les modèles améliorés par EMD surpassaient de manière significative les méthodes traditionnelles dans dix stations de surveillance, en particulier dans les prévisions à plusieurs étapes, démontrant une précision et une fiabilité supérieures. Mehdizadeh et al. (2020) ont effectué les prévisions SPEI-3, SPEI-6 et SPEI-12 à l'aide des données obtenues par les six stations météorologiques situées en Turquie. Ils ont souligné que le modèle hybride ondelette-programmation de l'expression génétique(GEP) donne de meilleurs résultats que le modèle GEP autonome.

80

La comparaison entre les valeurs prédites et les valeurs réelles révèle que le modèle hybride est plus performant que le modèle unique dans toutes les stations. En outre, le modèle hybride est plus efficace dans les stations Ain Elhadjel, Bou Saada et Elkantara que dans les autres stations. Cependant, dans les stations Msaad, M'doukel et M'sila, les prévisions des deux modèles ne sont pas fiables, sauf dans des cas exceptionnels. De meilleurs résultats peuvent être obtenus en manipulant l'algorithme du modèle ELM et sa combinaison avec le modèle VMD de prétraitement. Dans l'une de ces études Yong et al. (2022) ont proposé le modèle (ELM) améliorée par une décomposition variationnelle des modes (VMD) optimisée. Les innovations clés de ce modèle incluent la redéfinition de la sortie de la couche cachée de l'ELM à l'aide d'une décomposition matricielle triangulaire orthogonale (QR), créant ainsi l'ELM triangulaire orthogonale (QR-ELM). De plus, l'intégration d'un mécanisme d'apprentissage en ligne (OS) au sein du QR-ELM forme l'OS-QR-ELM, augmentant significativement l'efficacité de l'ELM. Pour traiter les effets de bord de la VMD, une méthode d'extension basée sur l'information mutuelle est appliquée au signal original. Le modèle combiné VMD-OS-QR-ELM démontre des améliorations substantielles en termes de fiabilité et de précision.

En conclusion, les résultats de cette étude indiquent que l'algorithme hybride VMD-ELM est nettement plus performant que l'algorithme ELM autonome pour l'estimation des conditions de sécheresse sur la base des valeurs SPI dans différents horizons de prévision. Le modèle hybride a fait preuve d'une précision et d'une efficacité supérieures à celles des autres modèles dans la plupart des stations de surveillance, en particulier lorsqu'il s'agit de prévoir les valeurs de l'indice SPI dans un délai de 12 mois. Bien que

plusieurs modèles aient été évalués, l'algorithme ELM autonome a montré la meilleure performance aux stations Msaad et El -Kantara. Cependant, dans la plupart des autres stations, le modèle hybride a constamment surpassé le modèle unique, bien qu'il y ait eu quelques endroits où les deux modèles se sont avérés peu fiables. Les performances variables des modèles existants dans différentes stations soulignent l'influence des facteurs météorologiques localisés, tels que la variabilité spatiale des régimes de précipitations. Cette observation est conforme aux conclusions de Yuan et al. (2023), qui ont noté que la topographie locale et les microclimats affectent de manière significative la prévisibilité de la sécheresse.

81

Dans l'ensemble, les recherches actuelles soutiennent l'application du modèle VMD-ELM pour la prédiction de la sécheresse. Cependant, plusieurs limites devraient être prises en compte dans les études futures. Premièrement, l'analyse a été menée sur un nombre limité de stations dans une région spécifique de l'Algérie, ce qui nécessite des recherches supplémentaires pour évaluer si ces résultats peuvent être généralisés à d'autres zones géographiques et conditions climatiques. Deuxièmement, l'étude n'a pris en compte que quelques variables météorologiques sélectionnées comme intrants pour le modèle ELM. L'incorporation de prédicteurs supplémentaires, tels que d'autres variables climatiques, des données sur l'utilisation des terres et les niveaux d'humidité du sol, pourrait améliorer la précision des prévisions de sécheresse. Des études récentes menées par Zhang et al. (2023a, b), Liu et al. (2022) et Lalika et al. (2024) ont mis en évidence les avantages de l'utilisation de sources de données multiples et de techniques d'apprentissage automatique pour la prédiction de la sécheresse. En outre, l'étude du potentiel des méthodes d'ensemble, comme l'ont démontré les recherches récentes de Gong et al. (2023), pourrait encore améliorer la précision des prévisions de sécheresse.

### 4.8. Conclusion

Cette étude s'est concentrée sur l'intégration de la technique de décomposition en mode variationnel (VMD) avec l'algorithme de machine d'apprentissage extrême (ELM), afin de mener une évaluation approfondie de la précision et de l'efficacité des modèles de prédiction de la sécheresse. L'objectif principal était d'améliorer la capacité à anticiper les

sécheresses et leurs effets sur les ressources en eau, l'agriculture, les écosystèmes et la production d'énergie. Notre étude a montré que l'algorithme hybride VMD-ELM était plus performant que l'algorithme ELM simple pour la prédiction du début des sécheresses en examinant divers intervalles de temps (1, 2 et 3 mois) et valeurs SPI (6 et 12 mois). Ce résultat met en évidence l'efficacité du traitement des signaux en tant que méthode de prétraitement pour améliorer les capacités de prédiction du modèle d'apprentissage automatique. L'inclusion de la VMD, qui a permis la décomposition des variables météorologiques et des valeurs SPI, a permis d'améliorer les données d'entrée du modèle et donc les prévisions. Plusieurs stations, chacune avec des caractéristiques uniques, ont été utilisées dans l'évaluation empirique de la précision du modèle. En particulier lors de la prédiction des valeurs de l'indice SPI 12, le modèle hybride VMD-ELM a constamment fait preuve d'une précision et d'une efficacité accrues dans les différentes stations. Cela confirme la capacité du modèle hybride à capturer les modèles complexes et les corrélations présentes dans les ensembles de données, fournissant des prévisions de sécheresse précises. Néanmoins, il est crucial de noter que le modèle ELM unique a démontré une performance remarquable dans certaines circonstances (par exemple, les stations M et K). Ces cas ont démontré la complexité de la modélisation prédictive et la valeur de l'adaptation des stratégies à des scénarios particuliers. Malgré ces valeurs aberrantes, le modèle hybride a toujours été plus performant dans la grande majorité des stations, ce qui souligne son potentiel en tant qu'outil utile pour la prédiction de la sécheresse. Les résultats de cette étude ont d'importantes ramifications pour la gestion des ressources en eau, la lutte contre le changement climatique et la prise de décision en connaissance de cause. En soutenant des stratégies et des interventions préventives, les prévisions précises produites par le modèle hybride VMD-ELM peuvent aider les parties prenantes et les décideurs à atténuer les effets négatifs de la sécheresse.

### Conclusion Générale

La sécheresse est un problème complexe qui affecte non seulement les écosystèmes, mais aussi les économies et les sociétés humaines. Les conséquences de la sécheresse, des pertes de biodiversité à l'épuisement des sources d'eau, nécessitent une compréhension détaillée des causes de ces phénomènes basés, d'une part, sur des processus naturels et, d'autre part, sur l'activité humaine. Des interventions flexibles et individualisées sont nécessaires pour renforcer la capacité des communautés à résister à ces événements climatiques extrêmes.

83

La modélisation stochastique, à travers les modèles ARIMA/SARIMA, a montré son efficacité pour prédire des indices de sécheresse sur des périodes plus longues. Cependant, ces modèles linéaires peuvent manquer de précision face aux composants non linéaires des données. La modélisation probabiliste, comme l'analyse de la chaîne de Markov, a également été utilisée pour des prévisions à court terme. Les modèles d'IA, tels que les réseaux de neurones, la logique floue et la régression vectorielle de soutien, se révèlent particulièrement efficaces pour prédire les événements de sécheresse complexes, capturant les aspects non stationnaires et non linéaires des données.

L'étude offre un aperçu détaillé du bassin Hodna et examine la base de données météorologiques utilisée. Elle présente également la méthodologie de calcul de l'indice SPI pour analyser la variabilité des précipitations. Ces éléments établissent les bases pour une meilleure compréhension des modèles hydrologiques dans la zone d'étude, essentielle pour les analyses et discussions futures, dans le but de prévoir les conditions de sécheresse à l'aide de modèles d'IA.

Cette étude a intégré la technique de décomposition en mode variationnel (VMD) avec l'algorithme d'apprentissage extrême (ELM) pour améliorer la prévision des sécheresses. Les résultats montrent que le modèle hybride VMD-ELM dépasse l'ELM simple, surtout pour la prévision du début des sécheresses sur différents intervalles de temps et valeurs SPI. La VMD, en décomposant les variables météorologiques et les valeurs SPI, a

amélioré les données d'entrée, ce qui a conduit à des prévisions plus précises. Bien que quelques exceptions existent, le modèle hybride s'est avéré supérieur dans la plupart des cas, offrant un potentiel significatif pour la gestion des ressources en eau et la prise de décisions face au changement climatique.

## Références Bibliographiques

- Acharya, N., Singh, A., Mohanty, U. C., Nair, A., & Chattopadhyay, S. (2013). Performance of general circulation models and their ensembles for the prediction of drought indices over India during summer monsoon. *Natural hazards*, 66, 851-871.
- Achite, M., Jehanzaib, M., Elshaboury, N., & Kim, T. W. (2022). Evaluation of machine learning techniques for hydrological drought modeling: A case study of the Wadi Ouahrane basin in Algeria. *Water*, 14(3), 431.
- Achite, M., Bazrafshan, O., Katipoğlu, O.M. et al. (2023). Evaluation of hydro-meteorological drought indices for characterizing historical droughts in the Mediterranean climate of Algeria. *Nat Hazards* 118, 427–453.
- Achite, M., Gul, E., Elshaboury, N., Jehanzaib, M., Mohammadi, B., & Mehr, A. D. (2023). An improved adaptive neuro-fuzzy inference system for hydrological drought prediction in Algeria. *Physics and Chemistry of the Earth, Parts A/B/C*, 131, 103451.
- Achour, K., Meddi, M., Zeroual, A., Bouabdelli, S., Maccioni, P., & Moramarco, T. (2020). Spatio-temporal analysis and forecasting of drought in the plains of northwestern Algeria using the standardized precipitation index. *Journal of Earth System Science*, 129, 1-22.
- Agana, N.A., Homaifar, A. (2018). EMD-Based Predictive Deep Belief Network for Time Series Prediction: An Application to Drought Forecasting. *Journal of Hydrology*. 5(1), 18. <https://doi.org/10.3390/hydrology5010018>
- Agha Kouchak, A. (2015). A multivariate approach for persistence-based drought prediction: Application to the 2010–2011 East Africa drought. *Journal of Hydrology*, 526, 127-135.
- Alam, N. M., Mishra, P. K., Jana, C., & Adhikary, P. P. (2014). Stochastic model for drought forecasting for Bundelkhand region in Central India.
- Alawsi, M. A., Zubaidi, S. L., Al-Bdairi, N. S. S., Al-Ansari, N., & Hashim, K. (2022). Drought forecasting: a review and assessment of the hybrid techniques and data pre-processing. *Hydrology*, 9(7), 115.

Ali, M., Deo, R. C., Downs, N. J., & Maraseni, T. (2018). An ensemble-ANFIS based uncertainty assessment model for forecasting multi-scalar standardized precipitation index. *Atmospheric Research*, 207, 155-180.

Apaydin, H., Sattari, M. T., Falsafian, K., & Prasad, R. (2021). Artificial intelligence modelling integrated with Singular Spectral analysis and Seasonal-Trend decomposition using Loess approaches for streamflow predictions. *Journal of Hydrology*, 600, 126506.

Avilés, A., Célleri, R., Solera, A., & Paredes, J. (2016). Probabilistic forecasting of drought events using Markov chain and Bayesian network-based models: A case study of an Andean regulated river basin. *Water*, 8(2), 37.

Bazrafshan, O., Salajegheh, A., Bazrafshan, J., Mahdavi, M., & Fatehi Maraj, A. (2015). Hydrological drought forecasting using ARIMA models (case study: Karkheh Basin). *Ecopersia*, 3(3), 1099-1117.

Belayneh, A., Adamowski, J., Khalil, B., Ozga-Sielinski, B. (2012). Long term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet neural networks and wavelet support vector regression models. *J Hydrol* 508: 418-429

Belayneh, A., & Adamowski, J. (2013). Drought forecasting using new machine learning methods. *Journal of Water and Land Development*, 18(9), 3-12.

Bordi, I., Sutera, A. (2007). Drought monitoring and forecasting at large scale in Rossi et al., (editors), *methods and tools for drought analysis management*, Springer.

Brace, P., & Hinckley, B. (1991). The Structure of Presidential Approval: Constraints Within and Across Presidencies. *The Journal of Politics*, 53, 993-1017. <http://dx.doi.org/10.2307/2131864>

Byun, H.R. and Wilhite, D.A. (1999). Objective Quantification of Drought Severity and Duration. *Journal of Climatology*, 12, 2747-2756.

Cacciamani, C., Morgillo, A., Marchesi, S., and Pavan, V. (2007). Monitoring and forecasting drought on a regional scale: Emilia Romagna region, J. Water science and technology, 1, 62(1): 29-48.

Caire, P., Hatabian, G., & Muller, C. (1992, June). Progress in forecasting by neural networks. In [Proceedings 1992] IJCNN International Joint Conference on Neural Networks (Vol. 2, pp. 540-545). IEEE.

Chebil, A., Souissi, A., Frija, A., & Stambouli, T. (2019). Estimation of the economic loss due to irrigation water use inefficiency in Tunisia. *Environmental Science and Pollution Research*, 26, 11261-11268.

Chen, J., Li, M., & Yang, W. (2012). Statistical Uncertainty Estimation Using Random Forests and Its Application to Drought Forecast. *Mathematical Problems in Engineering*, 2012.

Coşkun, O., Citakoglu, H. (2023). Prediction of the standardized precipitation index based on the long short-term memory and empirical mode decomposition-extreme learning machine models: The Case of Sakarya, Türkiye. *Physics and Chemistry of the Earth, Parts A/B/C* 131, 103418. <https://doi.org/10.1016/j.pce.2023.103418>.

Dai, A. (2013). Increasing drought under global warming in observations and models. *Nature Climate Change*, 3, 52–58.

Daksh, K., Kumari, V., Kumari, A., Mayoor, M., Singh, H. P., & Mahapatra, S. (2018). Drought risk assessment in Vidarbha region of Maharashtra, India, using standardized precipitation index. *International Journal of Innovative Knowledge Concepts*, 6(10), 13-23.

Das, J., Manikanta, V., Nikhil Teja, K., & Umamahesh, N. V. (2022). Two decades of ensemble flood forecasting: A state-of-the-art on past developments, present applications and future opportunities. *Hydrological Sciences Journal*, 67(3), 477-493.

Das, S., Das, J., & Umamahesh, N. V. (2022). Investigating seasonal drought severity-area-frequency (SAF) curve over Indian region: incorporating GCM and scenario uncertainties. *Stochastic Environmental Research and Risk Assessment*, 36(6), 1597-1614.

de Groot, C., & Würtz, D. (1991). Analysis of univariate time series with connectionist nets: A case study of two classical examples. *Neurocomputing*, 3(4), 177-192.

Dehghani, M., Saghafian, B., Rivaz, F., & Khodadadi, A. (2017). Evaluation of dynamic regression and artificial neural networks models for real-time hydrological drought forecasting. *Arabian Journal of Geosciences*, 10, 1-13.

88

Deo, R. C., & Şahin, M. (2015). Application of the extreme learning machine algorithm for the prediction of monthly Effective Drought Index in eastern Australia. *Atmospheric Research*, 153, 512-525.

Downing, T.E., Bakker, K. (2000). Drought discourse and vulnerability. In: Wilhite, D.A. (Ed.), *Drought: A Global Assessment, Natural Hazards and Disasters Series*. Routledge Publishers, UK.

Dracup, J. A., Lee, K. S., & Paulson Jr, E. G. (1980). On the statistical characteristics of drought events. *Water resources research*, 16(2), 289-296.

Droogers, P., Dam, J. C. V., Simons, G., Voogt, M., & Terink, W. (2012). The added value of high-resolution above coarse-resolution remote sensing images in crop yield forecasting: A case study in the Egyptian Nile Delta.

Elrafy, M. (2009). Impact of climate change: vulnerability and adaptation of coastal areas. Report of the Arab Forum for Environment and Development.

Feng, A., Liu, L., Wang, G., Tang, J., Zhang, X., Chen, Y., ... & Liu, P. (2023). Drought monitoring from Fengyun satellite series: a comparative analysis with meteorological-drought composite index (MCI). *Remote Sensing*, 15(22), 5410.

Fernández-Manso, A., Quintano, C., & Fernández-Manso, O. (2011). Forecast of NDVI in coniferous areas using temporal ARIMA analysis and climatic data at a regional scale. *International Journal of Remote Sensing*, 32(6), 1595-1617.

Foster, N. W., Morrison, I. K., Yin, X., & Arp, P. A. (1992). Impact of soil water deficits in a mature sugarmaple forest: stand biogeochemistry. *Canadian Journal of Forest Research*, 22(11), 1753-1760.

Fung, K. F., Huang, Y. F., Koo, C. H., & Soh, Y. W. (2020). Drought forecasting: A review of modelling approaches 2007–2017. *Journal of Water and Climate Change*, 11(3), 771-799.

Gaaloul, I., Montassar, S. & Frikha, W. (2021). Thermal effects on limit pressure in a cylindrical cavity expansion. *Innov. Infrastruct. Solut.* 6, 194  
.https://doi.org/10.1007/s41062-021-00562-5

89

Gibbs, W.J.(1975). Drought, its definition, delineation and effects. In *Drought: Lectures Presented at the 26th Session of the WMO*. Report No. 5. WMO, Geneva, pp. 3–30.

Gong, X., Li, M., Guan, K., & Sun, C. (2023). Climate change attention and carbon futures return prediction. *Journal of Futures Markets*, 43(9), 1261-1288.

Gorr, W. L., Nagin, D., & Szczygula, J. (1994). Comparative study of artificial neural network and statistical models for predicting student grade point averages. *International Journal of Forecasting*, 10(1), 17-34.

Guha-Sapir, D., Vos, F., Below, R., & Ponserre, S. (2011). Annual disaster statistical review 2010. *Centre for Research on the Epidemiology of Disasters*, 1-80.

Gyaneshwar, A., Mishra, A., Chadha, U., Raj Vincent, P. D., Rajinikanth, V., Pattukandan Ganapathy, G., & Srinivasan, K. (2023). A contemporary review on deep learning models for drought prediction. *Sustainability*, 15(7), 6160.

Hagman, G. (1984). Prevention better than cure: report on human and natural disasters in the Third World. Swedish Red Cross, Stockholm, Sweden.

Hayes, M. J. (2001). Equipping your personal drought monitoring tool box. In *Expansive Clay Soils and Vegetative Influence on Shallow Foundations* (pp. 215-222).

Heim, R. R. (2002). A review of twentieth-century drought indices used in the United States. *Bulletin of the American Meteorological Society*, 83(8), 1149–1165.

Herrera-Estrada, J. E., Martinez, J. A., Dominguez, F., Findell, K. L., Wood, E. F., & Sheffield, J. (2019). Reduced moisture transport linked to drought propagation across North America. *Geophysical Research Letters*, *46*(10), 5243-5253.

Hisdal, H., & Tallaksen, L. M. (2003). Estimation of regional meteorological and hydrological drought characteristics: a case study for Denmark. *Journal of Hydrology*, *281*(3), 230-247.

Hong, I., Lee, J. H., & Cho, H. S. (2016). National drought management framework for drought preparedness in Korea (lessons from the 2014–2015 drought). *Water Policy*, *18*(S2), 89-106.

90

Hosseini-Moghari, S. M., & Araghinejad, S. (2015). Monthly and seasonal drought forecasting using statistical neural networks. *Environmental Earth Sciences*, *74*, 397-412.

Huang, B. (2003, June). Recent advances in drought and heat stress physiology of turfgrass-A review. In *I International Conference on Turfgrass Management and Science for Sports Fields 661* (pp. 185-192).

Huang, G.-B., Zhu, Q.-Y., Siew, C.-K. (2006). Extreme learning machine: theory and applications. *Neurocomputing* *70*, 489–501.

Hui, Guo., Ying, Hou., Yuting, Yang., Wenbin, Liu. (2022). Global Evaluation of Runoff Simulation From Climate, Hydrological and Land Surface Models. <https://doi.org/10.1029/2021WR031817>

ISSA, S., BISSO, S., & OUSMANE, B. (2019). Modélisation des modules pluviométriques annuels au Niger. *Afrique SCIENCE*, *15*(2), 1-15.

Karthika, M., & Thirunavukkarasu, V. (2017). Forecasting of meteorological drought using ARIMA model. *Indian Journal of Agricultural Research*, *51*(2), 103-111.

Katipoğlu, O. M. (2023). Prediction of stream flow drought index for short-term hydrological drought in the semi-arid Yesilirmak Basin using Wavelet transform and artificial intelligence techniques. *Sustainability*, *15*(2), 1109.

Keyantash, J., Dracup, J.A. (2004). The quantification of drought: an evaluation of drought indices. *Bull. Am. Meteorol. Soc.* 83, 1167–1180.

Khadr, M. (2016). Temporal and spatial analysis of meteorological drought characteristics in the upper Blue Nile river region. *Hydrology Research*, 48(1), 265-276.

Khan, M. I., Zhu, X., Arshad, M., Zaman, M., Niaz, Y., Ullah, I., & Uzair, M. (2020). Assessment of spatiotemporal characteristics of agro-meteorological drought events based on comparing Standardized Soil Moisture Index, Standardized Precipitation Index and Multivariate Standardized Drought Index. *Journal of Water and Climate Change*, 11(S1), 1-17.

91

Kogan, F. N. (1997). Global drought watch from space. *Bulletin of the American Meteorological Society*, 78(4), 621-636.

Kouao, J. M., Kouassi, A. M., & Kouame, K. A. Prévission De La Sécheresse Météorologique Et Agrométéorologique Dans Un Contexte De Changements Climatiques En Afrique De L'ouest : Cas De La Côte D'ivoire. *Rev. Ivoir. Sci. Technol.*, 40 (2022) 279 – 307 .

Lalika, C., Mujahid, A. U. H., James, M., & Lalika, M. C. (2024). Machine learning algorithms for the prediction of drought conditions in the Wami River sub-catchment, Tanzania. *Journal of Hydrology: Regional Studies*, 53, 101794.

Liu, Z. N., Li, Q. F., Nguyen, L. B., & Xu, G. H. (2018). Comparing machine-learning models for drought forecasting in vietnam's cai river basin. *Polish Journal of Environmental Studies*, 27(6), 2633-2646.

Liu, Y., Yuan, S., Zhu, Y., Ren, L., Chen, R., Zhu, X., & Xia, R. (2023). The patterns, magnitude, and drivers of unprecedented 2022 mega-drought in the Yangtze River Basin, China. *Environmental Research Letters*, 18(11), 114006.

Malik, A., Kumar, A., Salih, S. Q., Kim, S., Kim, N. W., Yaseen, Z. M., & Singh, V. P. (2020). Drought index prediction using advanced fuzzy logic model: Regional case study over Kumaon in India. *Plos one*, 15(5), e0233280.

Malik, A., Tikhamarine, Y., Souag-Gamane, D., Rai, P., Sammen, S. S., & Kisi, O. (2021). Support vector regression integrated with novel meta-heuristic algorithms for meteorological drought prediction. *Meteorology and Atmospheric Physics*, 133, 891-909.

Masinde, M. (2014). Artificial neural networks models for predicting effective drought index: factoring effects of rainfall variability. *Mitigation and adaptation strategies for global change*, 19, 1139-1162.

Masinde, M. (2015). An innovative drought early warning system for sub-Saharan Africa: Integrating modern and indigenous approaches. *African Journal of Science, Technology, Innovation and Development*, 7(1), 8-25.

92

Mckee, T. B., Doesken, N. J. and Kleist, J. (1993). The relationship of drought frequency and duration to time scales in proceedings of 8 th conference on applied climatology, Anaheim, California, U.S.A: 179-184.

MDCE.(2016). La troisième communication nationale à la Convention-cadre des Nations unies sur les changements climatiques. Rabat, Maroc, ministère de l'Environnement, 132 p. [http://www.un-gsp.org/sites/default/files/documents/3069145\\_cite\\_divoire-nc3-1-cote\\_divoire\\_-\\_third\\_national\\_communication.pdf](http://www.un-gsp.org/sites/default/files/documents/3069145_cite_divoire-nc3-1-cote_divoire_-_third_national_communication.pdf)

Meddi, H., Meddi, M., & Assani, A. A. (2014). Study of drought in seven Algerian plains. *Arabian Journal for Science and Engineering*, 39, 339-359.

Mehdizadeh, S., Behmanesh, J., Khalili, K. (2020). Using MARS, SVM, GEP and empirical equations for estimation of monthly mean reference evapo transpiration. *Comput. Electron. Agric.* 139, 103–114. <https://doi.org/10.1016/j.compag.2017.05.002>.

Mishra, A. K., & Desai, V. R. (2005). Drought forecasting using stochastic models. *Stochastic environmental research and risk assessment*, 19, 326-339.

Mishra, A. K., & Desai, V. R. (2006). Drought forecasting using feed-forward recursive neural network. *Ecological modelling*, 198(1-2), 127-138.

Mishra, A. K., Desai, V. R., & Singh, V. P. (2007). Drought forecasting using a hybrid stochastic and neural network model. *Journal of Hydrologic Engineering*, 12(6), 626-638.

Mishra, A. K., & Singh, V. P. (2010). A review of drought concepts. *Journal of hydrology*, 391(1-2), 202-216.

Mishra, A.K.; Singh, V.P.(2011). Drought modeling – A review. *J. Hydrol*, 403, 157–175.

Mokhtar, A., Jalali, M., He, H., Al-Ansari, N., Elbeltagi, A., Alsafadi, K., ... & Rodrigo-Comino, J. (2021). Estimation of SPEI meteorological drought using machine learning algorithms. *IEEE Access*, 9, 65503-65523.

93

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.

Morid, S., Smakhtin, V., & Bagherzadeh, K. (2007). Drought forecasting using artificial neural networks and time series of drought indices. *International Journal of climatology*, 27(15), 2103-2112.

Moujahid, Y., Bouabid, R. (2014). Mineralogy and charge of Moroccan vertisols smectite. *J. Mat. Envir. Sci.*, 5 1541-1550.

Nguyen, L. B., Li, Q. F., Ngoc, T. A., & Hiramatsu, K. (2015). Adaptive Neuro-Fuzzy inference system for drought forecasting in the Cai River Basin in Vietnam.

NOAA. (2017). National Drought Overview in September 2017. <https://www.ncdc.noaa.gov/sotc/drought/201709> (accessed 16 May 2020).

Nourani, V., Baghanam, A. H., Adamowski, J., & Kisi, O. (2014). Applications of hybrid wavelet-artificial intelligence models in hydrology: a review. *Journal of Hydrology*, 514, 358-377.

Özger, M., Başakın, E. E., Ekmekcioğlu, Ö., & Hacısüleyman, V. (2020). Comparison of wavelet and empirical mode decomposition hybrid models in drought prediction. *Computers and Electronics in Agriculture*, 179, 105851.

Palmer, W.C. (1965). Meteorological Drought. US Department of Commerce, Weather Bureau, Technical Paper 45. pp. 58.

Pinkeye, S.(1966). Conditional Probabilities of Occurrence of Wet and Dry Years Over a Large Continental Area. Hydrol. Paper 12, Colorado State University, Fort Collins, Colorado.

Rajesh, A.M., Prakash,S., V.K. Shahi. (2011).Chlorine-tolerant poly electrolyte membrane for electrochemical dye degradation. Chemical engineering journal- Elsevier.

94

Rhee, J., & Im, J. (2017). Meteorological drought forecasting for ungauged areas based on machine learning: Using long-range climate forecast and remote sensing data. *Agricultural and Forest Meteorology*, 237, 105-122.

Sahin, S., Cigizoglu, H.K. (2012). The sub-climate regions and the sub-precipitation regime regions in Turkey. *J Hydrol* 450:180–189.

Sahin, U., Kuslu, Y., Kiziloglu, F. M., & Cakmakci, T. (2016). Growth, yield, water use and crop quality responses of lettuce to different irrigation quantities in a semi-arid region of high altitude. *Journal of applied horticulture*, 18(3), 195-202.

Santos, M.A.(1983). Regional droughts: a stochastic characterization. *J. Hydrol.* 66,183–211.

Seleiman, M. F., Al-Suhaibani, N., Ali, N., Akmal, M., Alotaibi, M., Refay, Y., ... & Battaglia, M. L. (2021). Drought stress impacts on plants and different approaches to alleviate its adverse effects. *Plants*, 10(2), 259.

Şen, Z. (1980). Regional drought and flood frequency analysis: Theoretical consideration. *Journal of hydrology*, 46(3-4), 265-279.

Sharma, T.C., Panu, U.S. (2012) Analytical procedures for weekly hydrological droughts: a case of Canadian rivers. *Hydrological Sciences Journal*, 55 (1), 79-92.

Shatanawi, K., Rahbeh, M., & Shatanawi, M. (2013). Characterizing, monitoring and forecasting of drought in Jordan River Basin. *Journal of Water Resource and Protection*, 2013.

Shukla, S., Wood, A.W. (2008). Use of a standardized runoff index for characterizing hydrologic drought. *Geophys. Res. Lett.*, 35.

Sibtain, M., Li, X., Azam, M. I., & Bashir, H. (2021). Applicability of a three-stage hybrid model by employing a two-stage signal decomposition approach and a deep learning methodology for runoff forecasting at Swat River catchment, Pakistan. *Polish Journal of Environmental Studies*, 30(1).

95

Slater, L., Arnal, L., Boucher, M. A., Chang, A. Y. Y., Moulds, S., Murphy, C., ... & Zappa, M. (2023). Hybrid forecasting: blending climate predictions with AI models.

Stour L. & Agoumi A. (2007). Réchauffement climatique et sécheresse au Maroc en 2050. *Revue Marocaine de Génie Civil* (119), 3<sup>e</sup> trimestre.

Sun, P., Zhang, Q., Cheng, C., Singh, V. P., & Shi, P. (2017). ENSO-induced drought hazards and wet spells and related agricultural losses across Anhui province, China. *Natural Hazards*, 89, 963-983.

Svoboda, M., Hayes, M., Wood, D. (2012). Standardized Precipitation Index User Guide; World Meteorological Organization: Geneva, Switzerland.

Tabari, H., Nikbakht, J., & Hosseinzadeh Talaee, P. (2013). Hydrological drought assessment in North western Iran based on stream flow drought index (SDI). *Water resources management*, 27, 137-151.

Tabet-Aoul, M. (2008). Impacts du changement climatique sur les agricultures et les ressources hydriques au Maghreb. *Les notes d'alerte du CIHEAM*, (48).

Touma, D., Ashfaq, M., Nayak, M., Kao, S., & Diffenbaugh, N. (2015). A multi-model and multi-index evaluation of drought characteristics in the 21st century. *Journal of Hydrology*, 526, 196–207.

Tsakiris, G., Pangalou, D., & Vangelis, H. (2007). Regional drought assessment based on the Reconnaissance Drought Index (RDI). *Water resources management*, 21, 821-833.

Van Loon, A. F. (2015). Hydrological drought explained. *Wiley Interdisciplinary Reviews: Water*, 2(4), 359-392.

Van Loon, A. F., Stahl, K., Di Baldassarre, G., Clark, J., Rangelcroft, S., Wanders, N., ... & Van Lanen, H. A. (2016). Drought in a human-modified world: reframing drought definitions, understanding, and analysis approaches. *Hydrology and Earth System Sciences*, 20(9), 3631-3650.

96

Wang, Y. and Markert, R. (2016). Filter Bank Property of Variational Mode Decomposition and Its Applications. *Signal Processing*, 120, 509-521.  
<https://doi.org/10.1016/j.sigpro.2015.09.041>

Wilhite, D. A., & Glantz, M. H. (1985). Understanding: the drought phenomenon: the role of definitions. *Water international*, 10(3), 111-120.

Wilhite, D. A., & Easterling, W. E. (1987). Planning for Drought. Wilhite, D. A., & Vanyarkho, O. V. (2000). Drought: Pervasive impacts of a creeping phenomenon. In D. Wilhite (Ed.), *Drought: A global assessment* (Vol. 1, pp. 245–255). London: Routledge.

Xu, Y., Lamarque, J. F. & Sanderson, B. M. (2018). The importance of aerosol scenarios in projections of future heat extremes. *Clim. Change* 146, 393–406.

Yaseen, Z. M., & Shahid, S. (2021). Drought index prediction using data intelligent analytic models: a review. *Intelligent Data Analytics for Decision-Support Systems in Hazard Mitigation: Theory and Practice of Hazard Mitigation*, 1-27.

Yeh, C. F., Wang, J., Yeh, H. F., & Lee, C. H. (2015). SDI and Markov chains for regional drought characteristics. *Sustainability*, 7(8), 10789-10808.

Yuan, X., Wang, Y., Ji, P., Wu, P., Sheffield, J., & Otkin, J. (2023). A global transition to flash drought under climate change. *Science*, 380(6641), 187–191.  
<https://doi.org/10.1126/science.abn6301>

Zhang, W., Villarini, G., Vecchi, G. A. & Smith, J. A. (2017). Urbanization exacerbated the rainfall and flooding caused by hurricane Harvey in Houston. *Nature* 563, 384–389.

Zhang, Liuhua., Tianbao, Gong., and Yanan, Tong. (2023a,b). The Impact of Digital Logistics Under the Big Environment of Economy. *PLoS ONE*, 18(4): e0283613.