



HAL
open science

Modélisation spatiale des précipitations en Méditerranée : prise en compte de la non-stationnarité spatiale et des événements extrêmes

Hela Hammami

► **To cite this version:**

Hela Hammami. Modélisation spatiale des précipitations en Méditerranée : prise en compte de la non-stationnarité spatiale et des événements extrêmes. Traitement du signal et de l'image [eess.SP]. Université de Montpellier; École supérieure des communications de Tunis (Tunisie), 2023. Français. NNT : 2023UMONG044 . tel-04654573

HAL Id: tel-04654573

<https://theses.hal.science/tel-04654573v1>

Submitted on 19 Jul 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

THÈSE POUR OBTENIR LE GRADE DE DOCTEUR DE L'UNIVERSITÉ DE MONTPELLIER ET DE L'ÉCOLE SUPÉRIEURE DES COMMUNICATIONS DE TUNIS

En Sciences de l'Eau et en Technologies de l'information et de la communication
École doctorale GAIA – Biodiversité, Agriculture, Alimentation, Environnement, Terre, Eau
Unité de recherche HydroSciences Montpellier (HSM)

En partenariat international avec

École supérieure des communications de Tunis, TUNISIE
École doctorale EDTIC - Technologies de l'information et de la communication
Laboratoire de recherche Communications, Signaux et Images (COSIM)

Modélisation spatiale des précipitations en Méditerranée : prise en compte de la non-stationnarité spatiale et des événements extrêmes

Présentée par Hela HAMMAMI

le 7 Décembre 2023

Sous la direction de Luc Neppel, Sadok Elasmî
et Julie Carreau

Devant le jury composé de

Marielle GOSSET, Directeur de recherche HDR, IRD

Rim ZITOUNA-CHEBBI, Maître de conférences, INRGREF

Neji YOUSSEF, Professeur, École Supérieure des Communications de Tunis

Riadh ABDEL FATTEH, Professeur, École Supérieure des Communications de Tunis

Gwladys TOULEMONDE, Maître de conférences, Université de Montpellier

Luc NEPPEL, Maître de conférences, PolyTech, Université de Montpellier

Sadok ELASMI, Professeur, École Supérieure des Communications de Tunis

Julie CARREAU, Professeure Adjointe, Polytechnique Montréal

Rapporteuse

Rapporteuse

Président de jury

Examineur

Examinatrice

Directeur de thèse

Directeur de thèse

Co-encadrante



UNIVERSITÉ
DE MONTPELLIER

SUP'COM
Higher School of Communication of Tunis

Remerciements

Au terme de ce parcours académique, je tiens à exprimer ma sincère gratitude envers toutes les personnes qui ont joué un rôle fondamental dans la réalisation de cette thèse. Ce travail de recherche a été mené dans le cadre d'une collaboration internationale entre l'Université de Montpellier (UM) en France et l'Université de Carthage / École Supérieure des Communications de Tunis (SUP'COM) en Tunisie. Une alliance exceptionnellement enrichissante grâce aux compétences complémentaires des deux laboratoires de recherche impliqués : l'unité mixte de recherche HydroSciences Montpellier (HSM) et le laboratoire de recherche Communications, Signaux et Images (COSIM).

En premier lieu, je souhaite exprimer ma plus profonde gratitude envers mes directeurs de thèse, M.Luc Neppel et M.Sadok Elasmî, ainsi que ma co-encadrante Mme.Julie Carreau. Leur engagement et leur soutien inestimables ont joué un rôle fondamental à chaque étape de mon parcours doctoral. Je tiens à souligner le temps précieux qu'ils ont généreusement consacré à la direction de ma thèse, ainsi que leurs remarques et leurs conseils qui ont enrichi ma recherche tout au long de ces années d'études doctorales.

Je remercie également les membres du comité de suivi de thèse qui ont évalué mon avancement et m'ont fourni des pistes de recherche : M.Yves Trambly (UM, Montpellier), Mme.Gwladys Toulemonde (UM, Montpellier), M.Jonathan Jalbert (Polytechnique Montréal) et M.Jean-Noël BACRO (UM, Montpellier). En plus, je tiens à remercier la référente à l'école doctorale GAIA, Mme.Agnès Begue (UM, Montpellier), pour son soutien et ses encouragements.

Je tiens à exprimer ma gratitude envers Mme.Marielle GOSSET (Directeur de recherche HDR, IRD) et Mme.Rim ZITOUNA-CHEBBI (Maître de conférences, INRGREF) pour avoir accepté de lire et de rapporter ma thèse. La version finale de ce manuscrit a bénéficié de leur relecture très attentive et de leurs remarques précieuses. J'aimerais remercier M.Neji YOUSSEF (Professeur à SUPCOM) d'avoir accepté d'être président du jury. Je remercie également M.Riadh ABDEL FATTEH (Professeur à SUPCOM) et Mme.Gwladys TOULEMONDE (Maître de conférences, UM) d'avoir accepté d'être examinateurs de ce travail.

J'adresse aussi mes remerciements à Mme.Sameh Chargui (Laboratoire de Géoressources, Centre de Recherches et des Technologies des Eaux (CERTÉ)), Mme.Haïfa Feki (Université de Carthage, Laboratoire Gestion intégrée des RESSOURCES Naturelles : TELÉDÉTECTION, Analyse spatiale et Modélisation (GREEN-TEAM)) et M.Radhouane Hamdi (Ingénieur hydrologue à l'Institut de Recherche pour le Développement (IRD)) pour leur précieuse contribution à travers les discussions enrichissantes et le partage d'informations.

L'appui financier du programme ARTS (Allocations de recherche pour une thèse au Sud), lancé par l'IRD, a été d'une importance capitale pour la réalisation de cette recherche. Ce programme a facilité les échanges et les mobilités Sud-Nord, renforçant ainsi la collaboration entre les institutions et contribuant à l'enrichissement des résultats de la thèse.

J'exprime également ma gratitude envers l'ensemble des doctorants et chercheurs avec lesquels j'ai eu le privilège de partager des moments chaleureux au sein d'HSM et COSIM. Je tiens tout particulièrement à mentionner Nesrine Farhani et Syrine Chouba, dont la présence a grandement contribué à rendre mes séjours à Montpellier agréables. Ces moments de convivialité ont non seulement renforcé mon réseau académique, mais ont également ajouté une dimension humaine et mémorable à mon expérience de recherche. Je suis reconnaissante pour leur générosité et leur amitié.

Je souhaite exprimer du fond du cœur, ma sincère reconnaissance envers ma famille, en particulier mes parents, Amjed et Nahla, ma sœur, Olfa, mon mari, Hatem Chebbi, ma belle-famille Ali, Amel et Marwen. Leur soutien permanent a été un pilier fondamental de la réussite de ce projet de thèse. Ils m'ont encouragé sans relâche, m'ont apporté la force lors de mes moments de faiblesse et la confiance lors de mes moments de doute. Je vous remercie d'avoir toujours cru en moi et de m'avoir toujours encouragé à aller de l'avant.

Cette thèse représente le fruit de l'effort collectif et du soutien généreux de nombreuses personnes. Je vous remercie pour avoir fait partie de ce projet et pour avoir contribué à sa réussite.

Résumé

Les pays du pourtour méditerranéen font face à des épisodes d'inondations causés par des événements de précipitations extrêmes. Ces événements peuvent causer des dégâts matériels considérables, des perturbations socio-économiques et des dommages environnementaux, soulignant la nécessité de mieux gérer ces risques. Dans ce but, l'objectif principal de cette thèse est de développer une modélisation des intensités journalières des précipitations, en tenant compte de la non-stationnarité spatiale et des événements extrêmes.

Pour prendre en compte la non-stationnarité spatiale des distributions de précipitations extrêmes, les paramètres des valeurs extrêmes généralisées (GEV) ont été modélisés en fonction des covariables. Cette modélisation s'appuie sur des approches statistiques, initialement en comparant un modèle linéaire généralisé (GLM) à un réseau de neurones artificiels (ANN) de type Feed-Forward. Le choix du nombre de neurones cachés, de covariables, ainsi que d'hyperparamètres d'apprentissage, est déterminante pour une modélisation optimale de la fréquence d'occurrence d'un événement de pluie extrême. De plus, la distribution des pluies positives, qu'elles soient extrêmes ou non, a été élaborée à travers la loi de Pareto généralisée étendue (EGPD), proposée par (Naveau et al., 2016), en utilisant un seuil de censure adéquat pour les pluies positives.

L'application de ces méthodes se base sur des séries de données pluviométriques journalières, intégrant des observations in situ et des produits satellitaires, collectées dans des sites d'études situés autour de la Méditerranée : la région de la Méditerranée française, la région du Cap Bon au nord-est de la Tunisie, et la région du Merguellil au centre de la Tunisie. La modélisation spatiale a impliqué l'obtention des cartes de niveaux de retour sur une période de retour 100 ans pour chaque site, ainsi que l'identification des covariables spatiales pour prendre en compte la complexité du climat méditerranéen. La comparaison entre le GLM et l'ANN a démontré l'efficacité de cette dernière pour obtenir un modèle plus appropriée sur plus de 60% des stations. En résumé, cette thèse apporte une contribution significative à la compréhension et à la gestion des risques liés aux précipitations extrêmes dans la région méditerranéenne, permettant de simuler à haute résolution spatiale des valeurs reproduisant le comportement aléatoire des précipitations.

Mots-clés : précipitations extrêmes, non-stationnarité spatiale, la théorie des valeurs extrêmes, réseaux de neurones artificiels, modèles linéaires généralisés.

Abstract

Countries around the Mediterranean are confronted with episodes of flooding caused by extreme precipitation events. These phenomena can cause significant material damage, socio-economic disruption and environmental damage, underlining the need for improved risk management. To address this, the main objective of this thesis is to develop a model for daily precipitation intensities, taking into account spatial non-stationarity and extreme events.

To account for the spatial non-stationarity of extreme distributions, the parameters of Generalized Extreme Value (GEV) distributions have been modeled based on covariates. This modeling relies on statistical approaches, initially comparing a Generalized Linear Model (GLM) to a Feed-Forward Artificial Neural Network (ANN). The selection of the number of hidden neurons, covariates, and learning hyperparameters is crucial for optimal modeling of the frequency of extreme rainfall events. Additionally, the distribution of positive rainfall, whether extreme or not, has been developed using the Extended Generalized Pareto Distribution (EGPD) proposed by (Naveau et al., 2016), employing an appropriate censoring threshold for positive rainfall.

These methods have been applied using daily precipitation datasets that integrate in situ observations and satellite products collected from study sites around the Mediterranean : the region of French Mediterranean, the Cap Bon region in northeast Tunisia, and the Merguellil region in central Tunisia. Spatial modeling involved obtaining return level maps over a 100-year return period for each site and identifying spatial covariates to address the complexity of the Mediterranean climate. A comparison between GLM and ANN highlighted the effectiveness of the latter in obtaining a more suitable model for over 60% of the stations. In summary, this thesis makes a significant contribution to understanding and managing risks associated with extreme precipitation in the Mediterranean region, enabling high-resolution spatial simulation of values that reproduce the random behavior of rainfall.

Keywords : extreme precipitation events, spatial non-stationarity, extreme value theory, artificial neural networks, generalized linear models.

Table des matières

1	Introduction	1
1.1	Contexte général et problématique	1
1.2	Les précipitations sur le pourtour méditerranéen	5
1.2.1	Contexte géographique et climatique de la région méditerranéenne	5
1.2.2	Sélection des sites d'études pour l'analyse des précipitations	6
1.3	Généralités sur les précipitations	9
1.3.1	Processus physiques à l'origine de la formation des précipitations	9
1.3.2	Techniques de mesure de pluie	10
1.4	Modélisation statistique des précipitations	13
1.4.1	Modélisation des intensités de précipitations extrêmes	15
1.4.2	Modélisation de la distribution complète des précipitations	16
1.4.3	Modélisation de la non-stationnarité spatiale	17
1.5	Objectifs de la thèse	20
1.6	Organisation du manuscrit	21
2	Analyse exploratoire des données	22
2.1	Introduction	22
2.2	Présentation des sites d'étude	22
2.2.1	La région de la Méditerranée française	22
2.2.2	La région du Merguellil, Tunisie centrale	28
2.2.3	La région du Lebna, Cap Bon, Tunisie	33
2.3	Base de données CHIRPS	36
2.4	Comparaison des trois sites d'étude	37
2.5	Synthèse	39
3	Modélisation des intensités de précipitations ponctuelles extrêmes	40
3.1	Introduction	40
3.2	Théorie des valeurs extrêmes	41
3.2.1	Approche des maxima par blocs	41

3.2.2	Approche des dépassements de seuils	43
3.3	Tests d'adéquation	46
3.3.1	Test de Kolmogorov-Smirnov	46
3.3.2	Les graphiques quantiles-quantiles	47
3.4	La loi de Pareto généralisée étendue (EGPD)	47
3.5	Synthèse	50
4	Modélisation de la non-stationnarité spatiale avec les réseaux de neurones	51
4.1	Introduction	51
4.2	Notion de la non-stationnarité spatiale	51
4.3	Théorie des réseaux de neurones artificiels	52
4.3.1	Architecture du réseau de neurones	53
4.3.2	Apprentissage du réseau de neurones	55
4.3.3	Procédure de validation pour la sélection du niveau de complexité, sous-apprentissage et sur-apprentissage	58
4.3.4	Rôle des unités cachées	60
4.3.5	Saturation des unités cachées	61
4.4	Comparaison avec un modèle linéaire généralisé	62
4.5	Synthèse	63
5	Article : Smooth spatial modeling of extreme Mediterranean precipitation	64
5.1	Résumé de l'article	64
5.2	Résultats complémentaires	83
5.2.1	Choix des covariables et du niveau de complexité	83
6	Modélisation des intensités de précipitations ordinaires et extrêmes	86
6.1	Introduction	86
6.2	Modélisation des valeurs extrêmes avec la GPD	87
6.3	Application de l'EGPD sur les données de précipitations	89
6.3.1	Cas de la région de la Méditerranée Française	89
6.3.2	Cas du Merguellil, Tunisie	94
6.3.3	Cas du Cap Bon, Tunisie	95
6.3.4	Inter-comparaison entre les trois sites d'étude	97
6.4	Synthèse	98
7	Conclusions et perspectives	99
	Annexe	104
	Bibliographie	107

Table des figures

1	Le nombre moyen de victimes d'inondations déclarées par pays et par an pendant la période de 1940 à 2015, selon les données d'EM-DAT (source : http://www.emdat.be/).	2
2	Précipitations moyennes cumulées (en mm) par saison humide (septembre à avril) pour la période 1950-2013 sur le bassin méditerranéen (Raymond et al., 2016)	6
3	Fréquence d'apparition des épisodes avec plus de 200 mm en 1 jour, pour la période du 1972 à 2021 en France (source : http://pluiesextremes.meteo.fr , édition du 01/02/2022)	7
4	Démarche de la modélisation globale de la thèse.	21
5	Localisation de la zone choisie située dans la région de la Méditerranée française.	23
6	Typologie climatique du territoire français en 8 classes (Joly et al., 2010) : 1.climat de montagne, 2.climat semi-continentale et des marges montagnardes, 3.climat océanique dégradé des plaines du Centre et du Nord, 4.climat océanique altéré, 5.climat océanique franc, 6.climat méditerranéen altéré, 7.climat du Bassin du Sud-Ouest, 8.climat méditerranéen franc.	24
7	Identification des stations dans la région de la Méditerranée française sous un climat méditerranéen.	25
8	Boxplots des cumuls mensuels moyens des précipitations sur toute la période d'étude pour la région de la Méditerranée française. La courbe rouge indique la moyenne pour chaque mois.	26
9	La carte de la moyenne des cumuls annuels sur la saison des pluies pour les 183 stations conservées pour l'étude dans la région de la Méditerranée française.	27
10	La carte de la moyenne des maxima annuels sur la saison des pluies pour les 183 stations conservées pour l'étude dans la région de la Méditerranée française.	28
11	La carte des maxima atteints en une journée pour les 183 stations conservées pour l'étude dans la région de la Méditerranée française.	28
12	Localisation de la zone choisie située dans la région de la Tunisie centrale. Les points noirs indiquent les 26 stations conservées pour l'étude et les lignes bleues délimitent le bassin versant.	29

13	Carte bioclimatique de la Tunisie (Zitouna-Chebbi, 2009).	30
14	Boxplots des cumuls mensuels moyens des précipitations sur toute la période d'étude au Merguellil, Tunisie. La courbe rouge indique la moyenne pour chaque mois.	31
15	La carte de la moyenne des cumuls annuels sur la saison des pluies pour les 26 stations conservées pour l'étude au Merguellil, Tunisie.	32
16	La carte de la moyenne des maxima annuels sur la saison des pluies pour les 26 stations conservées pour l'étude au Merguellil, Tunisie.	32
17	La carte des maxima atteints pour les 26 stations conservées pour l'étude au Merguellil, Tunisie.	33
18	Localisation de la zone choisie située dans la région du Cap Bon, Tunisie.	33
19	Boxplots des cumuls mensuels moyens des précipitations sur toute la période d'étude au Cap Bon, Tunisie. La courbe rouge indique la moyenne pour chaque mois.	34
20	La carte de la moyenne des cumuls annuels sur la saison des pluies pour les 18 stations conservées pour l'étude au Cap Bon, Tunisie.	35
21	La carte de la moyenne des maxima annuels sur la saison des pluies pour les 18 stations conservées pour l'étude au Cap Bon, Tunisie	35
22	La carte des maxima atteints pour les 18 stations conservées pour l'étude au Cap Bon, Tunisie.	36
23	Histogrammes de comparaison d'altitudes pour les trois sites d'étude.	38
24	Comparaison des précipitations saisonnières moyennes des données CHIRPS avec celles observées par les pluviomètres pour les trois sites d'étude.	39
25	Données de précipitations journalières observées à la station de Montpellier en mm/jour entre 2016 et 2019. Les lignes en pointillés représentent à gauche les blocs annuels et à droite le seuil fixé à 60mm.	40
26	Fonctions de répartition de la GEV pour $\mu = 0, \sigma = 1, \xi = (-0.4, 0, 0.4)$	42
27	Fonctions de répartition des lois de valeurs extrêmes généralisées pour $\sigma = 1$ et $\xi = (-0.4, 0, 0.4)$	44
28	Le graphique quantile-quantile de la distribution EGPD (avec le modèle 1) et la distribution Gamma ajustée pour les observations positives de précipitations journalières (>1mm) à la station Montpellier.	49
29	Représentation d'un neurone formel.	53
30	Représentation d'un réseau de neurones à une couche cachée.	53
31	Graphe de la fonction tangente hyperbolique	54

32	Vue géométrique de la fonction d'erreur $E(w)$ en tant qu'une surface sur l'espace des poids. Le point W_A est un minimum local et W_B est le minimum global. En tout point W_C , le gradient local de la surface d'erreur est donné par le vecteur ∇E (Bishop, 2006).	57
33	Schéma de la validation croisée K-fold, avec K=10	59
34	Courbes de l'erreur sur l'ensemble d'entraînement et l'ensemble de validation en augmentant la complexité du modèle ANN.	60
35	Le rôle du nombre d'unités cachées nh dans l'ajustement d'un ANN sur un exemple de fonction sinus. Allant de gauche à droite : $nh=\{2,3,4\}$	61
36	Résultat de l'ajustement d'un sinus, avec les données d'entrée non transformées (figure à gauche) et avec des données d'entrée centrées réduites (figure à droite).	61
37	La structure d'un GLM.	62
38	Résultat des courbes de la validation croisée avec le modèle ANN pour le site du Merguellil.	84
39	Résultat des courbes de la validation croisée avec le modèle ANN pour le site du Cap Bon.	85
40	Boxplots des estimations des niveaux de retour 100 ans avec la GEV et la GPD pour les trois sites d'étude.	88
41	Comparaison des estimations des paramètres de forme et les calculs des niveaux de retour 100 ans avec la GEV et la GPD pour les trois sites d'étude.	88
42	Boxplot des valeurs de critères de Nash-Sutcliffe, en variant le seuil de censure pour l'ajustement EGPD (1mm, 2mm, 5mm), pour les stations sur le site de la Méditerranée Française.	89
43	Localisation des stations de tests (les points en rouge) sur le site de de la Méditerranée Française.	90
44	Graphiques quantiles-quantiles sur les 6 stations de tests. Les points rouges correspondent aux modèles EGPD avec un seuil de 1mm, tandis que les points bleus représentent les modèles avec une censure de 5mm.	90
45	Comparaison des valeurs du critère NSE les plus proches de 1 pour les modèles EGPD et Gamma, en utilisant une censure des données à 1mm à gauche et une censure à 5mm à droite.	91
46	Nombre moyen d'observations (>5mm) par saison des pluies et par station, pour le site de la Méditerranée Française.	92
47	Graphiques quantiles-quantiles sur les 6 stations de tests, après la sélection des seuils de censure de l'EGPD établis selon le critère NSE. Les seuils correspondants pour chaque station, de 1 à 6, sont respectivement de 7, 5, 2, 10, 3 et 10 mm.	93

48	Le niveau de retour 100 ans avec l'ajustement de l'EGPD, sur le site de la Méditerranée Française.	93
49	Localisation des stations de tests (les points en rouge) sur le site du Merguellil, Tunisie.	94
50	Graphiques quantiles-quantiles pour 2 stations de tests, après la sélection du seuil de censure de l'EGPD établi selon le critère NSE. La valeur de seuil pour la station 1 est de 4 mm, tandis que pour la station 2, elle est de 2 mm.	95
51	Le niveau de retour 100 ans avec l'ajustement de l'EGPD, au Merguellil, Tunisie.	95
52	Localisation des stations de tests (les points en rouge) sur le site du Cap Bon, Tunisie.	96
53	Graphiques quantiles-quantiles sur 2 stations de tests, après la sélection du seuil de censure de l'EGPD établis selon le critère NSE. La valeur de seuil pour la station 1 est de 2 mm, tandis que pour la station 2, elle est de 6 mm.	96
54	Le niveau de retour 100 ans avec l'ajustement de l'EGPD, sur le Cap Bon, Tunisie.	97
55	Cartes des estimations ponctuelles du niveau de retour 100 ans avec ajustement de l'EGPD censurée pour trois sites d'étude (Méditerranée Française, Merguellil, Cap Bon) et comparaison avec les résultats de la GEV.	98

Liste des tableaux

2.1	Comparaison des caractéristiques des trois sites d'étude.	37
6.1	Récapitulatif des valeurs de seuil et du nombre de dépassements pour les trois sites d'étude.	87

Introduction

Dans ce premier chapitre, on commence par présenter le contexte général et identifier la problématique abordée dans cette thèse. On s'intéresse particulièrement à l'analyse des événements hydrométéorologiques dans la région du bassin méditerranéen (Section 1.1). Cette zone géographique est souvent confrontée à des risques de catastrophes naturelles, notamment les inondations. En raison de sa topographie singulière et de l'influence de plusieurs facteurs climatiques à différentes échelles (locale, régionale et globale), cette région est souvent soumise à des événements de précipitations extrêmes (Section 1.2). Par la suite, des notions générales sur les précipitations sont présentées, y compris les processus physiques à l'origine de leur formation ainsi que les différentes techniques de mesure (Section 1.3). La section suivante (Section 1.4) nous conduit à une revue de la littérature portant sur les approches de modélisation statistique des précipitations. Cette revue explore diverses approches visant à modéliser à la fois les événements de précipitations extrêmes, la distribution complète des précipitations et la non-stationnarité spatiale. Enfin, les objectifs spécifiques de cette thèse sont décrits dans la Section 1.5, en soulignant les contributions que nous souhaitons apporter. Ce chapitre se termine par un aperçu de l'organisation du reste du manuscrit (Section 1.6).

1.1 Contexte général et problématique

Les inondations comptent parmi les événements catastrophiques d'origine naturelle les plus fréquents avec des conséquences souvent dévastatrices. Elles représentent 44% de toutes les catastrophes signalées à l'échelle mondiale au cours des deux dernières décennies ([Mizutori and Guha-Sapir, 2020](#)). Les fortes précipitations, étant la principale cause des inondations, se produisent souvent de manière soudaine avec peu ou pas de signes préalables. Elles sont des phénomènes difficiles à prévoir en raison de leur nature aléatoire, ce qui complique leur évaluation et leur gestion. En effet, le risque d'inondations est amplifié par la fréquence d'occurrence élevée de l'aléa et par les enjeux associés à la présence humaine (infrastructures, biens, etc.) décrivant la vulnérabilité d'un territoire ([Provitolo, 2007](#); [Fujiki and Finance, 2022](#)). Par conséquent, le risque résulte de la conjonction entre la vulnérabilité d'un territoire et la fréquence

élevée des occurrences du phénomène aléatoire (Newton and Weichselgartner, 2014).

Les pays du pourtour méditerranéen sont particulièrement vulnérables aux inondations (Llasat et al., 2010; Gaume et al., 2016; Khodayar et al., 2021). Les crues éclair sont beaucoup plus fréquentes dans cette région que dans le reste de l'Europe (Gaume et al., 2009). Pour ne citer que quelques éléments de l'histoire d'événements catastrophiques, rappelons par exemple les inondations qui ont touché la Tunisie en septembre 1969 (Poncet, 1970), la ville de Gênes en Italie en octobre 1970 (Siccardi, 1996), la commune française Vaison-la-Romaine en septembre 1992 (Vinet et al., 2016) et l'Algérie en novembre 2001 (Djellouli and Saci, 2003). De nombreux dégâts matériels et humains, ainsi que des menaces de perturbation des écosystèmes terrestres et océaniques, ont été signalés après ces événements. Certaines activités, comme l'agriculture, sont de plus en plus vulnérables et subissent de graves répercussions en cas d'inondation (Brémond et al., 2013; Alazard et al., 2015). Les fortes pluies et la montée des eaux peuvent endommager les systèmes d'irrigation, détruire les cultures, emporter les terres et même ruiner des récoltes entières. En outre, l'impact sur le bien-être humain est significatif en raison de l'urbanisation massive et de la croissance démographique. En effet, selon la base de données MEFF DB (*Mediterranean Flood Fatality Database*) sur les décès liés aux inondations en Méditerranée entre 1980 et 2018, une personne par million d'habitants meurt en moyenne tous les deux ans à cause de ces événements dans certains pays du bassin méditerranéen (Vinet et al., 2019). Le taux de mortalité diminue de l'ouest à l'est de la Méditerranée, avec notamment un taux proche de 1 dans le sud de la France. Selon la base de donnée internationale sur les catastrophes EM-DAT (*Emergency Events Database*), les pays ayant le plus grand nombre de décès liés aux inondations dans la région méditerranéenne sont l'Algérie, l'Italie, le Maroc, l'Espagne, la Tunisie, et la France (voir Figure 1).




FIGURE 1 – Le nombre moyen de victimes d'inondations déclarées par pays et par an pendant la période de 1940 à 2015, selon les données d'EM-DAT (source : <http://www.emdat.be/>).

Face aux événements catastrophiques antérieurs, il devient crucial d'adopter des politiques préventives efficaces afin de réduire les éventuels dommages causés par les inondations et les crues associées. Un certain nombre de mesures ont été progressivement développées et mobilisées par les acteurs de la prévention. Sur le plan technique, la construction et la gestion de divers ouvrages hydrauliques (e.g. barrages et systèmes de rétention) permettent de retenir l'accumulation des précipitations de façon temporaire (Ciampa et al., 2021). Ces aménagements, très coûteux à construire et à entretenir, ne peuvent être efficaces que si elles sont bien conçues et surtout bien situées. Un cadre global de gestion des risques doit permettre de localiser les régions qui seront touchées par l'inondation, en tenant compte des différents facteurs impliqués. Par conséquent, la cartographie des zones susceptibles d'être inondées est d'une importance primordiale. Cette information est utilisée par les autorités afin d'élaborer des plans d'intervention d'urgence et d'orienter les stratégies de prévention des risques.

Un défi majeur pour les études sur les risques d'inondation est de disposer d'estimations fiables basées sur des données enregistrées d'événements passés. La disponibilité de telles données est souvent limitée, comme les observations hydrologiques, les crues historiques et les relevés topographiques (Kourgialas and Karatzas, 2017). Toutes ces informations sont plus rares dans les bassins versants peu ou pas jaugés, où les observations sont absentes ou insuffisantes à différentes échelles spatiales et temporelles. En effet, les précipitations peuvent être relativement ponctuelles et ne concerner qu'une petite partie de l'espace, ou se produire sur une étendue plus vaste. Leurs intensités peuvent être très variables dans l'espace, comme ils dépendent d'un certain nombre de facteurs. Ainsi, le phénomène peut passer inaperçu dans une région et être de grande ampleur ailleurs. Par conséquent, la compréhension des processus liés aux événements de précipitation est un prérequis essentiel pour évaluer le risque associé en tout point du territoire. Une connaissance rigoureuse de ces mesures est d'une grande importance, notamment dans les pays arides où l'eau est au cœur de toute l'économie agricole et où les précipitations déterminent les prévisions d'irrigation.

La littérature actuelle offre une diversité de modèles visant à fournir des informations essentielles pour l'analyse des risques hydrologiques, avec une attention particulière accordée aux modèles à base physique. Ces modèles peuvent reproduire le comportement des précipitations extrêmes en se basant sur une compréhension approfondie des processus physiques sous-jacents, incluant des variables hydrométéorologiques telles que les précipitations, la température, le vent, l'humidité de l'air, et le rayonnement (e.g. Boulet et al., 2015). Dans ce cas, la simulation est exprimée à l'aide d'équations dérivées de la nature physique des précipitations, nécessitant des données d'entrée telles que l'utilisation des sols, la topographie et les structures hydrauliques. Ces données sont mesurées aux différents sites instrumentés de la zone d'étude ou obtenues à partir des données de télédétection (Pavesi et al., 2022). Cependant, il est nécessaire de restreindre les modèles en les soumettant à des scénarios de forçage climatique qui intègrent la variabilité spatiale à l'intérieur de la zone d'étude en simulant les variables hydrométéorologiques de manière multi-locale, par exemple sur une grille couvrant la zone d'étude. Des

modèles climatiques régionaux, basés sur la résolution d'équations physiques, peuvent fournir de tels scénarios (Caillaud et al., 2021). Or, le temps de calcul de ces modèles est important en raison du nombre élevé de données d'entrée et de la complexité des paramètres. En plus, la collecte et la gestion de ces données peuvent être laborieuses et coûteuses, limitant souvent l'applicabilité de ces modèles dans des régions où ces informations sont rares ou difficiles à obtenir. En outre, il est possible que ces modèles ne représentent pas de manière exhaustive la réalité en raison des connaissances limitées sur les processus physiques liés à la génération des inondations. Ces limitations entraînent une incertitude significative, rendant l'utilisation de ces modèles à grande échelle peu pratique. Par conséquent, cette thèse se concentre plutôt sur les modèles statistiques, qui peuvent constituer une alternative plus flexible et efficace pour évaluer le risque d'inondation. Ils offrent l'avantage d'une modélisation nécessitant relativement moins de données d'entrée et présentant un coût de calcul plus faible (Moseley et al., 2019) (voir Section 1.4).

Dans le cadre méditerranéen, la modélisation statistique des phénomènes hydrologiques rencontre plusieurs difficultés, principalement en raison de la grande variabilité spatiale et temporelle des précipitations. Cette variabilité est particulièrement marquée à des échelles spatiales de l'ordre de quelques kilomètres et sur des intervalles de temps correspondant au cumul journalier. En effet, les conditions météorologiques spécifiques à la région méditerranéenne, caractérisées par des précipitations irrégulières, rendent complexe la création de modèles statistiques fiables pour la prédiction des phénomènes hydrologiques dans cette région. Cette complexité est accentuée par des facteurs tels que le relief prononcé, les influences maritimes et désertiques qui varient en fonction des champs de vents. De plus, les configurations instrumentales sont souvent caractérisées par une faible densité de stations de mesure, des périodes d'observation courtes et souvent non-concomitantes pour les différentes variables hydrométéorologiques. Les modèles hydrologiques globaux sont généralement déployés à des échelles relativement larges (à l'ordre de 0,5 à 1 km) (Bierkens et al., 2015). Cependant, les modèles hydrologiques à l'échelle régionale exigent généralement des résolutions plus fines, peu étudiées jusqu'à présent, afin de mieux représenter les détails locaux des différentes zones (Cavicchia et al., 2018; Adewoyin et al., 2021).

Par conséquent, l'objectif principal de cette recherche est de développer un modèle spatial pour les précipitations journalières en tenant compte de la complexité du milieu méditerranéen. Pour cela, deux axes majeurs sont traités. Le premier axe repose sur la caractérisation des pluies extrêmes en un point spécifique, et plus largement, sur une surface pour créer de l'information spatialisée là où elle n'existe pas. Le deuxième axe porte sur la caractérisation simultanée des pluies ordinaires et extrêmes. Avant de pouvoir répondre à cette problématique, il est essentiel de fournir des éléments clés concernant le contexte géographique et climatique de la zone d'étude, ainsi qu'une explication du processus sous-jacent aux inondations (voir Section 1.2).

1.2 Les précipitations sur le pourtour méditerranéen

1.2.1 Contexte géographique et climatique de la région méditerranéenne

Le bassin méditerranéen est la région géographique qui couvre la mer Méditerranée et les territoires qui l'entourent. La mer intercontinentale et semi-fermée, se trouve dans une zone de transition entre une masse d'air froid venant du nord et une masse d'air chaud venant du sud. Elle est confinée entre un régime de circulation atmosphérique de moyenne latitude et un régime subtropical (Lionello et al., 2006). Le climat méditerranéen se caractérise par des hivers tempérés et humides, et des étés chauds et secs (Seager et al., 2019). Les régions qui ont un climat méditerranéen typique sont généralement les régions côtières, plus chaudes et plus humides que les régions intérieures. Une variation climatique considérable existe dans d'autres régions en fonction de la géographie, de l'altitude, des champs de vents et des influences climatiques locales. Il est donc important de noter que la définition du climat méditerranéen ne s'applique pas de manière uniforme à toutes les régions du pourtour de la mer Méditerranée.

Une caractéristique spécifique de cette zone est le contraste marqué entre les différentes régions en raison d'une morphologie complexe. Cela est dû à la présence de nombreux éléments orographiques, comme les chaînes de montagnes de différentes hauteurs (comme l'Atlas, les Pyrénées, les Alpes, les Balkans, etc.) et le vaste désert qui traverse l'Afrique (Cramer et al., 2018). Les chaînes de montagnes peuvent bloquer les vents, influencer les températures et les précipitations, créant ainsi des microclimats qui varient considérablement en fonction de l'altitude. Par exemple, les régions montagneuses peuvent avoir des températures plus faibles et des précipitations plus élevées que les régions côtières, tandis que les régions désertiques peuvent avoir des températures plus élevées et des précipitations plus faibles. Par exemple, selon (Zittis et al., 2021) pour la partie nord du bassin méditerranéen, les précipitations annuelles dépassent souvent les 1000 mm/an. Dans des zones spécifiques telles que les régions de haute altitude, les pentes exposées au vent, et les zones côtières, ces précipitations peuvent même atteindre des valeurs aussi élevées que 3000 mm/an. D'autre part, dans les parties arides et semi-arides de l'Afrique du Nord et du Moyen-Orient, les précipitations annuelles se limitent généralement à moins de 200 mm/an.

La région est influencée non seulement par le relief, mais également par la présence de la mer. Il existe de forts contrastes terre-mer qui exercent une influence significative sur les conditions climatiques. Les zones côtières peuvent avoir des températures plus faibles et plus humides en raison de l'influence des courants maritimes. Certains pays n'ont qu'un littoral méditerranéen réduit (comme la France) ou n'ont même aucune côte méditerranéenne (comme la Jordanie ou le Portugal). Il convient également de noter que d'autres régions du monde, ne se trouvant pas sur le pourtour méditerranéen, sont caractérisées par ce climat. Ces régions sont généralement situées aux mêmes latitudes et présentent des conditions climatiques assez semblables (la Cali-

forne, le centre du Chili, la région du Cap en Afrique du Sud, le Sud et l’Ouest de l’Australie). En effet, les cumuls moyens de précipitation par saison humide dans la région présentent des variations géographiques, avec des valeurs plus élevées dans les pays du nord par rapport aux pays du sud (voir Figure 2). Cette répartition s’explique principalement par l’influence des circulations atmosphériques aux larges échelles. Certains secteurs nord-méditerranéens, tels que l’est de l’Espagne, sont protégés des vents d’ouest (effet dit "sous le vent"), expliquant ainsi le faible cumul des précipitations observé par saison (Raymond et al., 2016). Cette variation est également saisonnière à petite échelle : les zones côtières peuvent recevoir des précipitations sur une longue période, tandis que les zones intérieures peuvent être soumises à des périodes de sécheresse prolongées (Vogel et al., 2021).




FIGURE 2 – Précipitations moyennes cumulées (en mm) par saison humide (septembre à avril) pour la période 1950-2013 sur le bassin méditerranéen (Raymond et al., 2016)

1.2.2 Sélection des sites d’études pour l’analyse des précipitations

Dans le cadre de cette thèse, nous nous intéressons à trois régions représentatives du climat méditerranéen avec un gradient d’aridité nord-sud : un site sur l’arc méditerranéen français, mis à disposition par Météo-France, ainsi que deux autres sites en Tunisie affiliés au projet LMI NAILA (*Le Laboratoire Mixte International de gestioN des ressources en EAu dans les mILieux rurAux tunisiens*) et fournis par la Direction Générale des Ressources en Eau (DGRE). Ce choix nous permettra de comparer notre approche sur ces trois régions afin de voir si les performances des méthodes sont dépendantes du site. Une description plus détaillée des sites étudiés et des caractéristiques correspondantes est présentée dans le Chapitre 2.

Au cours de son histoire, la région de la Méditerranée française a connu plusieurs inondations violentes causées par des événements pluvieux intenses. Ces événements se produisent principalement en automne, lorsque l’air en altitude se refroidit plus vite que la mer est encore chaude, favorisant ainsi l’évaporation (Mariotti et al., 2002; Brunet et al., 2018). Ces épisodes donnent lieu à des orages de courte durée, avec de fortes précipitations localisées, déclenchés sous l’ef-

1.2. Les précipitations sur le pourtour méditerranéen

fet de l'humidité générée par la mer, des creux d'altitude froids venant du nord et des reliefs prononcés des régions voisines (Delrieu et al., 2005). Cette région est spécialement caractérisée par des intensités pluviométriques plus élevées par rapport au reste du pays. Les départements du Gard et de l'Ardèche connaissent en moyenne au moins un épisode par an avec plus de 200 mm par jour (voir Figure 3). Cette fréquence d'événements explique le risque important d'inondation dans la région, comme les inondations au département de l'Aude en 1999 (Neppel et al., 2001) ou au département du Gard en 2002 (Neppel et al., 2003; Gaume and Bouvier, 2004). Cette région étant sujette à des événements extrêmes, l'INSU-CNRS (*Institut National des Sciences de l'Univers*) et l'OSUG (*Observatoire de Sciences de l'Univers de Grenoble*) ont créé l'OHMCV (*Observatoire Hydro-Météorologique Cévennes-Vivarais*) (Delrieu, 2003) chargé de mener des études sur les précipitations extrêmes et les crues soudaines. Ces dernières années, le programme international de recherche HyMeX (*Hydrological Cycle in the Mediterranean Experiment*) a été mis en place dans le but de mieux comprendre le cycle hydrologique dans les régions méditerranéennes et d'améliorer la prévision des risques hydrométéorologiques (Drobinski et al., 2014; Ducrocq et al., 2019).

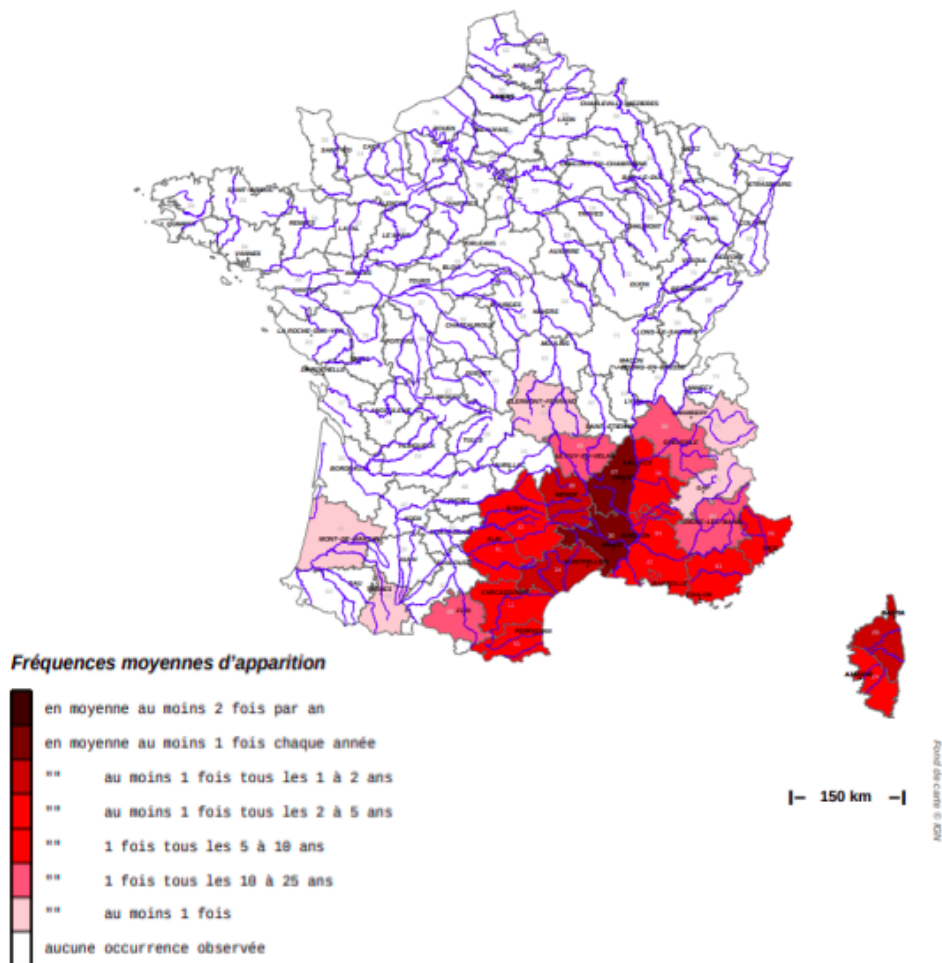


FIGURE 3 – Fréquence d'apparition des épisodes avec plus de 200 mm en 1 jour, pour la période du 1972 à 2021 en France (source : <http://pluiesextremes.meteo.fr>, édition du 01/02/2022)

Le deuxième site d'étude est le bassin versant de Merguellil, situé au centre de la Tunisie. Il est caractérisé par un climat semi-aride avec une forte variabilité des précipitations ainsi que des sécheresses récurrentes. La région connaît de violents orages convectifs, en particulier à l'automne et au printemps. Les pluies résultants de ces orages sont liées à une humidité relativement faible en été, assez élevée en hiver, ainsi qu'à des températures fortement continentales à grande amplitude (Slimani et al., 2007). Ce bassin versant est représentatif de nombreux problèmes que l'on retrouve ailleurs dans le bassin méditerranéen, notamment les problèmes de répartition inégale des ressources en eau. Il s'agit principalement d'une région à dominante rurale et agricole de premier ordre, englobant des cultures très diversifiées telles que les cultures maraîchères et fruitières (agrumes, vignes, oliviers, etc.). La menace de pénurie d'eau a entraîné une détérioration considérable de l'activité agricole et de l'approvisionnement en eau potable. Depuis la fin des années 1980, plusieurs politiques de mobilisation pour la conservation de l'eau ont été mises en œuvre pour améliorer la gestion des ressources hydriques, y compris la construction de barrages et de systèmes d'irrigation. Un dispositif de mesure des variables hydrologiques est installé sur la région faisant partie d'une convention de recherche entre le ministère de l'agriculture tunisien et l'Institut de Recherche pour le Développement (IRD). Cette région revêt un intérêt significatif en tant que sujet d'investigation pour de nombreux projets de recherche (Leduc et al., 2007; Kingumbi et al., 2007; Alazard et al., 2015; Ogilvie et al., 2016).

Le troisième site est localisé dans le Nord-Est de la Tunisie. Le bassin versant de Lebna est l'un des bassins versants de la partie orientale du Cap Bon. Il fait partie d'un réseau de 27 bassins versants surveillés dans le cadre d'une convention avec le Ministère de l'agriculture de la Tunisie. Dans la partie sud du bassin, un barrage a été construit à la jonction des rivières El Ouedyenne et Bou Dokhane. Il s'agit du plus grand barrage du Cap Bon, situé à environ trois kilomètres de la mer, avec une capacité initiale de 30 millions de m³. Plusieurs retenus collinaires ont été créés en amont du barrage, comme le sous-bassin versant de Kamech (une superficie de 2.63 km² et une capacité d'environ 142000 m³) qui est un site expérimental de l'observatoire de recherche environnementale OMERE (*Observatoire Méditerranéen de l'Environnement Rural de l'Eau*, <https://www.obs-omere.org/>, décrite en détail dans (Molénat et al., 2018)), co-piloté par l'UMR LISAH Montpellier SupAgro-INRA-IRD, l'UMR Hydrosociétés CNRS-IRD-Université Montpellier II, l'INRGREF (*Institut National de la Recherche en Génie Rural, Eaux et Forêts de Tunisie*) et l'INAT (*Institut National Agronomique de Tunisie*). En ce qui concerne le climat, la partie la plus éloignée en amont du bassin connaît un climat méditerranéen humide, tandis que le centre du bassin présente un climat subhumide, et la partie en aval affiche un climat semi-aride. En septembre 2018, cette région a été frappée par des précipitations violentes, provoquant de graves inondations. En cinq heures, environ un tiers des précipitations annuelles moyennes ont été enregistrées. Les précipitations les plus fortes ont été observées à Béni Khalled (297 mm) (Jaouadi, 2019). L'intérêt porté à l'étude et à la gestion des ressources en eau de cette région fait actuellement l'objet de nombreuses recherches.

Parmi les exemples, une étude de la variabilité temporelle et spatiale de l'humidité du sol a été menée dans (Mekki et al., 2018), une évaluation des aspects liés aux tendances des extrêmes pluviométriques est présente dans (Chargui et al., 2022), une investigation de l'origine et les processus de salinisation des eaux souterraines dans l'aquifère côtier a été menée dans (Ziadi et al., 2019). La description du bassin versant fut détaillée dans le cadre de plusieurs autres études (e.g. (Mekki, 2003; Zitouna Chebbi et al., 2014)). À titre d'exemple, une étude sur la variabilité temporelle et spatiale de l'humidité du sol a été réalisée dans (Mekki et al., 2018). Une évaluation des tendances des extrêmes pluviométriques est présentée dans (Chargui et al., 2022). Une enquête sur l'origine et les processus de salinisation des eaux souterraines dans l'aquifère côtier a été menée, comme décrit dans l'article de référence (Ziadi et al., 2019). De plus, plusieurs autres études ont détaillé la description du bassin versant, telles que les travaux mentionnés dans les articles (Mekki, 2003) et (Zitouna Chebbi et al., 2014).

1.3 Généralités sur les précipitations

1.3.1 Processus physiques à l'origine de la formation des précipitations

Les précipitations jouent un rôle essentiel dans le système climatique et la régénération de l'eau sur Terre, assurant ainsi la survie de tous les êtres vivants. Le cycle hydrologique est le résultat de divers processus physiques qui impliquent des mouvements et des changements dans l'état de l'eau de façon récurrente (Kuchment, 2004). L'eau de la surface de la Terre (océans, rivières, lacs, etc.) est transformée en vapeur d'eau par la chaleur. Les précipitations se produisent lorsqu'une partie de l'atmosphère est saturée en vapeur d'eau, de sorte que l'eau se condense pour former des fines gouttelettes (des hydrométéores). À la suite d'un processus microphysique, ces entités se regroupent et deviennent suffisamment volumineuses pour précipiter sous l'effet de la gravité. Elles peuvent apparaître sous n'importe quelle forme en fonction de la température de l'air : sous forme liquide (e.g. pluie, bruine, averse), solide (e.g. neige, grêle, grésil) ou des précipitations occultes (e.g. givre, rosée, gelée blanche). Certaines précipitations ne parviennent pas toujours à atteindre la surface et s'évaporent. Sur le total des précipitations reçues, une partie de l'eau peut être infiltrée dans les sols pour mener à la formation de cours d'eau souterrains. Une autre partie s'écoule à la surface du sol, drainée vers les cours d'eau et finit par retourner à la mer par le biais de ruissellements et d'écoulements (Besbes et al., 2014).

En effet, les précipitations sont inégalement réparties sur le globe. Les océans reçoivent environ 80 % des précipitations (Habets et al., 2005b) et le reste est réparti de manière non-uniforme sur les terres. Les précipitations dans la zone tempérée s'élèvent généralement à environ 700 à 1000 mm/an, puis diminuent pour devenir pratiquement nulles à la latitude des "déserts chauds" tels que le Sahara (De Marsily, 2020). De plus, les précipitations tombent de manière inégale dans le temps : de nombreux jours sans pluies, d'autres avec des pluies légères, et certains avec

des pluies torrentielles. D'ailleurs, les précipitations sont classées en différentes catégories selon la manière dont elles se forment. La pluie stratiforme se manifeste par une distribution uniforme de la pluie, associée à des nuages stratiformes développés horizontalement. Elle se caractérise par des épisodes comprise entre plusieurs heures et une journée et d'intensité faible à modérée avec une répartition spatiale relativement homogène (Habets et al., 2005a). D'autre part, la pluie convective associée aux nuages cumuliformes, avec un fort développement vertical, se caractérise par une courte durée (quelques heures) et une forte intensité localisés sur quelques kilomètres carré (Luu et al., 2022). Par exemple, un système convectif de mésoéchelle quasi-stationnaire a entraîné de fortes précipitations de 690 mm en moins de 24 heures à la région du Gard en France en septembre 2002 (Bresson, 2011). Les précipitations peuvent également être liées au forçage orographique par le relief, qui résulte de la rencontre d'une masse d'air chaud et humide avec une barrière topographique importante. Le relief fait monter la masse d'air à des altitudes plus élevées, condensant une grande quantité de vapeur qui tombe sous forme de fortes précipitations. Ces événements peuvent également se produire à la suite d'une instabilité de la masse d'air, de perturbations à grande échelle ou d'une combinaison de tous ces facteurs. Le relief ayant tendance à bloquer le mouvement des nuages, l'air s'élève et provoque une augmentation de l'activité orageuse, ce qui explique pourquoi les régions montagneuses sont plus fréquemment touchées par les orages que les zones de plaine.

L'un des phénomènes observés dans la région méditerranéenne est celui des crues soudaines, également connues sous le nom de crues éclair (Llasat et al., 2010). Ces crues hydrologiques rapides sont souvent déclenchées par des précipitations convectives de forte intensité, générant des cumuls de précipitations de 100 mm ou plus en quelques heures (Gaume et al., 2016). La montée très rapide des eaux, souvent en moins de 24 heures, est amplifiée à l'échelle du bassin versant lorsque les sols sont localement saturés ou présentent une capacité d'infiltration réduite (Alaoui et al., 2018). Une description plus détaillée des conditions atmosphériques induisant des crues éclair sur la Méditerranée est présentée par (Boudevillain et al., 2009; Dayan et al., 2015).

1.3.2 Techniques de mesure de pluie

La collecte des variables hydrologiques sur terre remonte à une longue histoire (Park et al., 2017). Depuis des siècles, les êtres humains ont cherché à mesurer les phénomènes liés à l'eau, tels que les précipitations, l'évaporation et le débit des cours d'eau. La recherche en matière de techniques de mesure a connu un développement considérable au fil des années, permettant des mesures de plus en plus précises. En règle générale, on mesure un volume de précipitations par unités de temps et on exprime ce volume sous la forme d'une lame d'eau en millimètre (mm), tel que 1mm représente un litre d'eau sur une surface d'un mètre carré (Leroy, 2002). On distingue deux catégories d'instruments de mesure des lames de précipitations : les mesures directes sur le terrain et les mesures indirectes par des moyens de télédétection (Michaelides

et al., 2009; Tapiador et al., 2012).

Les mesures directes sont effectuées à partir de stations pluviométriques placées sur le sol, fournissant des observations ponctuelles des précipitations. Le pluviomètre est classé comme la méthode la plus ancienne, la plus simple et la plus directe. Comme son nom l'indique, il s'agit d'un instrument qui mesure la quantité d'eau précipitée et recueillie dans un récipient gradué sur une période donnée (généralement 24 heures). Outre le niveau d'eau total, le pluviographe mesure l'intensité des précipitations sur des pas de temps plus courts (généralement de 1 à 6 minutes). Plusieurs modèles de pluviomètres enregistreurs ont été inventés, comme les appareils à augets basculants, les appareils à pesée ou à mesure optique. Aujourd'hui, la plupart des appareils exploités dans les réseaux pluviométriques de Météo-France, à titre d'exemple, sont des pluviomètres à augets basculants. La qualité des mesures directes s'est améliorée au fil du temps, mais ces instruments peuvent encore présenter diverses sources d'erreur. Il s'agit, par exemple, de l'effet du vent (Habib et al., 1999), des pertes par évaporation, du débordement en cas de forte intensité ou encore de l'incertitude de calibration de l'appareil. L'emplacement du dispositif par rapport à l'environnement est également très important. Il arrive même que l'instrument soit endommagé, ce qui entraîne des mesures avec des données manquantes (Sattari et al., 2017). Même si la densité des réseaux de stations de mesure est désormais bien importante, certains événements extrêmes peuvent échapper aux mesures précises en tombant entre deux points de mesure. Par ailleurs, la répartition inégale des réseaux de stations est notable, avec une densité moins élevée dans les zones à faible densité de population et une densité plus élevée dans d'autres régions.

La deuxième catégorie de mesure de pluie concerne les mesures indirectes effectuées à l'aide de techniques de télédétection terrestres et satellitaires. Ces techniques offrent une vision globale et en temps réel des conditions météorologiques sur de vastes zones géographiques. Le radar météorologique représente un système de télédétection active axé sur la mesure des hydrométéores (Andrieu, 2002). Les mesures radar fournissent des informations tridimensionnelles des systèmes pluvieux et de leur évolution (Masunaga, 2022). Son principe consiste à émettre des ondes électromagnétiques dans l'atmosphère qui sont réfléchies par les précipitations. Les informations reçues sont ensuite converties en précipitations cumulées par unité de temps avec une certaine résolution spatiale. Ces mesures peuvent assurer une couverture de quelques centaines de km, avec un échantillonnage de quelques centaines de mètres et de quelques minutes. À titre d'exemple, citons le réseau opérationnel ARAMIS (Application RAdar à la Météorologie Infra-Synoptique) de Météo-France (Tabary et al., 2013). Ces radars effectuent des balayages de l'atmosphère à des intervalles de 15 minutes, couvrant des distances significatives pouvant atteindre 256 kilomètres. Bien que cette technique de mesure terrestre permette de couvrir des zones mal desservies par les réseaux de mesure des précipitations au sol, elle peut également entraîner des erreurs dues à divers obstacles qui peuvent dévier la trajectoire des ondes. Ainsi, elle est peu fiable à la fois en milieu urbain et montagneux (Pellarin et al., 2002).

En plus des instruments au sol, l'enregistrement moderne des précipitations repose large-

ment sur l'observation par satellite, comme souligné par (Levizzani and Cattani, 2019). Ces satellites fournissent une mesure indirecte, offrant l'avantage d'une couverture quasi-mondiale, y compris les zones océaniques (Aubert et al., 2022). La constellation de satellites dédiée au suivi des systèmes pluvieux offre une diversité de produits résultant de différents niveaux d'algorithmes, aboutissant à l'élaboration de produits selon une grille spatiale régulière et à des intervalles de temps constants. Au cours des dernières décennies, une panoplie de produits de précipitations satellitaires à haute résolution spatio-temporelle ont été développés, alimentés par divers algorithmes tels que le Climate Hazards Group InfraRed Precipitation with Station data (CHIRPS) (Funk et al., 2015), Tropical Rainfall Measuring Mission (TRMM) Multi-satellite Precipitation Analysis (TMPA) (Huffman et al., 2007), et Integrated Multi-satellitE Retrievals for (GPM) mission (IMERG) (Huffman et al., 2015). Ces produits offrent des résolutions spatiales et temporelles variées, par exemple, IMERG propose une résolution spatiale élevée de 0.1 degrés (environ 11 km²) et une résolution temporelle de 30 minutes (Mahmoud et al., 2019), CHIRPS présente une résolution spatiale de 0.05 degrés (environ 5 km²) et une résolution temporelle journalière (Hamouda et al., 2023).

De nombreuses études ont été menées pour évaluer la performance de ces produits de précipitations satellitaires à l'échelle régionale et globale. Une analyse comparative entre les ensembles de données IMERG et CHIRPS réalisée par (Hamouda et al., 2023) met en lumière l'utilité d'intégrer les données CHIRPS pour valider les tendances observées dans IMERG. La cohérence des tendances entre les deux ensembles de données renforce la fiabilité des résultats et améliore la compréhension des schémas des précipitations sur la zone étudiée. Par ailleurs, (Guermazi et al., 2019) concluent que CHIRPS surpasse le jeu de données PERSIANN-CDR lorsqu'il est évalué dans le bassin versant de la Medjerda. Les résultats dans (Katsanos et al., 2016) ont montré une bonne corrélation entre les valeurs CHIRPS et les précipitations enregistrées dans la région méditerranéenne, bien qu'une surestimation des données ponctuelles ait été constatée au cours de la dernière décennie. Il faut noter que les données satellitaires doivent être souvent calibrées avant de pouvoir être utilisées pour toute modélisation hydrologique. (Camici et al., 2018) mettent en évidence que les produits pluviométriques basés sur les données satellitaires sont relativement peu performants par rapport au cas où des observations au sol sont utilisées.

Toutefois, ces techniques sont encore récentes, de sorte que les méthodes qui nécessitent le plus de données doivent souvent s'appuyer sur les informations fournies par les mesures directes. Dans ce cadre, les données maillées de ré-analyses résultent de la combinaison des données d'observation au sol avec les sorties de modèles numériques. Cette combinaison permet de produire des données spatiales structurées sur des grilles régulières, couvrant des échelles temporelles journalières ou infra-journalières. Par exemple, les réanalyses COMEPHORE produites par Météo-France, proviennent d'une combinaison de données radar et de mesures pluviométriques au sol. Elles sont disponibles au pas de temps horaire, sur une grille de 1 km². Les données ERA5 (la cinquième génération de ré-analyse atmosphérique du *Centre européen pour les prévisions météorologiques à moyen terme* (CEPMMT)), est une réanalyse mondiale à haute résolution

spatiale et temporelle, couvrant une période plus étendue (Hersbach et al., 2020). Dans (Tramblay et al., 2021), les auteurs ont comparé les performances des données CHIRPS et ERA5 sur les précipitations maximales annuelles moyennes. Ils ont conclu qu'ERA5 pourrait sur-estimer la fréquence des précipitations et sous-estimer les extrêmes (Beck et al., 2020; Faranda, 2020; Bandhauer et al., 2022). Une revue des progrès récents dans l'utilisation des observations satellitaires au-dessus de l'Afrique est présentée dans (Papa et al., 2023). Les auteurs ont mis en évidence leur utilisation pour surveiller les ressources en eau, évaluer la qualité de l'eau et caractériser divers processus hydrologiques, tout en soulignant les avantages et les difficultés actuels.

En conclusion, bien que différentes techniques de mesure de la pluie soient utilisées, il convient de souligner que les mesures directes effectuées au sol restent les seules "vérités terrain" à l'échelle locale. Ces mesures fournissent une base solide pour la validation et la calibration des données collectées par les autres méthodes, ainsi que les séries de données les plus longues. Elles permettent une évaluation des quantités de précipitations et contribuent à l'amélioration des modèles de prévision météorologique. Il est donc primordial de réaliser une analyse basée sur des mesures directes, car elles jouent un rôle essentiel dans la fiabilité et la qualité des données.

1.4 Modélisation statistique des précipitations

La modélisation statistique des précipitations joue un rôle crucial dans la compréhension des comportements des systèmes hydrologiques. En effet, l'utilisation de modèles statistiques permet de générer des simulations réalistes des champs de pluie en s'appuyant sur des données historiques de précipitations. C'est là qu'interviennent les générateurs stochastiques de conditions météorologiques. Ces modèles statistiques complexes ont la capacité de générer aléatoirement des séries temporelles de données. Les séries de données générées présentent des caractéristiques statistiques similaires à celles observées (Ailliot et al., 2015; Zhao et al., 2019). Ainsi, lorsqu'il s'agit d'évaluer les conséquences potentielles d'événements hydrométéorologiques, ces générateurs offrent une base solide dans le contexte des études d'impact.

Les principales applications des générateurs stochastiques incluent la modélisation des systèmes météorologiques, la génération de données météorologiques manquantes, ainsi que la réduction d'échelle des scénarios de changement climatique (Bourotte, 2016). Pour capturer la nature intermittente des précipitations, les générateurs stochastiques peuvent incorporer plusieurs aspects des phénomènes pluvieux, tels que l'intensité, l'occurrence des jours humides et secs, la corrélation spatiale (dans le cas multisite) ou la corrélation entre d'autres variables (dans le cas multivarié). Généralement, la modélisation de l'occurrence des précipitations peut être réalisée en prenant en compte l'intensité de la pluie, soit de manière indépendante, soit de manière combinée. Une approche consiste à modéliser chaque type de pluie de manière individuelle, puis combiner les simulations de chaque type dans un modèle global. Pour simuler l'occurrence de jours humides et de jours secs, l'utilisation d'une approche basée sur les chaînes

de Markov peut être adoptée. Cette approche suppose que le système modélisé est un processus de Markov, où les états cachés représentent les différents modèles de précipitations qui se produisent au fil du temps. À titre d'exemple, le modèle de Markov caché élaboré par (Ailliot et al., 2009) pour représenter l'évolution spatio-temporelle des précipitations journalières offre une description plus précise de la structure spatiale des précipitations par rapport à un modèle standard fréquemment utilisé dans la littérature. Les auteurs ont combiné deux approches, à savoir l'utilisation d'un modèle de Markov caché pour modéliser les types de temps régionaux et l'utilisation de distributions gaussiennes censurées et transformées en puissance pour modéliser la dépendance spatiale des précipitations des types de temps. Bien que le modèle puisse bien décrire les distributions marginales et la structure spatiale des données, il montre des limites en reproduisant pleinement la dynamique locale et en sous-estimant les autocorrélations. Dans le même esprit, dans l'étude menée par (Stoner and Economou, 2020), le modèle de Markov caché utilisé parvient à saisir des caractéristiques importantes des précipitations à l'échelle infra-journalière. Cela inclut la variation saisonnière de l'occurrence et de l'intensité des précipitations, les longues périodes sèches, ainsi que les valeurs extrêmes. Cette performance est démontrée à travers son application à une série temporelle couvrant une période de 8 ans, basée sur des mesures horaires provenant d'un seul pluviomètre situé à Exeter, au Royaume-Uni.

Le travail de cette thèse se concentre spécifiquement sur la modélisation de l'intensité de la pluie, dans le but de contribuer au développement de générateurs stochastiques. Dans cette section, nous explorons les principaux concepts et méthodologies de la modélisation statistique des précipitations, en mettant en avant son application dans la région méditerranéenne. Cette région suscite un intérêt croissant de la part des scientifiques pour la modélisation de différents phénomènes hydrologiques. L'état actuel des connaissances sur la modélisation statistique des précipitations est très vaste, avec de nombreuses recherches menées, en particulier dans la région méditerranéenne. Par exemple, les recherches de (Bacro and Chaouche, 2006) mettent en lumière l'impact significatif de l'hétérogénéité des données sur l'estimation des quantiles extrêmes, remettant en question l'ajustement de la loi de Gumbel pour les précipitations extrêmes observées dans la région de Marseille, en France. Dans le même contexte méditerranéen, l'étude de (Toreti et al., 2010) adopte une approche distincte, intégrant un modèle statistique extrême et une procédure d'identification de modèle atmosphérique. Cette approche repose sur l'analyse des événements de précipitations journalières extrêmes observés sur 20 sites côtiers. D'autre part, l'étude de (Tramblay et al., 2013) a révélé une forte tendance à la diminution des cumuls de précipitations et des jours humides, ainsi qu'à l'augmentation de la durée des périodes sèches. D'autres études se sont penchées spécifiquement sur la région tunisienne. Par exemple, (Feki et al., 2016) ont cherché à évaluer un réseau pluviométrique en utilisant la méthode de réduction de la variance par krigeage à trois échelles de temps différentes : mensuelle, saisonnière et interannuelle. En Tunisie également, les recherches de (Farhani et al., 2022) ont présenté l'adaptation et l'évaluation d'un générateur stochastique de temps infrajournalier multi-variable. Cet outil se révèle être une ressource fiable pour détecter de manière réaliste le stress hydrique

en l'absence d'informations hydrométéorologiques. Cependant, cette étude présente certaines limites, notamment la complexité d'ajustement des paramètres, la sous-estimation des événements extrêmes due au choix de la distribution Gamma, et l'incapacité à reproduire les valeurs les plus élevées de l'indice de stress hydrique.

Ces études soulignent l'importance croissante accordée à la modélisation des précipitations et à l'évaluation des réseaux pluviométriques dans la région méditerranéenne, en mettant en lumière l'importance de l'influence de l'hétérogénéité spatio-temporelle des données, tant au niveau global qu'à l'échelle régionale.

1.4.1 Modélisation des intensités de précipitations extrêmes

Par définition, les événements rares sont des événements dont la probabilité d'occurrence est faible. Ils sont dits "extrêmes" lorsqu'ils ont des valeurs beaucoup plus grandes (ou plus petites) que celles normalement observées. Donc les observations des événements extrêmes ne représentent qu'une petite partie de l'ensemble des échantillons de données. Dans ce cadre, les théories statistiques classiques ne sont plus appropriées puisqu'elles sont basées sur le théorème de la limite centrale caractérisant le comportement moyen des phénomènes. Ce problème a conduit à la formulation de la théorie des valeurs extrêmes (TVE) qui fournit un outil statistique adapté à l'analyse des événements extrêmes.

Les méthodes issues de la TVE s'appuient sur le comportement asymptotique des grandes valeurs : maxima ou excédents. En effet, il existe deux approches principales pour déduire le comportement extrême : les maxima par blocs et les dépassements au-dessus d'un seuil. L'approche de maxima par blocs consiste à décrire la distribution des maxima parmi une série d'observations dans des blocs de temps de taille fixe. Pour modéliser les maxima annuels, la distribution des valeurs extrêmes généralisées (GEV) est théoriquement justifiée (Fisher and Tippett, 1928; Gnedenko, 1943; Coles, 2001). La deuxième approche des dépassements au-dessus d'un seuil, consiste à fixer un seuil, et modéliser les valeurs dépassant cette valeur par la distribution de Pareto généralisée (GPD). La difficulté de cette approche réside dans le choix optimal du seuil (Deidda, 2010) (plus de détails au Chapitre 3).

En hydrologie, on s'intéresse particulièrement à l'estimation d'une période de retour associée à une probabilité de dépassement d'un certain niveau de retour. Cette période de retour est interprétée comme une moyenne du nombre d'années séparant un événement de grandeur donnée d'un second événement d'une grandeur égale ou supérieure (Guillou and Willems, 2006). Pour approfondir la compréhension de l'application des statistiques des valeurs extrêmes en hydrologie, une revue exhaustive est proposée dans (Katz et al., 2002). En outre, il convient de noter que la TVE demeure un domaine de recherche dynamique et en constante évolution. Des développements significatifs continuent d'émerger dans ce domaine. Par exemple, Merz et al. (2022) abordent la génération de distributions à queues lourdes pour les événements de précipitation, et explorent leurs implications sur la gestion des risques liés aux inondations.

1.4.2 Modélisation de la distribution complète des précipitations

Les deux approches issues de la TVE présentent certaines limitations. Dans le cas de la GEV, les maxima sont identifiés par blocs, ce qui peut ne pas tenir compte de la possibilité d'avoir plusieurs événements extrêmes au sein d'un même bloc. De plus, il est possible que d'autres blocs ne contiennent aucun événement extrême, ce qui nous obligera de sélectionner une valeur relativement faible (Katz et al., 2002). En ce qui concerne la GPD, il n'existe pas encore de méthode unifiée pour choisir de manière optimale le seuil, et les observations situées en dessous du seuil choisi ne sont pas utilisées. En plus des événements extrêmes, la problématique de la modélisation de l'ensemble des précipitations non nulles revêt une importance capitale pour la gestion des ressources en eau.

Généralement, les quantités de précipitations journalières sont décrites par la distribution Gamma, en raison de leur distribution asymétrique vers la droite (Papalexiou et al., 2013). Cependant, la partie supérieure de la distribution Gamma peut être trop légère pour capturer les fortes intensités de pluie, ce qui implique une sous-estimation du niveau de retour (Katz et al., 2002). Plusieurs autres variantes existent dans la littérature. Certains travaux s'appuient sur des modèles de mélange qui permettent de joindre une loi ajustée à la queue de la distribution (généralement la GPD) et une autre loi pour la partie centrale de la distribution. Dans ce cas, le choix du seuil de GPD peut être effectué en le considérant comme un paramètre à estimer ou il peut être contourné en utilisant des fonctions de transition entre les deux composantes du mélange. Par exemple, (Frigessi et al., 2002) ont proposé un mélange d'une distribution de Weibull et une GPD, avec une fonction de poids reliant les deux parties de manière fluide, tout en contournant le choix du seuil. Ce modèle a inspiré (Vrac and Naveau, 2007) en considérant le mélange avec une distribution Gamma au lieu de la distribution Weibull. Une distribution de Pareto hybride a été introduite par (Carreau and Bengio, 2009) qui est une combinaison d'une distribution normale avec la GPD, en imposant la continuité de la densité et sa dérivée première, y compris l'extension à un mélange de ces distributions de Pareto hybrides. Ce modèle aide à atténuer le biais de l'approximation de la queue par la Pareto généralisée. (Carreau and Vrac, 2011) ont proposé un modèle de mélange conditionnel combinant une densité Gaussienne avec une GPD à queue lourde. Plusieurs autres exemples ont abordé de la même manière le problème de la modélisation de la distribution complète des précipitations (e.g. (Tancredi et al., 2006; MacDonald et al., 2011; Li et al., 2012; Scarrott and MacDonald, 2012)). Cependant, les modèles de mélange présentent certaines limites, notamment le grand nombre de paramètres impliqués, les contraintes de continuité au point de jonction et les défis liés à l'inférence, en particulier pour les paramètres de forme.

Récemment, une distribution qui assure une représentation de l'intensité des précipitations a été proposée par Naveau et al. (2016) en s'inspirant du travail de Papastathopoulos and Tawn (2013). La distribution EGPD (*Extended Generalized Pareto Distribution*) est un modèle de type Gamma dans la partie centrale et de type GPD dans la partie supérieure, avec une

transition fluide entre les deux. Cette transition est réalisée par une fonction de transformation, de sorte que toute la partie centrale et extrême des intensités de précipitation est modélisée sans sélection de seuil. Ce modèle a récemment prouvé son efficacité dans le cadre de différents travaux. [Tencaliec et al. \(2020\)](#) ont proposé une version semi-paramétrique de l'EGPD, où les précipitations faibles et fortes sont représentées par la TVE et les précipitations modérées sont capturées par un modèle basé sur les polynômes de Bernstein. [Rivoire et al. \(2021\)](#) ont présenté une comparaison des précipitations journalières modérées et fortes en ajustant une EGPD. Dans un contexte multi-sites, [Evin et al. \(2018\)](#) ont utilisé l'EGPD pour les distributions marginales, [Haruna et al. \(2022a\)](#) ont comparé trois approches de régionalisation appliquées à l'EGPD, et [Le Gall et al. \(2022\)](#) ont comparé les modèles locaux, semi-régionaux et régionaux basés sur l'EGPD. Contrairement à l'utilisation courante des données extrêmes pour construire les courbes Intensité-Durée-Fréquence (IDF), [Haruna et al. \(2022b\)](#) ont utilisé toutes les intensités de précipitations non nulles modélisées à l'aide de l'EGPD. Ainsi, la modélisation de l'intensité des précipitations nécessite une approche plus fine, et l'EGPD apparaît comme une solution prometteuse qui mérite une attention particulière dans les futures recherches en hydrologie.

1.4.3 Modélisation de la non-stationnarité spatiale

Compte tenu de la forte variabilité spatiale des précipitations extrêmes dans la région méditerranéenne, il est essentiel d'estimer le risque en tout point de l'espace. Toutefois, la couverture spatiale des réseaux de stations de mesures ponctuelles est limitée et peu dense, en particulier dans les zones géographiques éloignées. Cette limitation entrave la possibilité d'effectuer des estimations précises à une échelle spatiale fine, ce qui a pour conséquence de restreindre la précision des résultats obtenus. Ainsi, face à la disponibilité limitée des stations pluviométriques, il est crucial de maîtriser les méthodes permettant de mieux estimer les distributions des précipitations à un emplacement spécifique. C'est là qu'intervient la modélisation "spatiale", qui permet de représenter des champs continus en 2D.

Afin de disposer d'une information de pluie spatialisée, plusieurs approches peuvent être appliquées à partir d'observations de qualité contrôlée couvrant des périodes relativement longues ([Beguería and Vicente-Serrano, 2006](#); [Li and Heap, 2008](#); [Szolgay et al., 2009](#); [Panthou et al., 2012](#)). En fait, les pluies précipitées entre les mesures ponctuelles peuvent être estimées par l'interpolation spatiale. Des approches géostatistiques peuvent être utilisées pour représenter les caractéristiques locales : après avoir estimé les paramètres de la distribution ou le niveau de retour localement (pour chaque station), une interpolation de ces estimations est appliquée. Le krigeage, initialement proposé par ([Kriging, 1951](#)), est la technique d'interpolation spatiale probablement la plus utilisée. Dans ([Blanchet and Lehning, 2010](#)), en vue de représenter les niveaux de retour de l'épaisseur de la neige en Suisse, une estimation locale des paramètres de la distribution GEV a été interpolée avec plusieurs méthodes : le krigeage, la pondération inverse à la distance, les modèles de régression linéaire et les modèles de régression basés sur

des splines. Ces méthodes peuvent être efficaces si les mesures ponctuelles ne sont pas trop distantes les unes des autres.

Outre les méthodes d'interpolation spatiale, il existe d'autres approches pour traiter ce problème, qui permettent de prendre en compte des valeurs supérieures aux valeurs observées, plutôt que de les lisser. Par exemple, on peut distinguer les méthodes basées sur l'homogénéité régionale. L'idée de l'analyse fréquentielle régionale (RFA pour *regional frequency analysis*) est de définir des sous-régions homogènes, puis de rassembler toutes les observations appartenant à une même région afin de compenser les observations courtes sur un seul site. Une distribution est ajustée aux observations d'une région, de sorte que toutes les stations de cette région partagent les mêmes paramètres (e.g. (Hosking and Wallis, 1997; Carreau and Girard, 2011; Neppel et al., 2011)). Au lieu de définir des régions distinctes et séparées par des frontières, la méthode de la région d'influence, proposée par (Burn, 1990), est une autre alternative qui consiste à attribuer une région d'influence pour chaque station. L'information issue de la station d'intérêt est enrichie en utilisant les mesures effectuées sur d'autres stations proches ou similaires. Dans le même esprit, (Le Gall et al., 2022) ont proposé une autre approche basée sur la similarité du comportement de la queue supérieure de la distribution des précipitations de chaque station. Des comparaisons entre ces différentes approches régionales sont présentées dans (Gaál et al., 2008; Carreau et al., 2013; Evin et al., 2016; Das, 2019; Haruna et al., 2022a). D'après les résultats du projet ExtraFlo (*Extreme Rainfall and Flood estimation*) (Neppel et al., 2014), les méthodes régionales sont plus stables que les méthodes classiques basées sur l'interpolation spatiale. Il est donc intéressant de prendre en compte le voisinage pour assurer une variation spatiale lisse des paramètres.

Une autre façon d'introduire la non-stationnarité consiste à estimer des *surfaces de réponse* pour chaque paramètre de la distribution, notamment les niveaux de retour. Dans ce cas, toutes les stations participent à l'estimation spatiale directe sans passer par l'estimation ponctuelle. Cette technique, bien que peu utilisée dans la littérature, offre une grande flexibilité pour obtenir des informations spatialisées. Une manière simple de représenter la non-stationnarité est d'inclure un facteur spatial directement dans les paramètres de la fonction de distribution de probabilité. Les informations spatiales peuvent contribuer à améliorer les estimations. Par exemple, dans l'approche présentée par (Blanchet and Lehning, 2010), où les paramètres de la distribution sont modélisés comme des fonctions lisses des covariables spatiales, les niveaux de retour des hauteurs de neige extrêmes sont estimés de manière plus précise qu'avec les méthodes d'interpolation par krigeage. Les paramètres du modèle de loi de probabilité varient en fonction de "covariables" qui peuvent rajouter de l'information complémentaire. Dans ce cas, le modèle est conditionné par des covariables géographiques qui décrivent l'emplacement pour l'ensemble de la région et pas seulement pour les stations météorologiques. Par exemple, dans (Bracken et al., 2016), les covariables utilisées comprennent l'altitude et les précipitations saisonnières moyennes. De même, (Cooley et al., 2007) ont utilisé l'altitude et les précipitations moyennes pour les mois d'avril à octobre. D'autres exemples de covariables sont mentionnés dans les

travaux de (Coles, 2001; Katz et al., 2002; El Adlouni et al., 2007; Van de Vyver, 2012; Katz, 2013).

Les surfaces de réponse peuvent être obtenues en ajustant des modèles linéaires généralisés (GLM pour *Generalized Linear Models*), qui sont une généralisation de la régression linéaire adaptée à l'étude des événements extrêmes (Chandler and Wheater, 2002; Chandler, 2005). Yee and Stephenson (2007) ont introduit les modèles vectoriels généralisés et additifs qui permettent une modélisation des paramètres de la distribution des événements extrêmes en fonction de co-variables. Par exemple, dans (Carreau and Toulemonde, 2020), un GLM a été employé pour l'interpolation des paramètres afin de modéliser des distributions marginales univariées. L'hypothèse de linéarité des GLMs suppose l'existence d'une relation linéaire. Cependant, dans de nombreux scénarios réels, les relations entre les variables explicatives et la réponse peuvent être complexes et non linéaires. Une structure plus générale et plus complexe implique l'utilisation des réseaux de neurones artificiels (ANN pour *Artificial Neural Networks*). Ces modèles, caractérisés par leur nature non-linéaire et non-paramétrique, sont reconnus par leur capacité à approximer toute fonction continue. De nombreuses applications des réseaux de neurones ont été développées dans le contexte climatique. Par exemple, Rigol et al. (2001) ont présenté les réseaux de neurones comme un outil d'interpolation spatiale de la température journalière de l'air. Plusieurs autres exemples témoignent de l'utilisation des ANN en hydrologie, ce qui met en lumière leur pertinence et leur efficacité (Dawson and Wilby, 2001; Cannon, 2007; Carreau and Bengio, 2009; Ceresetti et al., 2012; Tanty and Desmukh, 2015; Kharroubi et al., 2016; Daliakopoulos and Tsanis, 2016; Cannon, 2018; Ahmad et al., 2022; Papailiou et al., 2022). Une proposition d'un modèle non-linéaire en utilisant un réseau de densité conditionnelle (une extension du réseau de neurones) a été proposée par (Cannon, 2010) pour l'analyse des valeurs extrêmes généralisées non-stationnaires. Une évaluation de la performance des réseaux de neurones pour l'interpolation spatiale a été présentée par (Snell et al., 2000), où il a été démontré que la performance de prédiction surpasse celle obtenue avec d'autres méthodes traditionnelles. Une définition plus détaillée de ces deux méthodes (GLM et ANN) est fournie dans le Chapitre 4. Pour ces raisons, nous proposons dans ce travail de comparer l'efficacité de ces modèles de régression, conditionnés par des covariables géographiques, pour obtenir des surfaces de réponse des paramètres de distribution des précipitations.

Un exemple de comparaison avec les méthodes d'interpolation classiques est présenté par (Ceresetti et al., 2012) sur la région Cévennes-Vivarais. En effet, ils ont comparé deux méthodes d'interpolations de modèles de valeurs extrêmes (GEV avec krigeage, GEV avec ANN et GPD avec krigeage). Dans cette application, les deux méthodes de régionalisation ont produit des résultats d'estimation de niveau de retour 100-ans similaires, cependant le krigeage s'est avéré plus efficace dans les réseaux de stations avec une densité élevée.

1.5 Objectifs de la thèse

Cette thèse s'inscrit dans le contexte de l'étude des ressources en eau et des risques naturels dans les pays du pourtour méditerranéens. L'objectif principal consiste à fournir une modélisation spatiale des événements extrêmes et ordinaires, dans le but de contribuer au développement d'outils d'aide à la décision et de systèmes d'alerte aux risques d'inondation. Des développements méthodologiques sont proposés, combinant des approches non-paramétriques et la théorie des valeurs extrêmes. Une telle modélisation statistique doit pouvoir prendre en compte le caractère non-stationnaire des précipitations en Méditerranée. Dans ce cadre, des mesures ponctuelles de précipitations journalières ont été utilisées : un site sur l'arc méditerranéen français, et deux autres sites en Tunisie.

L'un des principaux défis de la modélisation statistique des événements de précipitations est de réussir à établir une représentation spatiale des estimations. Les mesures ponctuelles des précipitations provenant des réseaux pluviométriques sont insuffisantes pour fournir des connaissances spatiales précises décrivant les régions vulnérables aux événements extrêmes. De ce fait, un processus de traduction des informations ponctuelles en une variable spatiale continue doit être impliqué. Une fois qu'une distribution adaptée est ajustée à l'ensemble des données, et que les paramètres de distribution sont connus, différentes représentations du risque peuvent être évaluées. Ainsi, les objectifs de cette thèse peuvent être résumés par les points suivants :

1. Développement méthodologique d'une modélisation qui intègre des covariables spatiales afin de mieux décrire la non-stationnarité spatiale des précipitations.
2. Décision de choix de covariables qui décrivent au mieux la variabilité spatiale.
3. Évaluation de la performance des modèles à l'aide des tests statistiques.
4. Comparaison des résultats obtenus sur les trois sites d'études du bassin méditerranéen.

La démarche globale de cette étude est synthétisée dans la Figure 4. La première étape consiste à modéliser les événements de précipitations extrêmes, en mettant initialement l'accent sur les extrêmes au niveau des points de mesure. Cette approche utilise la théorie des valeurs extrêmes, soit avec la distribution des valeurs extrêmes (GEV), définissant un événement extrême par bloc (la saison des pluies), soit avec la distribution généralisée de Pareto (GPD), où le seuil est établi par les quantiles 98%. Après l'estimation des paramètres de ces distributions et l'application de tests d'adéquation, une estimation ponctuelle du niveau de retour 100 ans est obtenue. Ensuite, l'analyse se déplace vers les extrêmes en des points sans mesures, nécessitant l'intégration d'informations spatiales disponibles à chaque point de l'espace. Pour cela, nous avons combiné la GEV avec un modèle linéaire généralisé (GLM) et un réseau de neurones artificiels (ANN). Après l'estimation des paramètres, la sélection des covariables spatiales et l'évaluation de ces deux modèles, des estimations spatiales du niveau de retour 100 ans ont été obtenues. La deuxième étape de la recherche se concentre sur la modélisation des événements de précipitations ordinaires et extrêmes au niveau des points de mesure. À cet effet,

la distribution EGPD est appliquée, nécessitant une étude approfondie pour calibrer le seuil de censure approprié. Après l'estimation des paramètres et les tests d'adéquation, des estimations ponctuelles du niveau de retour 100 ans sont présentées. Cette approche globale vise à fournir une compréhension approfondie des caractéristiques spatiales des précipitations, en mettant en évidence à la fois les événements ordinaires et extrêmes.

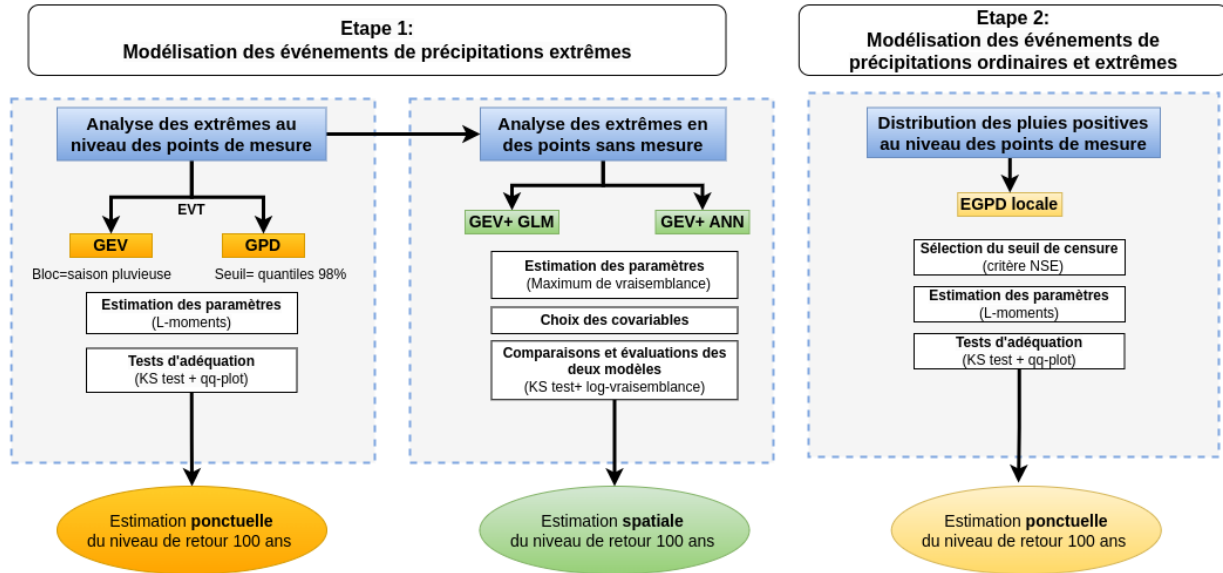


FIGURE 4 – Démarche de la modélisation globale de la thèse.

1.6 Organisation du manuscrit

Le plan de la suite du manuscrit est le suivant :

- **Chapitre 2** présente une description de la région d'étude avec des analyses préliminaires des données de précipitation journalières disponibles.
- **Chapitre 3** est consacré à la théorie des valeurs extrêmes et aux différentes méthodes d'estimations.
- **Chapitre 4** concerne les méthodes de modélisation de la non-stationnarité spatiale, particulièrement les ANN.
- **Chapitre 5** présente les résultats de la modélisation spatiale des précipitations extrêmes avec les surfaces de réponse (avec un GLM et un ANN). Ces travaux ont mené à la publication de l'article ([Hammami et al., 2022](#)).
- **Chapitre 6** concerne une extension de la modélisation de la distribution des précipitations ordinaires et extrêmes.
- **Chapitre 7** est un résumé des principaux résultats et l'apport original de cette thèse. Les limites de cette recherche seront également discutées avec quelques pistes de travail futures mises en perspective.

Analyse exploratoire des données

2.1 Introduction

Dans ce chapitre, nous abordons les aspects géographiques et hydro-météorologiques des trois régions d'étude situées dans le pourtour méditerranéen. Les données collectées comprennent des observations pluviométriques journalières, qui ont fait l'objet d'analyses préliminaires pour extraire les informations pertinentes avant toute modélisation statistique. Les mesures ponctuelles ont particulièrement été privilégiée pour leur précision. Toutefois, ces mesures peuvent être incomplètes et ne couvrir qu'une partie limitée d'un bassin versant. Par conséquent, pour avoir une information exhaustive des comportements de précipitations à l'échelle spatiale, nous avons également considéré des données issues de réanalyses. Ces dernières ont l'avantage de couvrir des zones plus étendues que les mesures ponctuelles, mais avec l'inconvénient d'être affectées par des biais. Ainsi, afin de conclure ce chapitre, nous procédons à une analyse comparative entre les données de mesure ponctuelles et les données de réanalyse. Il convient de souligner aussi que les analyses sont évaluées exclusivement sur la saison des pluies par soucis d'homogénéité.

2.2 Présentation des sites d'étude

2.2.1 La région de la Méditerranée française

La première région sélectionnée est située au sud de la France, délimitée à l'ouest par le Massif Central, à l'est par les Alpes et au sud par la mer Méditerranée. Elle regroupe les principaux départements concernés par les épisodes méditerranéens, notamment l'Hérault, le Gard et l'Ardèche. La région présente une topographie diversifiée, offrant une grande variété de paysages naturels, comme l'illustre le modèle numérique de terrain (MNT) de la Figure 5. En effet, le MNT est une représentation de la surface d'un terrain créée en associant chaque point de cette surface à une valeur d'élévation. Ces points sont généralement définis par leurs coordonnées géographiques, et pour notre étude, celles-ci sont projetées sur le système de coor-

2.2. Présentation des sites d'étude

données Lambert II étendu. Les données d'élévation associées à ces coordonnées sont exprimées en mètres au-dessus du niveau de la mer (ou *meters above sea level* (masl) en anglais). À l'est de la région, les Alpes se distinguent par des paysages montagneux avec des sommets atteignant environ 2694,5 m d'altitude. À l'ouest, la région du Massif central s'élève jusqu'à 1756,8 m, avec des collines, des vallées et des rivières. Au sud du Massif central se trouvent les "Cévennes", une chaîne de montagnes composée de petits massifs de faible à moyenne altitude. La vallée du Rhône traverse la région, reliant ces deux zones montagneuses de part et d'autre du fleuve, et présente l'altitude relative la plus basse de la région.

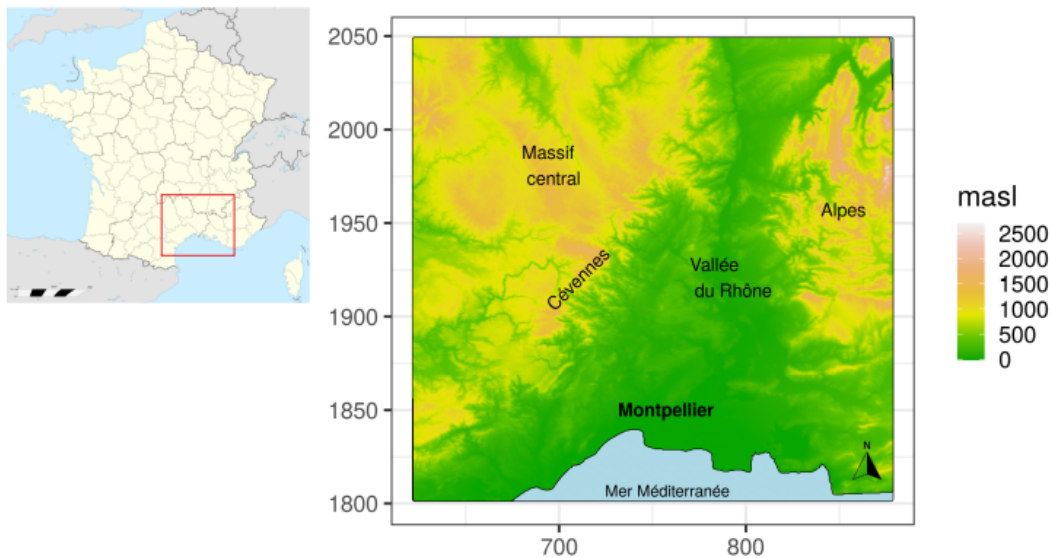


FIGURE 5 – Localisation de la zone choisie située dans la région de la Méditerranée française.

Le climat de la région est en grande partie de type méditerranéen, caractérisé par des étés chauds et secs ainsi que des hivers doux et humides. En effet, le climat peut varier considérablement d'une région à l'autre en raison de la grande variété des reliefs et de la proximité de la mer. Par exemple, la région des Cévennes présente un climat plus frais et plus humide par rapport à la vallée du Rhône, où les conditions sont plus chaudes et plus sèches. De plus, dans la région des Alpes, l'altitude élevée contribue à des hivers encore plus froids et enneigés. L'influence des vents joue également un rôle majeur dans le climat de la région. Le mistral, un vent puissant soufflant de la vallée du Rhône vers la Méditerranée, exerce une grande emprise sur le climat et le paysage environnant. Dans les zones côtières, les températures sont plus modérées en hiver et plus élevées en été, avec des précipitations plus abondantes en automne et en hiver. Dans les zones montagneuses, les hivers sont plus rigoureux tandis que les étés sont plus frais, avec des précipitations relativement abondantes tout au long de l'année. Il convient de noter que la région étudiée présente essentiellement deux types de climats : le climat méditerranéen et le climat de montagne (voir Figure 6). En général, le climat de montagne peut se caractériser par une saison des pluies plus prolongée que celle du climat méditerranéen.




FIGURE 6 – Typologie climatique du territoire français en 8 classes (Joly et al., 2010) : 1.climat de montagne, 2.climat semi-continental et des marges montagnardes, 3.climat océanique dégradé des plaines du Centre et du Nord, 4.climat océanique altéré, 5.climat océanique franc, 6.climat méditerranéen altéré, 7.climat du Bassin du Sud-Ouest, 8.climat méditerranéen franc.

La diversité climatique de la région exerce une influence directe sur les caractéristiques des données de précipitation dont nous disposons. Ces données d'observation, extraites de la base de données de Météo-France, contiennent les mesures journalières de précipitations enregistrées par station sur la période allant du 01/01/1958 au 31/12/2019. La répartition géographique de ce réseau de stations est illustrée dans la Figure 7. Afin d'explorer ces données et d'identifier des régions ayant des similitudes climatologiques et des comportements hydrométéorologiques cohérents, nous avons utilisé une approche inspirée par les travaux de Pujol et al. (2007) qui ont développé une méthodologie de "zonage climatique". Cette méthodologie vise à classer les données d'observations par station pour distinguer les types de climats. Chaque station est représentée par un vecteur composé de 15 éléments, incluant les quantiles 95% des maxima mensuels des précipitations journalières pour chaque mois de l'année, ainsi que les coordonnées géographiques pondérées (longitude, latitude et altitude). Le choix des quantiles extrêmes met en évidence les événements climatiques exceptionnels susceptibles de définir le climat local. La moyenne pourrait ne pas refléter adéquatement ces situations critiques, étant donné la variation significative des conditions climatiques.

Afin de classer ces stations en deux groupes distincts, nous avons appliqué l'algorithme K-means (MacQueen, 1967). L'objectif était de minimiser la somme des carrés des distances entre les points et les centres des groupes assignés. Les résultats de cette classification sont présentés dans la Figure 7. Pour délimiter la région, nous avons repéré les stations situées aux extrémités du premier groupe, marquées en vert et numérotées de 1 à 13 sur la Figure 7a. Les stations qui ont été finalement retenues sont celles incluses dans l'ensemble délimité par la ligne de contour,

2.2. Présentation des sites d'étude

correspondant à environ 63.1% du nombre total de stations disponibles (représentées en bleu sur la Figure 7b). En complément des résultats obtenus par l'algorithme K-means, l'identification de ces stations a reposé sur des considérations géographiques et climatiques. Conformément aux connaissances préalables sur le climat de la région, les stations regroupées dans cette zone sont généralement localisées dans des régions où le climat méditerranéen prédomine. Cette affirmation s'appuie sur des recherches antérieures, telles que celles présentée dans (Allam et al., 2020). Dans cette étude, le climat des stations de la région méditerranéenne est défini à l'aide d'un ensemble d'indices, principalement la saisonnalité et l'aridité, afin d'établir une classification climatique spécifique à la Méditerranée. Par conséquent, les stations incluses dans cette zone spécifique seront utilisées comme échantillons représentatifs de la région méditerranéenne dans toutes les analyses statistiques ultérieures.

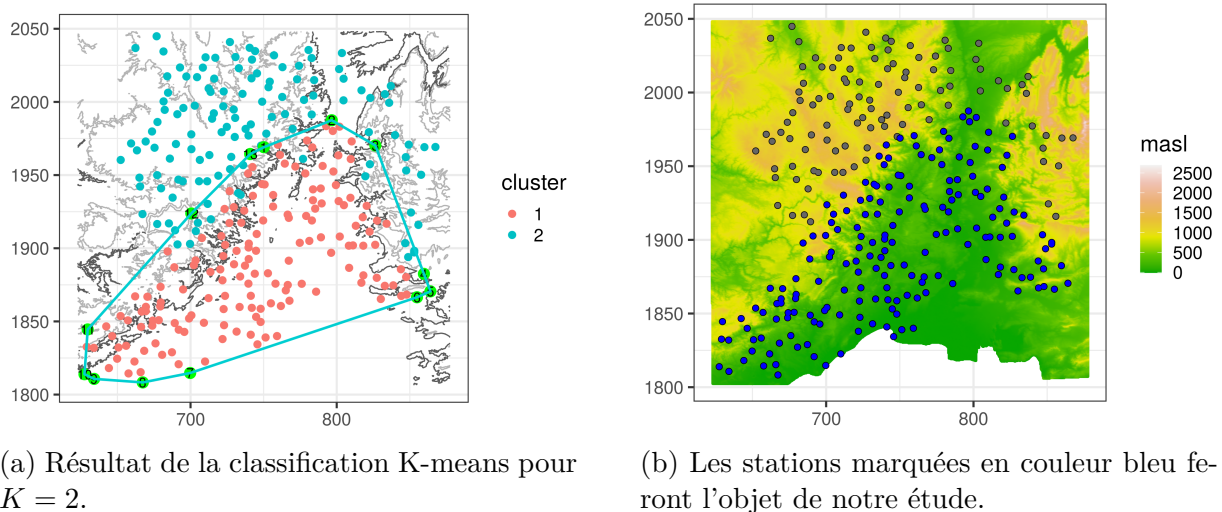


FIGURE 7 – Identification des stations dans la région de la Méditerranée française sous un climat méditerranéen.

Afin d'assurer la fiabilité de nos analyses statistiques, il est essentiel de veiller à la qualité de nos données. C'est dans cette optique que nous avons commencé par l'évaluation du pourcentage de valeurs manquantes par station. Parmi l'ensemble des 183 stations pluviométriques, nous avons remarqué que seulement 20 d'entre elles disposaient d'observations complètes. Pour les autres stations, nous avons instauré un critère de sélection rigoureux : seules celles bénéficiant d'une période d'observations d'au moins 30 ans et avec moins de 10% de valeurs manquantes pour chaque saison des pluies ont été retenues.

En effet, à l'échelle du bassin méditerranéen, la saison des pluies est généralement comprise entre l'automne et l'hiver. Pendant cette période, la région méditerranéenne française connaît fréquemment des épisodes de précipitations intenses, particulièrement durant les mois de septembre, octobre et novembre, comme souligné par (Molinié et al., 2012; Blanchet et al., 2018). La caractérisation de cette période s'appuie souvent sur des critères bien définis. Parmi eux, on peut mentionner la moyenne mensuelle de précipitations (Dieulin et al., 2019), la différence

entre les précipitations et l'évapotranspiration (Rivoire et al., 2019) ou le cumul de précipitations sur une période donnée (Molinié et al., 2012). Cependant, il convient de reconnaître que les particularités locales jouent un rôle crucial dans la délimitation temporelle de la saison des pluies. Par exemple, Raymond et al. (2016) identifie cette période comme allant de septembre à avril, tandis que Trambly (2018) l'étend d'octobre à avril. Les mois de transitions entre les saisons peuvent donc varier en fonction du contexte géographique et des données d'observations intégrées dans le cadre des travaux.

À partir des données historiques dont nous disposons, on a calculé la distribution des cumuls mensuels moyens des précipitations pour chaque mois de l'année (voir Figure 8). L'analyse de ce graphique permet d'identifier les mois avec les cumuls de précipitations les plus élevés et les plus faibles. La variation des précipitations entre le mois le plus sec (juillet) et le mois le plus humide (octobre) est en moyenne de 89.6 mm. Entre les mois de mai et d'août, on observe une période de sécheresse ou de faible pluviosité. Par conséquent, la période propice aux précipitations les plus abondantes correspond en général à la période de septembre à avril, soit 241 (ou 242) jours par an.

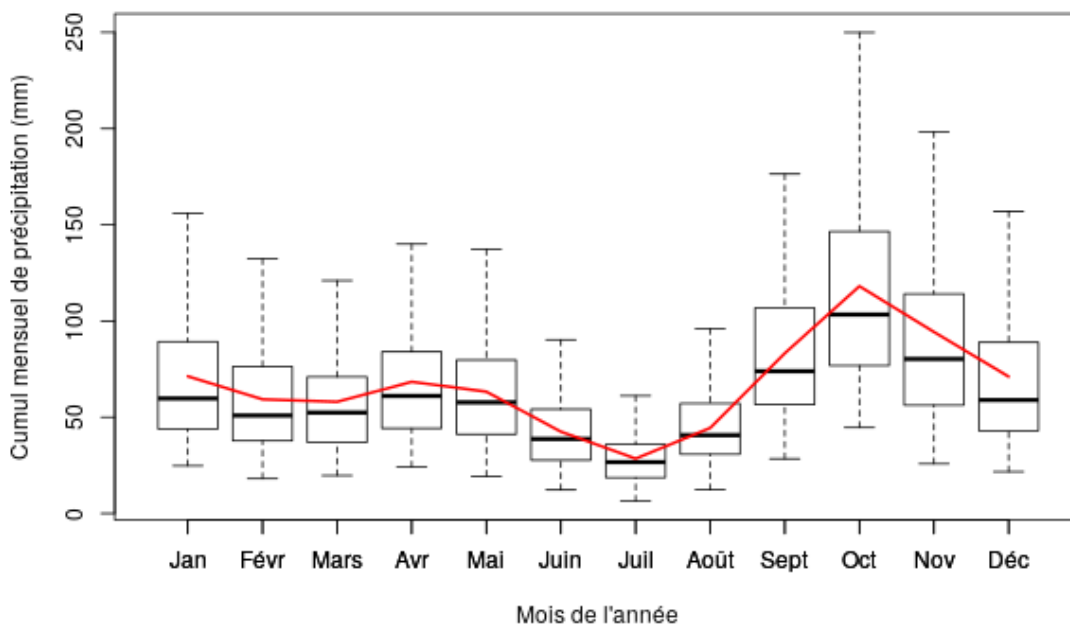


FIGURE 8 – Boxplots des cumuls mensuels moyens des précipitations sur toute la période d'étude pour la région de la Méditerranée française. La courbe rouge indique la moyenne pour chaque mois.

2.2. Présentation des sites d'étude

Suite à la définition de la saison des pluies, la base de données a été restreinte afin de mener une analyse exploratoire exclusive sur cette période. Il est primordial de commencer par une comparaison des cumuls de précipitations pour chaque station en vue de déterminer les disparités relatives aux quantités de pluies enregistrées en différents points de l'espace. D'après la Figure 9, la moyenne du cumul sur la saison pluvieuse est fortement influencée par l'altitude. La vallée du Rhône et le littoral méditerranéen présentent les sous-régions les plus sèches avec les plus faibles cumuls (433.4 mm), tandis que la région montagneuse des Cévennes enregistre les valeurs les plus importantes (1697.3 mm). On retrouve une variation spatiale semblable avec les maxima annuels qui varient entre 55.02 mm et 190.68 mm (voir Figure 10). Cette variation peut s'expliquer par plusieurs facteurs, notamment l'effet orographique, détaillé dans la Section 1.2. Par contre, les valeurs maximales atteintes par chaque station toutes les années confondues ont une répartition spatiale légèrement différente (voir Figure 11). La valeur maximale du cumul journalier observé est de 543 mm/jour, qui coïncide avec les crues du Gard en septembre 2002 (Brunet et al., 2012).




FIGURE 9 – La carte de la moyenne des cumuls annuels sur la saison des pluies pour les 183 stations conservées pour l'étude dans la région de la Méditerranée française.

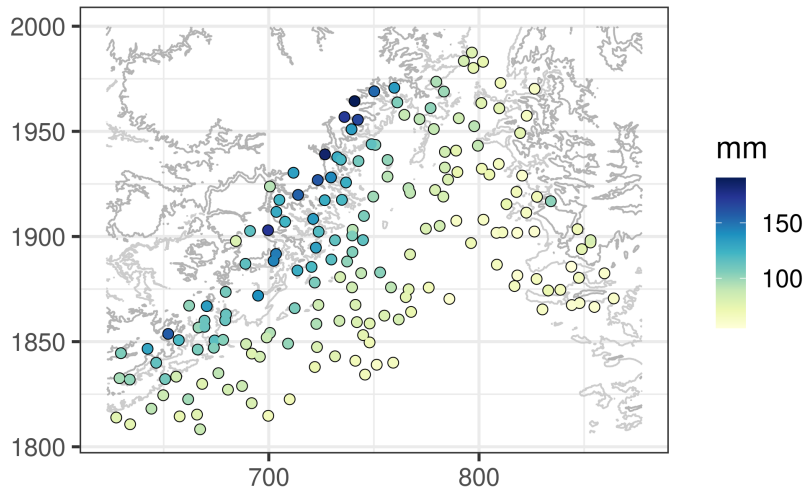


FIGURE 10 – La carte de la moyenne des maxima annuels sur la saison des pluies pour les 183 stations conservées pour l'étude dans la région de la Méditerranée française.




FIGURE 11 – La carte des maxima atteints en une journée pour les 183 stations conservées pour l'étude dans la région de la Méditerranée française.

2.2.2 La région du Merguellil, Tunisie centrale

La deuxième zone d'étude est située en Tunisie centrale, à l'ouest de Kairouan, spécifiquement la région autour du bassin versant de Merguellil (voir Figure 12). Contrairement aux autres régions sélectionnées, cette région n'a pas de côtes sur la mer Méditerranée. L'oued Merguellil, qui donne son nom à la région, est l'un des grands oueds qui aboutissent dans la plaine de Kairouan. Son bassin comporte une partie amont, relativement montagneuse, qui s'étend sur environ 1200 km² et une partie aval située dans une vaste plaine agricole. Entre ces deux parties se trouve le barrage d'El Haouareb qui retient toutes les eaux de l'oued. Il est important de noter que la région fait face à une surexploitation de ses ressources en eau, en raison

de l'augmentation de la population, de l'agriculture et de l'industrie. Diverses structures de conservation des eaux, telles que des lacs et des barrages collinaires, ont été construites dans le but de prévenir l'érosion des sols et d'alimenter certains périmètres irrigués de la région (El Amami et al., 2005).

Le bassin du Merguellil peut être considéré comme un lieu représentatif des défis auxquels fait face l'ensemble du bassin méditerranéen, particulièrement les conditions d'un milieu semi-aride (Leduc et al., 2004). En effet, la région subit une double influence climatique : celle du climat tempéré du nord tunisien, caractérisé par des températures relativement fraîches et des précipitations abondantes, et celle du climat aride du sud, marqué par des températures élevées et des précipitations rares et irrégulières (voir Figure 13). Cette combinaison de facteurs climatiques peut entraîner des conditions environnementales contrastées dans la région, avec d'importantes variations de la pluviométrie. Cette zone se distingue par une grande variabilité spatiale des précipitations avec des épisodes d'inondations et de sécheresses intenses. En raison de son emplacement sur les plaines et de sa proximité de plusieurs cours d'eau, la région a été confrontée à plusieurs reprises à des inondations au cours de son histoire. Ces inondations ont été causées essentiellement par des événements de précipitations extrêmes, des débordements de rivières ou des crues de barrages (Alazard et al., 2015).




FIGURE 12 – Localisation de la zone choisie située dans la région de la Tunisie centrale. Les points noirs indiquent les 26 stations conservées pour l'étude et les lignes bleues délimitent le bassin versant.

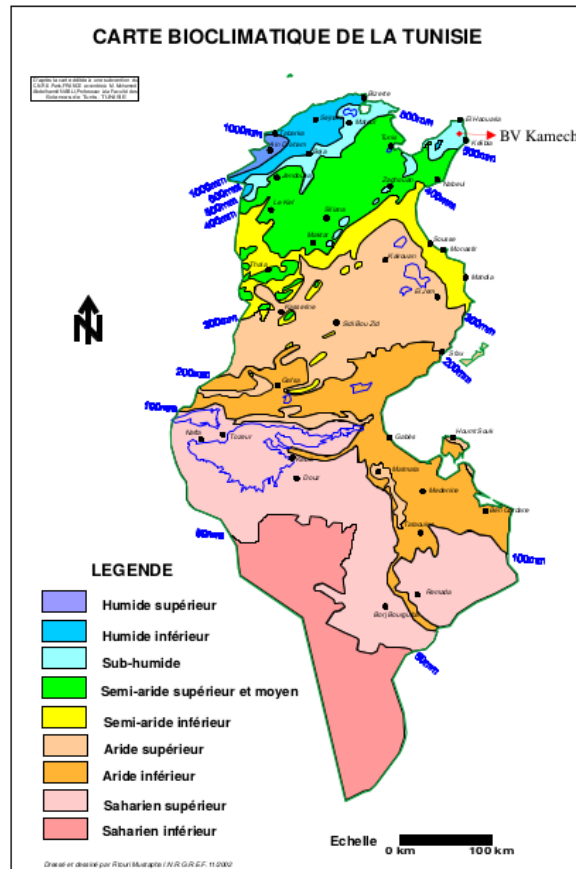


FIGURE 13 – Carte bioclimatique de la Tunisie (Zitouna-Chebbi, 2009).

La base de données disponible dans cette région comporte des séries temporelles de précipitations journalières, enregistrées par les stations météorologiques couvrant l'ensemble du bassin versant, sur la période allant du 01/01/1900 au 31/01/2014. Cette région est caractérisée par des événements de précipitations intenses, surtout au printemps et à l'automne (Ogilvie et al., 2016). Comme pour la région française, la saison des pluies pour cette région a été définie pour s'étendre de septembre à avril, en se basant sur l'observation d'une diminution significative de la moyenne des cumuls de précipitations en dehors de cette période (voir Figure 14). Cette décision vise à concentrer l'analyse exploratoire sur les périodes les plus pertinentes en termes de précipitations, contribuant ainsi à l'obtention de résultats plus précis.

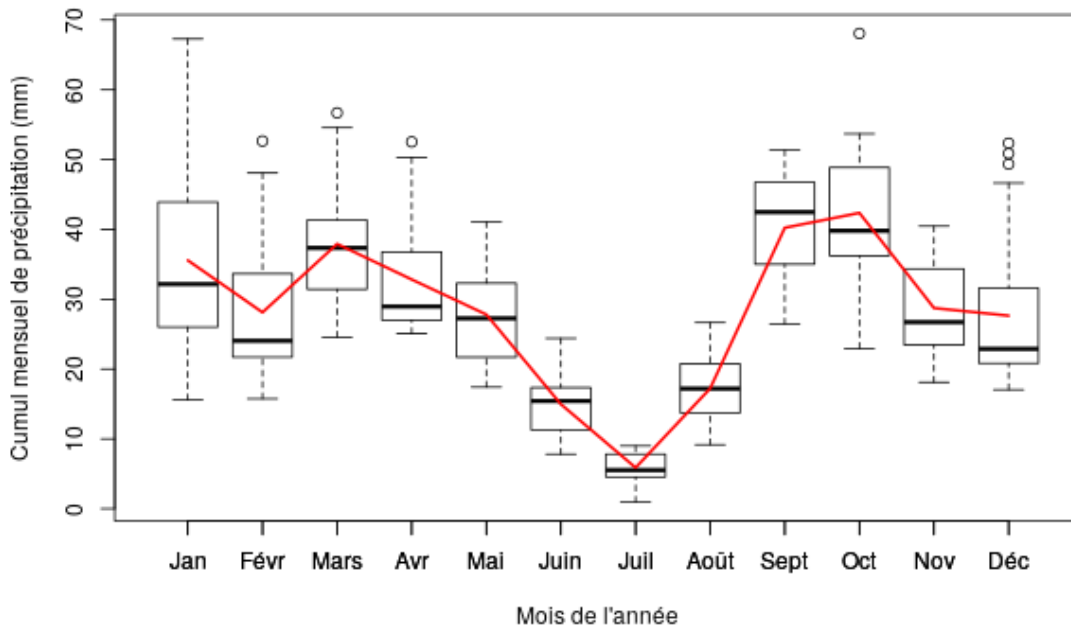


FIGURE 14 – Boxplots des cumuls mensuels moyens des précipitations sur toute la période d'étude au Merguellil, Tunisie. La courbe rouge indique la moyenne pour chaque mois.

Afin de réduire le pourcentage de valeurs manquantes, on a utilisé seulement les stations qui présentent une période d'observations d'au moins 30 ans et avec moins de 10% des valeurs manquantes par saison des pluies. Ainsi, sur l'ensemble des stations météorologiques couvrant le bassin versant, seules 26 répondaient à ce critère et ont été retenues pour l'analyse ultérieure. D'après la carte illustrée dans la Figure 15, il est clair que la moyenne des cumuls annuels au cours de la saison des pluies manifeste une variation significative entre les zones montagneuses en amont et les plaines en aval. Plus précisément, la moyenne est de 430.2 mm sur les hauteurs, tandis que sur la plaine, elle est de seulement 185.6 mm. Cette même variation est observée pour la moyenne des maxima annuels sur la saison des pluies, présentée dans la Figure 16. Cette différence s'explique par les conditions topographiques distinctes des deux régions, les zones montagneuses étant davantage exposées aux masses d'air humide, favorisant ainsi les précipitations, tandis que les plaines connaissent généralement des conditions plus sèches et reçoivent moins de précipitations. En outre, les valeurs maximales journalières de précipitations enregistrées varient considérablement dans le bassin versant étudié, variant entre 61 mm et 278,3 mm (voir Figure 17). La station en aval du bassin est celle qui a enregistré la valeur maximale lors des inondations d'octobre 1969. Cette disparité dans les valeurs maximales de précipitations observées et les moyennes du cumul annuel dans les différentes stations met en évidence l'hétérogénéité des conditions météorologiques locales au sein du bassin versant.

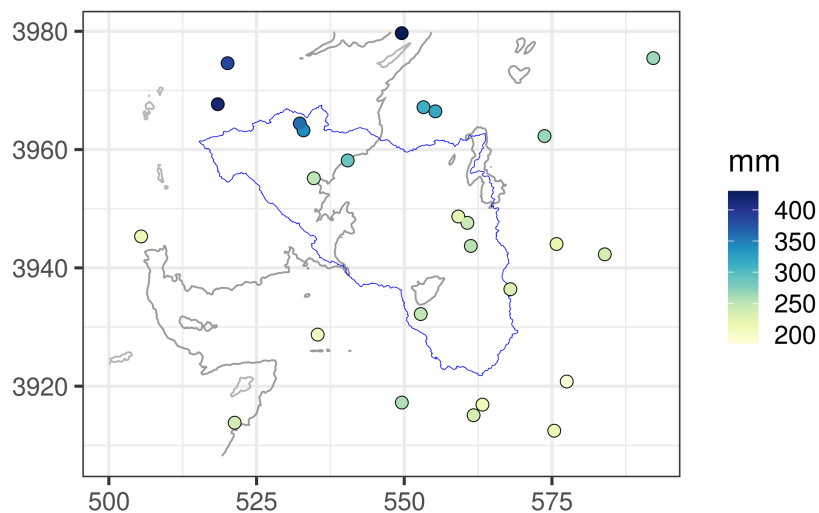


FIGURE 15 – La carte de la moyenne des cumuls annuels sur la saison des pluies pour les 26 stations conservées pour l'étude au Merguellil, Tunisie.

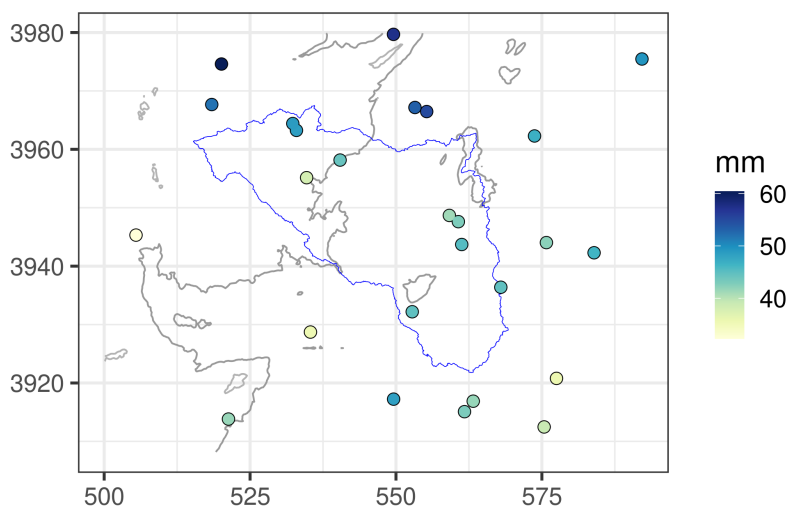


FIGURE 16 – La carte de la moyenne des maxima annuels sur la saison des pluies pour les 26 stations conservées pour l'étude au Merguellil, Tunisie.

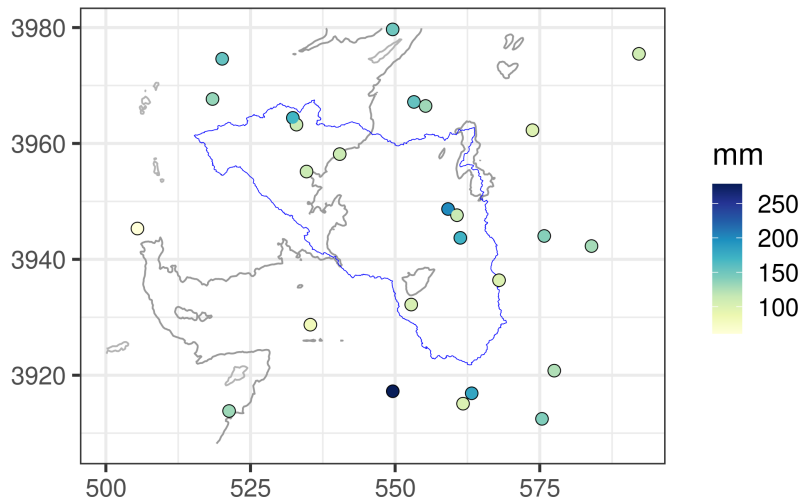


FIGURE 17 – La carte des maxima atteints pour les 26 stations conservées pour l'étude au Merguellil, Tunisie.

2.2.3 La région du Lebna, Cap Bon, Tunisie

La troisième zone d'étude que nous avons sélectionnée est la région du Cap Bon, située à l'extrême nord-est de la Tunisie et correspondant au gouvernorat de Nabeul. Cette région est délimitée par la mer sur trois côtés et se distingue par un relief plutôt irrégulier, avec des caractéristiques différentes entre les côtes ouest et est de la péninsule (voir Figure 18). Le paysage de cette région est varié, comprenant une zone montagneuse à l'ouest atteignant l'altitude maximale au Djebel Abderrahmane, le point le plus élevé de la dorsale tunisienne. Par ailleurs, on y trouve des plaines, des collines, des hauts plateaux et des dépressions. Le choix de cette région comme zone d'étude repose principalement sur son climat méditerranéen subhumide typique, qui en fait un cas d'intérêt particulier pour notre analyse.

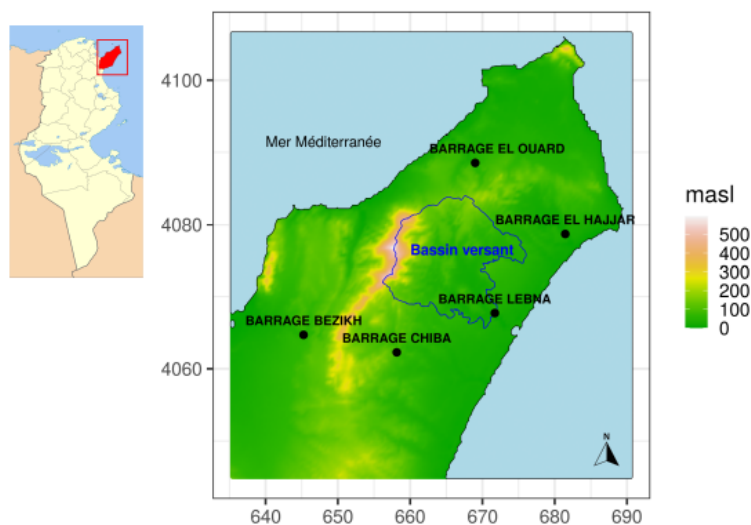


FIGURE 18 – Localisation de la zone choisie située dans la région du Cap Bon, Tunisie.

2.2. Présentation des sites d'étude

Des données de précipitations journalières ont été collectées sur une période allant du 04/01/1919 au 09/30/2014, à partir d'un réseau de stations météorologiques. La Figure 19 illustre la variation de précipitations tout au long de l'année à travers les boxplots des moyennes des cumuls de précipitations. D'après cette figure, on a pu identifier la saison de pluie qui varie du mois de septembre au mois d'avril. Cette constatation cohérente entre les trois sites d'étude nous a permis d'établir une définition uniforme de la saison pluvieuse, ce qui facilitera la comparaison et l'analyse des caractéristiques des précipitations sur l'ensemble des zones étudiées.

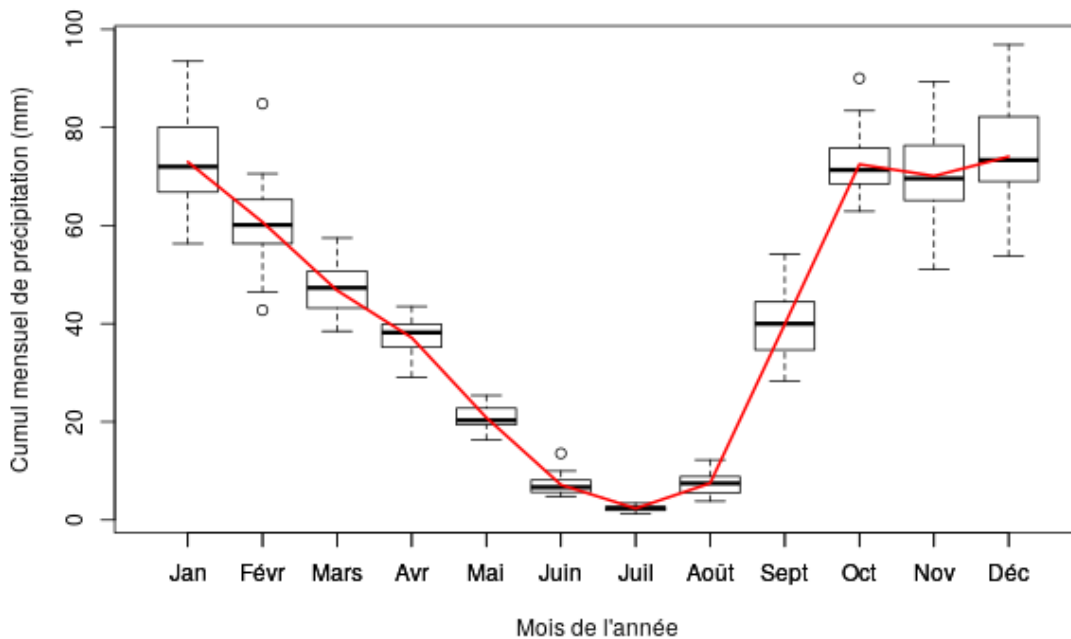


FIGURE 19 – Boxplots des cumuls mensuels moyens des précipitations sur toute la période d'étude au Cap Bon, Tunisie. La courbe rouge indique la moyenne pour chaque mois.

De façon analogue à notre démarche pour les autres sites d'étude, nous avons choisi de n'utiliser que les données provenant des stations météorologiques répondant au critère de sélection (c'est-à-dire celles ayant une période d'observations d'au moins 30 ans et présentant moins de 10% de valeurs manquantes pour chaque saison de pluie). Parmi l'ensemble initial des stations météorologiques, seulement 18 stations (localisées sur la Figure 20) ont répondu à ce critère et ont été conservées pour nos analyses ultérieures. La Figure 20 met en évidence une variation significative de la moyenne des cumuls annuels pendant la saison des pluies, selon une répartition géographique allant du nord-ouest au sud-est, avec des valeurs variant entre 377.3 mm et 583.2 mm. Une variation semblable est observée pour la moyenne des maxima annuels sur la saison des pluies (Figure 21). En revanche, une différence remarquable est observée dans la distribution des valeurs maximales journalières. Toutefois, la station située à l'extrémité de la péninsule se distingue par des valeurs élevées dans les trois cartes.

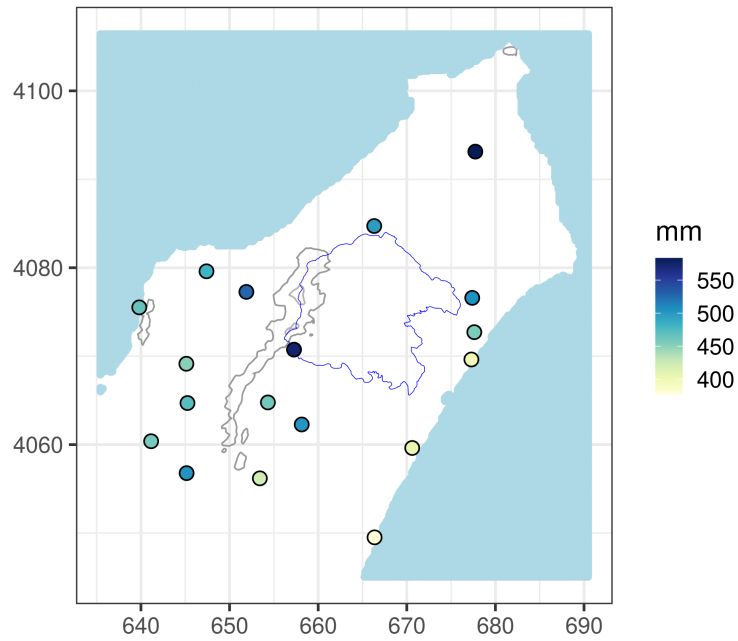


FIGURE 20 – La carte de la moyenne des cumuls annuels sur la saison des pluies pour les 18 stations conservées pour l'étude au Cap Bon, Tunisie.

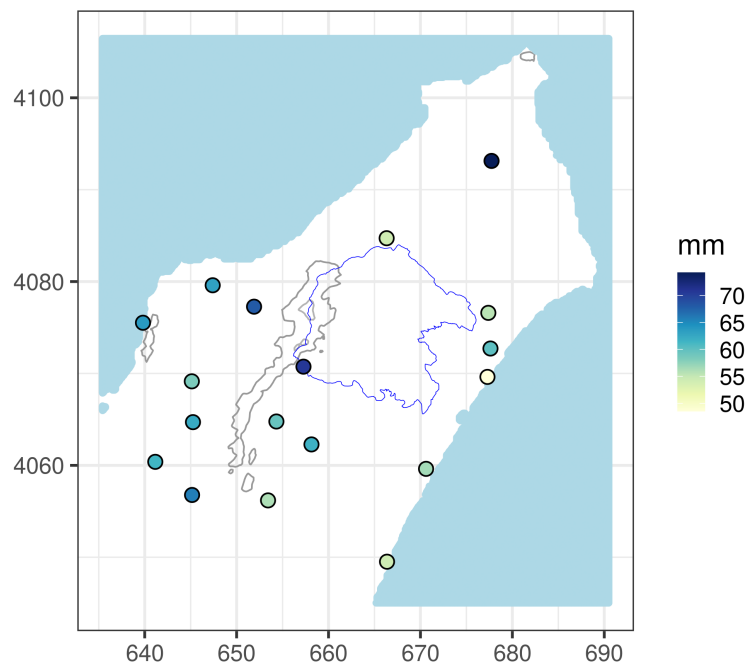


FIGURE 21 – La carte de la moyenne des maxima annuels sur la saison des pluies pour les 18 stations conservées pour l'étude au Cap Bon, Tunisie

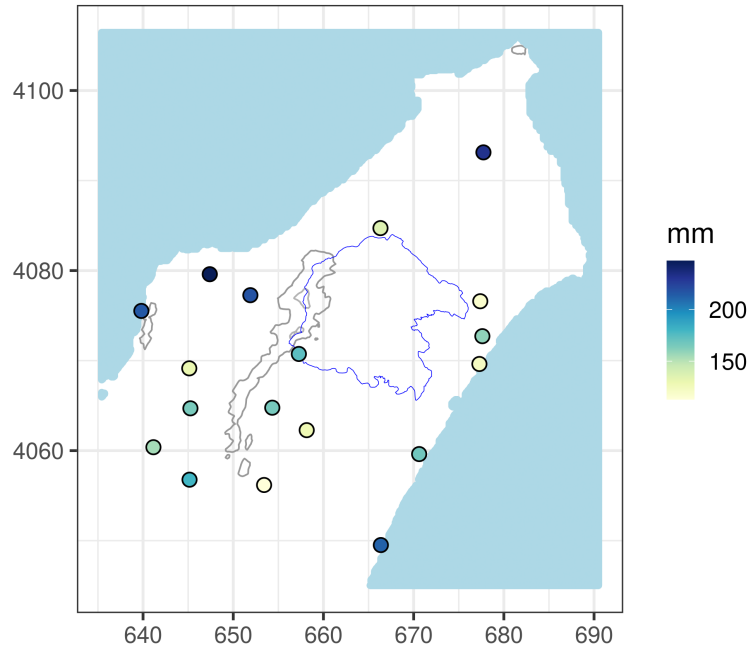


FIGURE 22 – La carte des maxima atteints pour les 18 stations conservées pour l'étude au Cap Bon, Tunisie.

2.3 Base de données CHIRPS

Les données CHIRPS (Climate Hazards Group InfraRed Precipitation with Station data) constituent un produit satellitaire développé en collaboration entre l'US Geological Survey (USGS) et le Climate Hazards Group de l'Université de Californie, Santa Barbara (UCSB). Il s'agit des données de précipitations maillées à haute résolution spatiale ($0.05^\circ \times 0.05^\circ$) définies à l'échelle du globe, sur une période qui s'étale de 1981 jusqu'à présent (Funk et al., 2015). Les informations qui interviennent dans la création des données CHIRPS sont les suivantes :

1. Des données de précipitations moyennes mensuelles fournies par CHPclim (Climate Hazards Precipitation Climatology).
2. Des observations par satellite infrarouge thermique géostationnaire issues de sources de la NOAA (National Oceanic and Atmospheric Administration) : le Centre National des Données Climatiques (NCDC) et le Centre de prévision du Climat (CPC).
3. Le produit TRMM-3B42 de la NASA.
4. Des prévisions des précipitations obtenues des modèles atmosphériques du système de prévision climatique de la NOAA (CFSv2).
5. Des mesures des précipitations in-situ.

Il s'agit donc d'une estimation spatiale et temporelle des précipitations en combinant les données satellitaires avec celles provenant des stations météorologiques. Ainsi, cela sert à produire des cartes de précipitations dans des zones où les données de surface sont rares.

Cependant, ces informations ne sont pas utilisées directement pour analyser les extrêmes en raison de leur résolution spatiale élevée et du biais potentiel existant entre ces données et les observations des stations de mesure. Néanmoins, elles peuvent être intégrées dans des modèles climatiques en conjonction avec d'autres données météorologiques afin de prévoir les conditions futures liées aux précipitations. Dans le cas de notre étude, ces données ont été utilisées pour calculer des cumuls saisonniers moyens sur les trois sites d'études. Ces valeurs moyennes saisonnières sont ensuite incorporées comme covariables dans notre analyse.

Dans le présent travail, les données CHIRPS ont été extraites de 1981 à 2019 sur les trois sites d'étude¹. Les coordonnées de longitude et de latitude ont été projetées sur les coordonnées Lambert 2. Ensuite, une interpolation bi-linéaire a été appliquée à ces valeurs pour permettre une meilleure correspondance avec la grille du MNT. Finalement, la valeur de la maille de grille la plus proche a été attribuée pour chaque station. Cette valeur constitue la covariable qui sera utilisée à la modélisation statistique subséquente.

2.4 Comparaison des trois sites d'étude

L'analyse comparative des variables hydrométéorologiques, basée sur des données collectées en des points spécifiques de chaque site, est une étape essentielle pour mieux comprendre les différences et les similitudes entre les régions. Le tableau 2.1 synthétise les résultats issus de l'analyse exploratoire des données pour les trois sites d'étude. Cette analyse offre un aperçu des différentes caractéristiques observées dans les variables hydrométéorologiques entre les régions, mettant ainsi en évidence les particularités propres à chaque site.

	La Méditerranée française	Merguellil, Tunisie	Cap Bon, Tunisie
<i>Nombre de stations</i>	183	26	18
<i>Altitude en masl (moyenne/max)</i>	539.1 - 2694.5	459.54 - 1348.29	80.26 - 595.07
<i>Cumul annuel moyen en mm (min/max)</i>	433.4 - 1697.3	185.6 - 430.2	377.3 - 583.2
<i>Nombre moyen de jours de pluie (>1mm) par saison</i>	41.96	10.72	24.28
<i>Précipitation maximale en une journée sur toute la période d'observation en mm</i>	543	278.3	247

TABLEAU 2.1 – Comparaison des caractéristiques des trois sites d'étude.

1. accessibles via <https://www.chc.ucsb.edu/data/chirps>, fournies en format .TIFF, .NetCDF ou .HDF

2.4. Comparaison des trois sites d'étude

Le nombre de stations de mesure sélectionnées pour le site français est significativement plus élevé que celui des sites tunisiens. Cette différence s'explique notamment par la disponibilité et la densité des réseaux de mesure dans chaque pays. En effet, la France dispose d'un réseau de stations de mesure hydrométéorologiques relativement dense, tandis que la Tunisie connaît des contraintes qui limitent la mise en place d'un grand nombre de stations. Cependant, la sélection des stations de mesure a été réalisée de manière rigoureuse et en tenant compte des caractéristiques propres à chaque site d'étude. Les stations ont été sélectionnées principalement sur la base de leur représentativité spatiale, en veillant à couvrir les bassins versants de manière adéquate. Ainsi, même si le nombre de stations de mesure est plus limité en Tunisie, les données recueillies ont été sélectionnées de manière à assurer leur pertinence et leur fiabilité.

Parmi les trois sites d'étude, le site de la Méditerranée française se distingue par ses caractéristiques hydrométéorologiques. Cette particularité est observée notamment à travers le cumul annuel moyen des précipitations ainsi que le nombre moyen de jours de pluie, qui se révèlent nettement plus élevés par rapport aux sites tunisiens. De plus, les précipitations maximales enregistrées en une seule journée affichent des valeurs significativement supérieures à celles enregistrées dans les sites tunisiens. Cette différence s'explique par le fait que le site français est situé dans une zone où les conditions météorologiques sont plus instables et où les précipitations sont plus fréquentes et plus intenses. Par contre, le site du Merguellil a le plus faible cumul annuel moyen et le plus faible nombre moyen de jours de pluie par saison pluvieuse. Ces indicateurs reflètent le climat semi-aride de cette région, où les précipitations sont moins fréquentes et moins abondantes. Par ailleurs, l'altitude est un paramètre important à considérer lorsqu'on analyse les caractéristiques hydrométéorologiques car elle peut avoir une influence significative sur les précipitations. Selon les informations présentées dans la Figure 23, les trois sites d'étude présentent des différences significatives en termes de relief. La région du Cap Bon est caractérisée par une topographie relativement plane, s'élevant jusqu'à une altitude de 595.07m. En revanche, les deux autres sites présentent des reliefs plus marqués, avec des altitudes allant jusqu'à 2694.5m pour le site français et jusqu'à 1348.29m pour le site Merguellil.

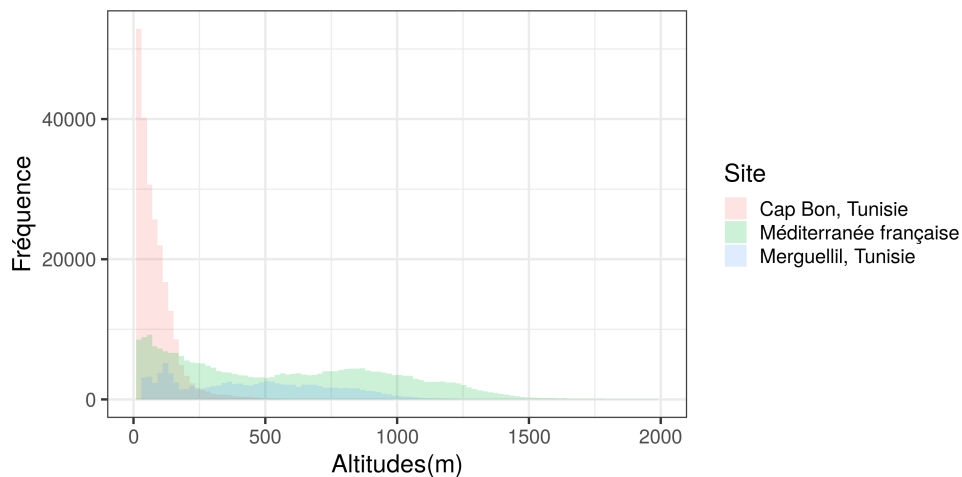


FIGURE 23 – Histogrammes de comparaison d'altitudes pour les trois sites d'étude.

Par rapport aux données de réanalyse CHIRPS, la comparaison des points de grille les plus proches, avec les données de pluviomètres observées, est présentée dans la Figure 24. Pour la région de la Méditerranée française, on constate que les moyennes des cumuls de précipitations saisonnières CHIRPS sont moins faibles que les données issues des stations de mesure ponctuelles. La différence de la qualité entre ces deux types de données peut s'expliquer par plusieurs facteurs. D'une part, les données CHIRPS sont généralement plus complètes et représentatives que les données ponctuelles, car elles couvrent une plus grande superficie et sont collectées sur une plus longue période. D'autre part, les données du CHIRPS sont moins sujettes aux erreurs de mesure que les données ponctuelles, car elles proviennent d'un grand nombre de sources de données.

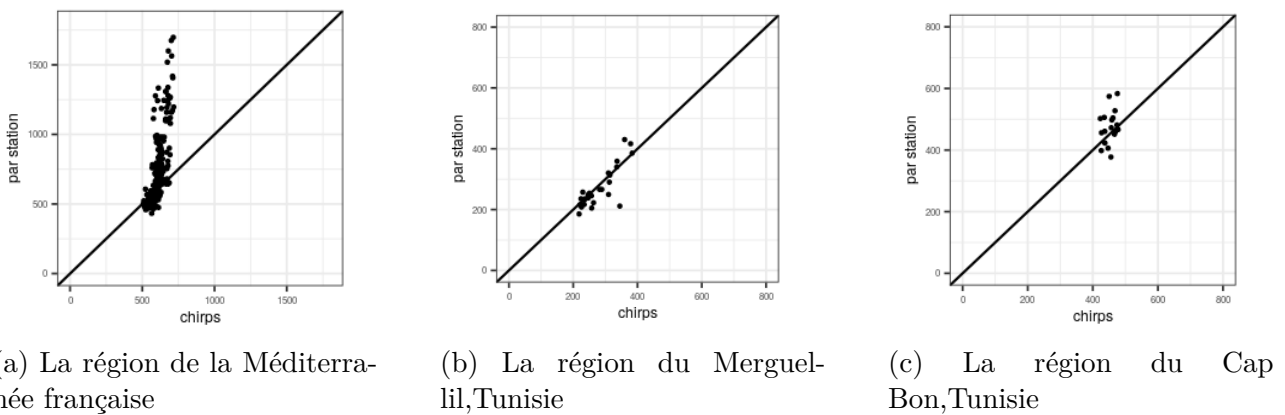


FIGURE 24 – Comparaison des précipitations saisonnières moyennes des données CHIRPS avec celles observées par les pluviomètres pour les trois sites d'étude.

2.5 Synthèse

Dans ce chapitre, nous explorons les caractéristiques géographiques et hydro-météorologiques de trois régions méditerranéennes spécifiques, à savoir le sud de la France, la Tunisie centrale autour du bassin de Merguelil, et le Cap Bon en Tunisie. Une attention particulière est accordée aux données pluviométriques journalières, qui comprennent à la fois des observations ponctuelles et des réanalyses CHIRPS. L'analyse statistique descriptive des données révèle l'existence de régimes de précipitations distincts dans ces régions, particulièrement dans les cumuls annuels et les extrêmes de précipitations. Ces disparités soulignent l'influence majeure de la topographie et du climat local sur les schémas de précipitations observés. Ainsi, ces résultats mettent en évidence l'importance de prendre en compte les caractéristiques géographiques spécifiques de chaque région méditerranéenne pour comprendre et interpréter les phénomènes hydro-météorologiques.

Modélisation des intensités de précipitations ponctuelles extrêmes

3.1 Introduction

Ce chapitre est consacré à présenter les principaux outils statistiques utilisés pour modéliser les événements de précipitations extrêmes. Il s'agit d'événements qui se produisent avec une très faible probabilité et qui prennent des valeurs beaucoup plus grandes que celles habituellement observées. En effet, la Théorie des Valeurs Extrêmes (TVE) offre un cadre mathématique rigoureux pour décrire le comportement des queues des distributions, ce qui permet en particulier d'estimer les risques associés à ces événements (Coles, 2001). Cette théorie propose essentiellement deux approches pour identifier les valeurs extrêmes. La première approche consiste à considérer le maximum par blocs de temps, tandis que la deuxième approche se concentre sur les valeurs dépassant un seuil suffisamment élevé. La différence entre ces deux approches est illustrée dans la Figure 25. Le panneau de gauche montre les maxima de précipitations journalières $\{X_1, X_2, X_3, X_4\}$ par blocs de temps et le panneau de droite présente les maxima $\{X_1, X_3, X_5, X_6\}$ qui dépassent un seuil fixé.

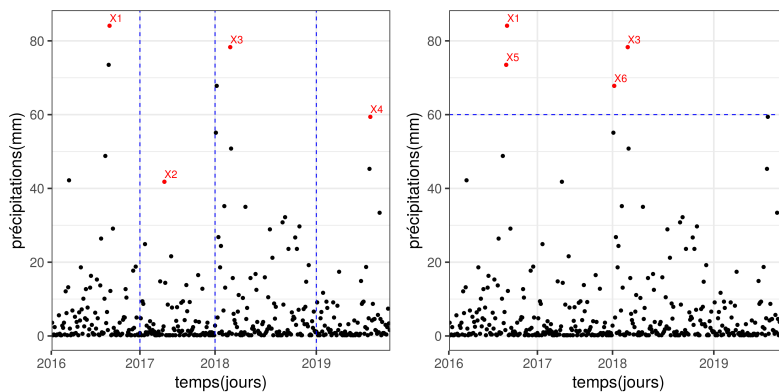


FIGURE 25 – Données de précipitations journalières observées à la station de Montpellier en mm/jour entre 2016 et 2019. Les lignes en pointillés représentent à gauche les blocs annuels et à droite le seuil fixé à 60mm.

Pour décrire la distribution des valeurs extrêmes, nous utilisons des lois de probabilité spécifiques à chaque approche, qui sont abordées en détail dans les sections 3.2.1 et 3.2.2. Ensuite, nous présentons la loi de Pareto généralisée étendue (EGPD) 3.4 qui sera utilisé pour modéliser les précipitations extrêmes et ordinaires conjointement. Les méthodes utilisées pour estimer les paramètres de chaque distribution sont présenté dans l'annexe. Pour plus de détails et d'éventuelles démonstrations, nous recommandons de se référer aux travaux de référence suivants (Coles, 2001; Beirlant et al., 2004; De Haan and Ferreira, 2007).

3.2 Théorie des valeurs extrêmes

3.2.1 Approche des maxima par blocs

Soit $X_1 \dots X_n$ un échantillon de variables aléatoires indépendantes et identiquement distribuées (i.i.d) dont la fonction de répartition est F définie par $F(X) = \mathbb{P}(X \leq x)$. On désigne par $M_n = \max\{X_1 \dots X_n\}$ la variable aléatoire représentant la série des maxima de blocs. La distribution de ce maximum peut s'écrire comme suit :

$$\mathbb{P}\{M_n \leq x\} = F(x)^n \quad (3.1)$$

Cependant, cette relation ne peut pas être utilisée dans la pratique puisque la fonction de distribution F est inconnue. Pour y remédier, la TVE a fourni une alternative en identifiant une distribution limite pour F^n sans connaître F .

Théorème 1 (*Fisher and Tippett, 1928; Gnedenko, 1943*)

Soit $(X_n)_{n \geq 1}$ une suite de variables aléatoires i.i.d de fonction de répartition F . Supposons qu'il existe deux suites normalisantes réelles $(a_n)_{n \geq 1} \in \mathbb{R}_+^*$ et $(b_n)_{n \geq 1} \in \mathbb{R}$ et une fonction de distribution limite non-dégénérée G telles que :

$$\lim_{n \rightarrow +\infty} \mathbb{P}\left(\frac{M_n - b_n}{a_n} \leq x\right) = \lim_{n \rightarrow +\infty} F^n(a_n x + b_n) = G(x) \quad \forall x \in \mathbb{R} \quad (3.2)$$

alors G appartient à l'une des trois classes suivantes :

$$G_1(x) = \exp\{-\exp[-(\frac{x-b}{a})]\}, x \in \mathbb{R} \quad (3.3)$$

$$G_2(x) = \begin{cases} \exp\{-\exp[-(\frac{x-b}{a})^{-\alpha}]\} & ,si x > b \\ 0 & ,si x \leq b \end{cases} \quad (3.4)$$

$$G_3(x) = \begin{cases} \exp\{\exp[-(\frac{x-b}{a})^\alpha]\} & ,si x < b \\ 1 & ,si x \geq b \end{cases} \quad (3.5)$$

où $\alpha, a > 0$ et $b \in \mathbb{R}$.

Ces trois classes de distribution sont appelées distributions de valeurs extrêmes. Ils sont les seules limites possibles pour les distributions de la variable M_n normalisée, quelle que soit la distribution F . Une proposition, issue des travaux de Von Mises (1954) et de Jenkinson (1955), a permis de disposer d'une famille paramétrique unifiée des trois types de distribution selon la définition suivante.

Définition 1 *La loi de valeurs extrêmes généralisée (GEV) est la loi de probabilité avec la fonction de répartition G donnée par :*

$$G(x) = \begin{cases} \exp[-\{1 + \xi(\frac{x-\mu}{\sigma})\}_+^{-1/\xi}] & ,si \xi \neq 0 \\ \exp[-\exp(-(\frac{y-\mu}{\sigma}))] & ,si \xi = 0 \end{cases} \quad (3.6)$$

où x est tel que $1 + \xi(x - \mu)/\sigma > 0$, $\mu \in \mathbb{R}$, $\sigma > 0$, $\xi \in \mathbb{R}$, et $x_+ = \max(x, 0)$.

Les paramètres de la GEV sont μ le paramètre de position, σ le paramètre d'échelle et ξ le paramètre de forme. Chaque distribution correspond à un comportement différent du maximum contrôlé par le paramètre de forme ξ :

- Si $\xi > 0$: l'extrémité supérieure de G est infinie et la distribution est à queue lourde, i.e. la queue de la distribution décroît de façon polynomiale (famille de Fréchet).
- Si $\xi = 0$: l'extrémité supérieure de G est infinie et la distribution est à queue légère, i.e. la queue de la distribution décroît de façon exponentielle (famille de Gumbel).
- Si $\xi < 0$: l'extrémité supérieure de G est finie, la queue de distribution est bornée, i.e. il existe une valeur finie que le maximum ne peut dépasser (famille de Weibull).

La Figure 26 représente les fonctions de répartition des lois des valeurs extrêmes dans ces trois cas.




FIGURE 26 – Fonctions de répartition de la GEV pour $\mu = 0, \sigma = 1, \xi = (-0.4, 0, 0.4)$

Remarque 1 *Si F vérifie le théorème 1, on dit alors que F appartient au domaine d'attraction de G et on note $F \in D(G)$.*

En pratique, les événements sont observés sur une période de temps qui est divisée en blocs, généralement d'une durée d'un an. Comme on s'intéresse dans ce travail à la modélisation des précipitations en milieu méditerranéen, nous avons choisi d'utiliser des blocs correspondant à la saison des pluies. Cette approche nous permet de regrouper les précipitations saisonnières d'une même année, formant ainsi un échantillon homogène. En étudiant de manière cohérente les caractéristiques des précipitations pendant la saison des pluies, nous sommes en mesure d'obtenir des résultats plus significatifs.

Niveau de retour de la GEV

Pour quantifier les extrêmes sur la base de leur fonction de distribution, on considère généralement les quantiles supérieurs d'ordre élevé. Ces quantiles, également appelés *niveaux de retour*, sont exprimés en termes de périodes de retour plutôt qu'en termes de probabilité. La période de retour d'un événement, notée T , représente la durée moyenne entre deux occurrences successives de cet événement. En d'autres termes, le niveau de retour associé à la période de retour $T = \frac{1}{p}$ est le niveau que l'on s'attend à dépasser, en moyenne, une fois toutes les T années.

Dans le cas de la GEV, le niveau de retour x_p est obtenue en inversant l'équation 3.6 :

$$x_p^{GEV} = \begin{cases} \mu - \frac{\sigma}{\xi} [1 - (-\log(1-p))^{-\xi}] & , \text{si } \xi \neq 0 \\ \mu - \sigma \log(-\log(1-p)) & , \text{si } \xi = 0 \end{cases} \quad (3.7)$$

où $G(x_p) = 1-p$ et p est la probabilité $0 \leq p \leq 1$. Les estimations de chaque paramètre de la GEV ($\hat{\mu}, \hat{\sigma}, \hat{\xi}$) peuvent être ensuite substitués dans l'équation (3.7) pour obtenir les estimations du niveau de retour \hat{x}_p .

3.2.2 Approche des dépassements de seuils

L'approche des dépassements de seuil repose sur le comportement des observations dépassant un certain seuil fixé. Dans ce cas, l'idée de base consiste à choisir un seuil suffisamment élevé et à étudier les excès au-delà de ce seuil. Soit un échantillon X_1, \dots, X_n , i.i.d de distribution F et de point terminal pouvant être infini $x_F = \sup\{x \in \mathbb{R}, F(x) < 1\}$. On se fixe un seuil u suffisamment élevé et nous ne prenons en compte que les observations qui dépassent ce seuil. On note $\{Y_1, \dots, Y_{N_u}\} = \{X_i - u | X_i > u, 1 \leq i \leq n\}$ les excès au-delà du seuil u , tel que $N_u = \text{Card}\{X_i > u\}$. La fonction de répartition de ces excès est alors donnée par :

$$\begin{aligned}
 F_u(y) &= \mathbb{P}(Y \leq y | X > u) \\
 &= \mathbb{P}(X - u \leq y | X > u) \\
 &= \frac{F(u+y) - F(u)}{1 - F(u)}
 \end{aligned} \tag{3.8}$$

Définition 2 La distribution de Pareto généralisée (GPD) est la loi de probabilité avec la fonction de répartition H donnée par :

$$H(x) = \begin{cases} 1 - \left[1 + \frac{\xi x}{\sigma}\right]^{-1/\xi} & , \text{si } \xi \neq 0 \\ 1 - \exp\left(-\frac{x}{\sigma}\right) & , \text{si } \xi = 0 \end{cases} \tag{3.9}$$

où $x \geq 0$ si $\xi \geq 0$ et $0 \leq x \leq -\frac{\sigma}{\xi}$ si $\xi < 0$ et $\sigma > 0$

Théorème 2 (Balkema and De Haan, 1974; Pickands, 1975) Une fonction de répartition F appartient au domaine d'attraction de G , si et seulement si, il existe une fonction $\sigma(\cdot)$ strictement positive et un réel ξ telles que la loi des excès au delà d'un seuil u peut être approchée uniformément par une loi de Pareto généralisée i.e.

$$\lim_{u \rightarrow x_F} \sup_{0 \leq x \leq x_F - u} |F_u(x) - H(x)| = 0 \tag{3.10}$$

Les paramètres de cette distribution sont liés aux paramètres de la distribution des valeurs extrêmes GEV. En particulier, la nature du comportement de la queue supérieure, contrôlée par le paramètre ξ , est la même pour les deux distributions. Nous représentons dans la Figure 27, les courbes rouge, bleue et verte correspondent respectivement aux fonctions de répartition des lois de Pareto généralisées de paramètres $\xi < 0$, $\xi = 0$ et $\xi > 0$ avec σ fixe.




FIGURE 27 – Fonctions de répartition des lois de valeurs extrêmes généralisées pour $\sigma = 1$ et $\xi = (-0.4, 0, 0.4)$

Sélection de seuil

L'un des principaux défis de l'ajustement GPD est de choisir un seuil adéquat. Ce choix est crucial car le niveau du seuil a un impact direct sur la taille de l'échantillon de données. En fait, il faut que ce choix vérifie un compromis entre le caractère asymptotique du modèle et le nombre suffisant de dépassements. Un seuil trop élevé produit un nombre très faible de valeurs à traiter. D'autre part, un seuil trop bas garantit un plus grand nombre d'observations, mais dans ce cas, l'approximation par la GPD peut ne pas être assurée. Bien que plusieurs techniques de sélection des seuils aient été proposées dans la littérature, il ne semble pas y avoir d'approche universelle pour les déterminer (e.g. (Coles, 2001; Beirlant et al., 2004; Raymond-Belzile, 2019)).

Diverses méthodes sont proposées dans la littérature pour estimer le seuil. Certaines méthodes sont graphiques, tandis que d'autres sont numériques. Les approches graphiques sont basées sur une analyse visuelle, comme par exemple le graphique de la fonction des excès moyens qui illustre la relation entre les excès moyens et différents seuils. Cette méthode permet de sélectionner un seuil à partir duquel la relation devient approximativement linéaire (Coles, 2001). Bien qu'ils soient largement utilisés, ces approches non paramétriques ne sont pas simples à appliquer en pratique car elles sont sujettes à un jugement subjectif dans l'interprétation des graphiques résultants.

D'autre part, les méthodes numériques fournissent une estimation du seuil de manière plus objective, tel que des approches basées sur des tests d'adéquation ou des approches computationnelles entre autres. Une possibilité consiste à utiliser un quantile empirique élevé des données (Smith, 1989). Par exemple, le seuil peut être fixé aux quantiles 98% (Carreau et al., 2017) des intensités de précipitations. D'autres études ont défini le seuil en se basant sur des événements de précipitations intenses dans une région spécifique, tel qu'un seuil de 100mm dans la même région de France que celle de notre étude (Soubeyroux et al., 2015).

Trouver le seuil optimal est une tâche encore discutée aujourd'hui, et de nombreuses suggestions provenant de différentes perspectives ont émergé dans la littérature. Récemment, de nouvelles méthodes ont été développées dans le but d'automatiser ce processus, telles que la sélection des seuils basée sur la méthode des L-moments introduite par (Silva Lomba and Fraga A., 2020).

Niveau de retour de la GPD

De manière analogue à la définition du niveau de retour des maxima par blocs, nous pouvons définir la notion de niveau de retour des dépassements de seuils. Supposons que la GPD soit un modèle approprié pour les dépassements, alors la probabilité des dépassements d'une variable X au-dessus d'un seuil élevé approprié u , tel que $x > u$ et $\xi \neq 0$, peut être écrite comme suit :

$$\mathbb{P}\{X > x | X > u\} = \left[1 + \xi \left(\frac{x - u}{\sigma}\right)\right]^{-\frac{1}{\xi}} \quad (3.11)$$

Si on considère la probabilité d'un dépassement du seuil u , notée $\zeta_u = \mathbb{P}\{X > u\}$, alors :

$$\mathbb{P}\{X > x\} = \zeta_u \left[1 + \xi \left(\frac{x-u}{\sigma}\right)\right]^{-\frac{1}{\xi}} \quad (3.12)$$

Ainsi, le niveau x_m qui est dépassé en moyenne une fois toutes les m observations est la solution de :

$$\zeta_u \left[1 + \xi \left(\frac{x_m - u}{\sigma}\right)\right]^{-\frac{1}{\xi}} = \frac{1}{m} \quad (3.13)$$

Ce qui donne :

$$x_m^{GPD} = \begin{cases} u - \frac{\sigma}{\xi} [(m\zeta_u)^\xi - 1] & \text{si } \xi \neq 0 \\ u + \sigma \log(m\zeta_u) & \text{si } \xi = 0 \end{cases} \quad (3.14)$$

x_m est appelé le niveau de retour des m -observations. Si on s'intéresse au niveau de retour à T années, on note n_y le nombre d'observations par année, alors $m = T \times n_y$. Par conséquent, le niveau de retour à T années est défini par :

$$x_T^{GPD} = \begin{cases} u - \frac{\sigma}{\xi} [(Tn_y\zeta_u)^\xi - 1] & \text{si } \xi \neq 0 \\ u + \sigma \log(Tn_y\zeta_u) & \text{si } \xi = 0 \end{cases} \quad (3.15)$$

3.3 Tests d'adéquation

Les tests d'adéquation sont utilisés pour vérifier la compatibilité des données observées avec une distribution choisie a priori. Pour effectuer cette évaluation, il est courant d'utiliser des tests statistiques non-paramétriques tels que le test de Kolmogorov-Smirnov (KS) (e.g (Ceresetti et al., 2010; Carreau and Girard, 2011)), ou bien avec les graphiques quantiles-quantiles (qq-plot) (e.g (Pujol and Neppel, 2007; Lazoglou and Anagnostopoulou, 2017)).

3.3.1 Test de Kolmogorov-Smirnov

Soit $X = x_1, \dots, x_n$ une variable aléatoire de fonction de répartition F . On pose ces deux hypothèses :

1. Hypothèse nulle (\mathcal{H}_0) : X suit la loi F .
2. Hypothèse alternative (\mathcal{H}_1) : X suit une autre loi que F

Si l'hypothèse \mathcal{H}_0 est correcte, alors la fonction de répartition empirique F_n de l'échantillon doit être proche de F (Stephens, 1974). La statistique de test utilisée est définie comme suit :

$$D_n = \sup_{x \in \mathbb{R}} |F_n(x) - F(x)| \quad (3.16)$$

Si $D_n > D_\alpha(n)$, l'hypothèse \mathcal{H}_0 est rejetée avec un risque α . Un tableau des valeurs critiques de $D_\alpha(n)$ a été construit (Marsaglia et al., 2003) pour différentes tailles d'échantillon n et différents niveaux de signification α . Dans cette étude, le test KS a été appliqué pour évaluer l'ajustement de la GEV et GPD, avec un niveau de signification de 5%.

3.3.2 Les graphiques quantiles-quantiles

Le graphique quantiles-quantiles (également connu sous le nom de qq-plot) est un outil de diagnostic visuel pratique qui permet d'examiner si un échantillon provient d'une distribution spécifique. Plus précisément, les quantiles d'une distribution empirique sont comparés aux quantiles d'une distribution théorique, en supposant que les données proviennent de la GEV (ou GPD) ajustée.

Supposons les valeurs observées ordonnées dans l'ordre croissant $x_1 \leq x_2 \leq \dots \leq x_n$ et \hat{F} la distribution empirique. Alors le graphique qq-plot est constitué de l'ensemble des points :

$$\{(F^{-1}(\hat{F}(x_i)), x_i)\}, i = 1, \dots, n \quad (3.17)$$

Si les données suivent parfaitement la distribution théorique, le graphe de cet ensemble de points doit se positionner suivant la première diagonale.

3.4 La loi de Pareto généralisée étendue (EGPD)

Récemment, une distribution qui assure une représentation de l'intensité des précipitations a été proposée par Naveau et al. (2016) en s'inspirant du travail de Papastathopoulos and Tawn (2013). La loi de Pareto généralisée (EGPD) a l'avantage d'utiliser toute l'information présente dans l'échantillon de données de précipitations non nulles et non pas seulement une valeur par bloc (comme dans la distribution GEV) ou seulement les valeurs supérieures à un seuil donné (comme dans la distribution GPD). Elle ne nécessite pas le choix d'un seuil GPD et présente l'avantage d'être conforme à la théorie des valeurs extrêmes dans les queues inférieures et supérieures tout en assurant une transition fluide entre les deux.

La distribution EGPD est définie par la fonction de distribution donnée par :

$$F(x) = T(H(\frac{x}{\sigma})) \quad \forall x > 0 \quad (3.18)$$

où T est une fonction continue sur $[0, 1]$ et H est la fonction de distribution de la GPD telle que définie à la Section 3.2.2. Afin de garantir le comportement des queues inférieures et supérieures, trois contraintes doivent être satisfaites pour toute fonction T candidate :

1. $\lim_{v \rightarrow 0} \frac{T(v)}{v} = c_1$
2. $\lim_{v \rightarrow 0} \frac{T(vw(v))}{G(v)} = c_2$

$$3. \lim_{v \rightarrow 0} \frac{T(v)}{v^k} = c_3$$

pour certaines valeurs finies et positives c_1 , c_2 et c_3 , avec $w(v)$ est toute fonction positive telle que $w(v) = 1 + o(v)$ lorsque $v \rightarrow 0$. Il en découle quatre modèles paramétriques différents pour G qui satisfont ces contraintes pour $T(v)$, où $v \in [0, 1]$:

1. **Modèle 1** : $T(v) = v^\kappa$, $\kappa > 0$. Ce modèle de loi de puissance dépend de trois paramètres : σ le paramètre d'échelle, ξ le paramètre de forme qui contrôle le taux de décroissance de la queue supérieure et κ le paramètre de forme de la queue inférieure ($\kappa = 1$ nous permet de retrouver le modèle GPD).
2. **Modèle 2** : $T(v) = 1 - Q_\delta\{(1-v)^\delta\}$, $\delta > 0$, où Q_δ est le cdf d'une variable aléatoire beta de paramètres $1/\delta$ et 2. Ce modèle, lié aux travaux de (Falk et al., 2010), dépend de trois paramètres : σ le paramètre d'échelle, ξ le paramètre de forme de la queue supérieure et δ contrôle la partie centrale de la distribution de manière à régler le seuil. Dans ce cas, le comportement de la queue inférieure est imposé par le choix du modèle au lieu d'être estimé à partir des données.
3. **Modèle 3** : $T(v) = [1 - Q_\delta\{(1-v)^\delta\}]^{\frac{\kappa}{2}}$. Un paramètre supplémentaire κ est ajouté pour contourner la limitation du modèle 2. Cela conduit à un modèle avec quatre paramètres : σ le paramètre d'échelle, κ , δ , ξ contrôlent respectivement les parties inférieures, centrales et supérieures de la distribution. Par construction, les queues inférieure et supérieure sont des GPD de paramètres de forme κ et ξ .
4. **Modèle 4** : $T(v) = pv^{\kappa_1} + (1-p)v^{\kappa_2}$, $\kappa_2 \geq \kappa_1 > 0$ et $p \in [0, 1]$. Ce modèle de mélange de lois de puissance dépend de cinq paramètres : p , σ , ξ , κ_1 le paramètre de forme de la queue inférieure et κ_2 contrôle le comportement de la densité dans sa partie centrale.

En effet, pour aborder la modélisation conjointe des valeurs extrêmes et ordinaires, la fonction Gamma est souvent utilisée. Cependant, la queue de la distribution Gamma peut être insuffisamment lourde pour capturer les événements de fortes intensités de pluie. Par conséquent, cette approche peut conduire à une sous-estimation du niveau de retour (Katz et al., 2002). Pour mettre en évidence cette différence, une visualisation de l'ajustement de la distribution EGPD et Gamma, sur des observations journalières de précipitations, est présentée dans la Figure 28. On montre ici que pour la loi Gamma, la queue inférieure et la partie centrale de la distribution sont estimées correctement, tandis qu'une diminution de la performance du modèle vers la queue supérieure est marquée par rapport à l'EGPD.

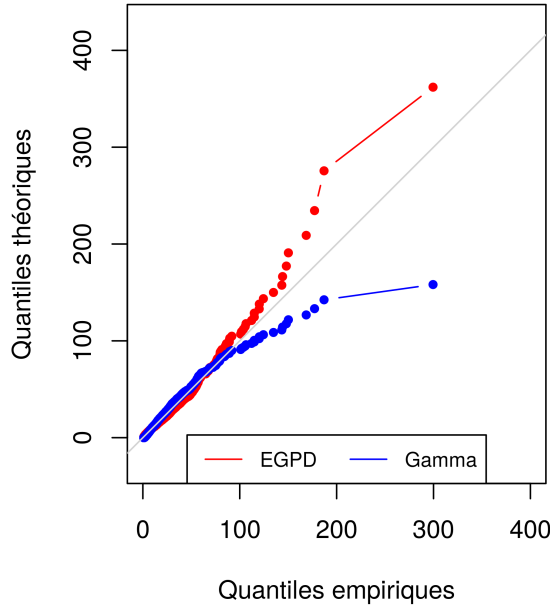


FIGURE 28 – Le graphique quantile-quantile de la distribution EGPD (avec le modèle 1) et la distribution Gamma ajustée pour les observations positives de précipitations journalières ($>1\text{mm}$) à la station Montpellier.

Parmi les modèles proposés par [Naveau et al. \(2016\)](#), le premier ($T(v) = v^\kappa$, $\kappa > 0$) est le plus simple et le plus parcimonieux. Dans cette étude, nous n'utiliserons que ce modèle qui a prouvé être en mesure de fournir une modélisation adéquate de l'intensité des précipitations et être suffisamment flexible ([Tencaliec et al., 2020](#); [Rivoire et al., 2021](#); [Le Gall et al., 2022](#); [Haruna et al., 2022b](#)). L'estimation des paramètres de la distribution (κ, σ, ξ) est effectuée avec la méthode des moments pondérés. Pour évaluer la qualité de l'ajustement, le coefficient d'efficacité de Nash-Sutcliffe (NSE) ([Nash and Sutcliffe, 1970](#)) est utilisé.

$$NSE = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y}_i)^2} \quad (3.19)$$

avec \hat{y}_i et y_i sont les valeurs simulées et observées, respectivement. Plus le coefficient est proche de 1, plus le modèle est plus précis.

Niveau de retour

Le niveau de retour, noté r_T , est le niveau que l'on s'attend à dépasser en moyenne une fois tous les T années. Dans le cas de la distribution EGPD, il doit satisfaire la relation :

$$\mathbb{P}(X \leq r_T | X > 0) = 1 - \frac{1}{T \times \delta} \quad (3.20)$$

avec δ est la moyenne du nombre de précipitations non nulles par an et par station ([Blanchet et al., 2019](#)). Ce qui nous donne l'expression du niveau de retour pour le modèle 1 :

$$r_T = \frac{\sigma}{\xi} \left[\left\{ 1 - \left(1 - \frac{1}{T \times \delta} \right)^{\frac{1}{k}} \right\}^{-\xi} - 1 \right] \quad (3.21)$$

3.5 Synthèse

Dans ce chapitre, les outils méthodologiques nécessaires à la modélisation des précipitations extrêmes ont été présentés. Deux stratégies principales peuvent être utilisées :

1. **L'approche des maxima par bloc** : Cette approche repose sur l'approximation des valeurs maximales observées au sein de blocs de données. Pour ce faire, nous utilisons la distribution des valeurs extrêmes généralisées (GEV) (Définition 3.6).
2. **L'approche des excès** : Cette approche se base sur l'approximation des dépassements d'un certain seuil par la distribution de Pareto généralisée (GPD) (Définition 3.9).

Chacune de ces stratégies présente des avantages et des limites, ce qui les rend appropriées pour différentes situations. Le choix entre ces deux approches dépendra donc de la nature spécifique de l'étude et des objectifs de modélisation des précipitations extrêmes. L'utilisation de la GPD soulève toutefois la question concernant la détermination d'un seuil approprié : ce seuil doit être suffisamment grand pour que les excès suivent une GPD, mais un seuil surestimé entraîne une réduction de la taille de l'échantillon et une augmentation de la variance des estimations. Par contre, un seuil plus petit augmente la taille de l'échantillon et introduit des biais dans les estimations. On n'a pas ce problème pour la GEV, mais plutôt de prendre en compte le choix de la taille du bloc de données. En général, l'intervalle est fixé sur une base annuelle. Pour notre étude, nous avons choisi de cibler la saison des pluies comme intervalle de temps. Dans les deux scénarios (GEV et GPD), il est généralement plus pratique d'interpréter les modèles de valeurs extrêmes en termes de quantiles ou de niveaux de retour, plutôt qu'en se basant sur les valeurs estimées des paramètres de la distribution.

Modélisation de la non-stationnarité spatiale avec les réseaux de neurones

4.1 Introduction

L'un des objectifs de cette recherche consiste à élaborer une modélisation spatiale pour les précipitations en tenant compte de la complexité du milieu méditerranéen, particulièrement la présence des événements extrêmes. En effet, les analyses préliminaires réalisées au Chapitre 2 ont mis en évidence la non-stationnarité spatiale de la distribution des événements pluviométriques dans cette région. Par conséquent, pour parvenir à une meilleure modélisation, il est nécessaire de prendre en compte ces caractéristiques spécifiques. Dans le Chapitre 1, on a présenté différentes méthodes de modélisation de la non-stationnarité spatiale dans la littérature. Ces choix de modélisation impliquent diverses considérations, telles que l'utilisation de fonctions linéaires ou non linéaires (Leclerc and Ouarda, 2007), l'intégration de covariables décrivant l'espace (Villarini et al., 2009), ou la nécessité de rendre les paramètres de distribution non-stationnaires (El Adlouni et al., 2007).

Notre intérêt se porte principalement sur l'élaboration d'une modélisation de la non-stationnarité spatiale à l'aide de réseaux de neurones artificiels. Ainsi, dans ce chapitre, on commence par une brève définition de la non-stationnarité spatiale (Section 4.2). Ensuite, nous explorons les principes fondamentaux d'une classe spécifique de réseaux de neurones (Section 4.3). Cette approche se veut prometteuse, offrant une perspective pour aborder la modélisation des précipitations dans un environnement géographique aussi complexe que le milieu méditerranéen.

4.2 Notion de la non-stationnarité spatiale

Dans les approches classiques de la modélisation statistique, les observations d'une variable aléatoire donnée doivent initialement valider les hypothèses d'indépendance et de stationnarité. Cependant, la présence de variabilité dans les séries de données météorologiques, en particulier les précipitations, peut remettre en cause l'hypothèse de stationnarité.

En général, le terme "stationnaire" est utilisé pour décrire la propriété d'un phénomène ou un processus stable, qui ne change pas au cours du temps. Ce terme peut également être défini comme une fonction de l'espace : les valeurs de la variable sont hétérogènes et présentent des variations significatives à différentes positions spatiales. Ainsi, si une variable aléatoire est spatialement non-stationnaire, sa distribution de probabilité varie en fonction de la position dans l'espace.

Plus précisément, une variable aléatoire $X(\mathbf{s})$, par exemple le cumul de précipitations journalières mesuré en une station, est considérée comme stationnaire si, pour toute position \mathbf{s} et pour toute distance \mathbf{h} , les propriétés statistiques de $X(\mathbf{s})$ et $X(\mathbf{s} + \mathbf{h})$ sont indépendantes dans l'espace. Autrement dit, les moments joints d'ordre $r = \{1, 2\}$ de $X(\mathbf{s} + \mathbf{h})$ existent et sont identiques aux moments joints d'ordre r de $X(\mathbf{s})$:

$$\mathbb{E}[X(\mathbf{s})^r] = \mathbb{E}[X(\mathbf{s} + \mathbf{h})^r] \quad (4.1)$$

En revanche, si les moments statistiques varient selon la position dans l'espace, la variable est considérée comme non-stationnaire. Dans ce cas, la distribution de probabilité de $X(\mathbf{s})$ dépend de la position dans l'espace et un modèle stationnaire n'est plus adapté.

4.3 Théorie des réseaux de neurones artificiels

L'apprentissage automatique, ou *Machine Learning* (ML) en anglais, est une sous-branche de l'intelligence artificielle (IA) qui vise à développer des algorithmes capables d'apprendre à partir de données automatiquement. Contrairement aux algorithmes traditionnels, qui sont programmés pour effectuer des tâches spécifiques selon des règles prédéfinies, les algorithmes de ML sont conçus pour apprendre à partir de données et à améliorer leur performance. Aujourd'hui, ce domaine connaît une croissance exponentielle et couvre plusieurs domaines de recherche tels que la classification, la prédiction, la détection d'objets, la segmentation d'images, etc. Parmi les algorithmes de ML, on s'intéresse particulièrement aux réseaux de neurones artificiels (ou ANN pour *Artificial Neural Networks* en anglais). Les premières notions des ANN ont été introduites par McCulloch et Pitts en 1943 (McCulloch and Pitts, 1943). Ensuite, le premier modèle de réseau de neurones, connu sous le nom de "perceptron", a été créé par Rosenblatt (1958). Ces premiers modèles étaient des représentations simplifiées des réseaux de neurones biologiques, visant à imiter le fonctionnement du cerveau humain en utilisant des unités de traitement interconnectées. L'utilisation de ces modèles était très limitée à l'époque en raison de leur coût de calcul élevé et du manque de données adéquates pour l'entraînement. Cependant, avec le développement rapide des nouvelles technologies informatiques, telles que l'amélioration considérable de la puissance de calcul et la disponibilité des unités de traitement graphique, leur utilisation est devenue de plus en plus fréquente (Mrowka, 2023).

4.3.1 Architecture du réseau de neurones

Le neurone formel, également appelé *perceptron*, est l'unité de base d'un réseau de neurones. Il s'agit d'une fonction qui réalise une combinaison de ses variables d'entrée pondérées par des paramètres souvent appelés *poids*. Ces entrées sont ensuite transformées par cette fonction pour produire un résultat en sortie. Pour $x_1 \dots x_n$ un vecteur de variables d'entrée, $w_1 \dots w_n$ les poids associés à chaque entrée et h une fonction d'activation, la transformation effectuée pour obtenir la sortie Y est formulée par $Y = h\left(\sum_{i=1}^n w_i x_i\right)$ (voir Figure 29).




FIGURE 29 – Représentation d'un neurone formel.

Un réseau de neurones se compose d'un grand nombre de ces neurones, où chaque unité est activée par la réception d'une entrée et l'envoi d'une autre. La structure du réseau est composée d'au moins trois couches : une couche d'entrée, une couche de sortie et une ou plusieurs couches intermédiaires dites *couches cachées* (voir Figure 30). Il est tout à fait possible d'insérer des couches cachées supplémentaires entre l'entrée et la sortie. Si le réseau de neurones a plus de trois couches, il est alors appelé un réseau de neurones profond (LeCun et al., 2015; Goodfellow et al., 2016). Dans notre travail, nous nous limitons à un réseau avec une seule couche cachée, vu la complexité du problème à résoudre et de la quantité de données d'entraînement disponibles.

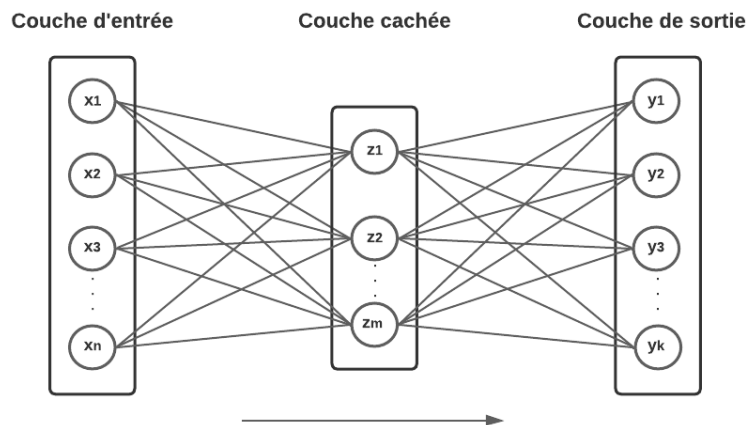


FIGURE 30 – Représentation d'un réseau de neurones à une couche cachée.

La manière d'organiser les neurones entre eux détermine l'architecture du réseau. Les réseaux de type *Feedforward* (à propagation avant) sont nommés ainsi car l'information se propage dans un sens unique des entrées vers la sortie. En effet, la loi qui détermine la réaction du neurone en fonction de l'information reçue est la fonction d'activation. C'est la fonction qui permet de modéliser les relations non linéaires. Elle est généralement différentiable, ce qui signifie que la dérivée de premier ordre peut être calculée pour une valeur d'entrée donnée. Cela est impératif pour l'algorithme d'optimisation, qui nécessite le calcul de la dérivée de l'erreur de prédiction afin de comprendre quels poids dans les neurones d'entrée peuvent fournir une meilleure prédiction. Dans le cas où le réseau de neurones fonctionne sans fonctions d'activation, chaque neurone effectuera une transformation linéaire des entrées pondérées, ce qui reviendra essentiellement à un modèle de régression linéaire. Le choix de la fonction d'activation a un impact important sur la performance du réseau de neurones. Elle peut prendre plusieurs formes, apportant chacune des comportements différents. La fonction tangente hyperbolique, donnée par $\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ et illustrée à la Figure 31, est l'une des fonctions les plus utilisées pour les réseaux de neurones de type Feedforward. Cette fonction est centrée en zéro et produit des valeurs de sortie dans l'intervalle $[-1, 1]$, donc plus x est grand (positif), plus la valeur de sortie sera proche de 1, tandis que plus x est petit (négatif), plus la sortie sera proche de -1. En plus, cette fonction a la propriété que sa dérivée peut facilement être exprimée en termes de la fonction elle-même : $\tanh'(x) = 1 - \tanh^2(x)$, ce qui sera utile lors de l'apprentissage du réseau.




FIGURE 31 – Graphe de la fonction tangente hyperbolique

La fonction calculée par le réseau de neurones à une couche cachée de la Figure 30 peut être décrite de la façon suivante. Soit $x = \{x_1, \dots, x_n\}$ les variables d'entrée. Chaque neurone j de la couche cachée transforme m combinaisons linéaires des entrées :

$$a_j = \sum_{i=1}^n w_{ji}^{(1)} x_i + w_{j0} \quad (4.2)$$

avec $w_{ji}^{(1)}$, $j = 1, \dots, m$ et $i = 1, \dots, n$, est le poids de la couche cachée reliant le neurone j à la $i^{\text{ème}}$ composante du vecteur d'entrée, et w_{j0} est le biais du neurone j . La transformation non-linéaire est ensuite appliquée avec la fonction d'activation $h(\cdot)$ par chaque neurone de la couche cachée pour obtenir : $z_j = h(a_j)$.

Selon le même principe, chaque neurone de la couche de sortie reçoit en entrée une combinaison linéaire des sorties z_j de la couche cachée :

$$a'_k = \sum_{j=1}^m w_{kj}^{(2)} z_j + w_{k0} \quad (4.3)$$

avec $w_{kj}^{(2)}$, $k = 1, \dots, p$ et $j = 1, \dots, m$, est le poids de la couche de sortie reliant le neurone k à la $j^{\text{ème}}$ unité cachée, et w_{k0} est le biais du neurone k . Chaque neurone de sortie transforme son entrée à l'aide de la fonction d'activation f pour obtenir : $y_k = f(a'_k)$. La fonction d'activation f peut être différente de h et le choix ici dépend de la tâche accomplie par le réseau de neurones. Ainsi, pour les problèmes de régression, la fonction d'activation f est simplement l'identité. Pour les problèmes de classification, chaque unité de sortie est activée à l'aide de la fonction sigmoïde dans le cas binaire, ou de la fonction softmax pour la classification multi-classes. La fonction d'activation softmax est généralement utilisée dans la dernière couche d'un réseau entièrement connecté pour normaliser les sorties du réseau en une distribution de probabilité sur les classes de sortie prédites (Ma and Álvarez, 2023). Dans le cas de la classification multi-classes, où plusieurs variables de sortie représentent différentes classes, la fonction softmax est utilisée pour mettre à l'échelle les sorties au-delà de quelques classes (Protonotarios et al., 2022).

Grâce à la fonction d'activation non-linéaire, les réseaux de neurones à une couche cachée sont considérés comme des *approximateurs universels*, dans le sens où ils peuvent approcher toute fonction continue à support borné. Ce théorème a été démontré par (Cybenko, 1989) pour la fonction d'activation sigmoïde, puis étendu à des activations non constantes bornées arbitraires par (Hornik et al., 1989). Cependant, cela ne signifie pas que le réseau peut apprendre efficacement n'importe quelle fonction car ce résultat ne fournit aucune information sur la façon de choisir le nombre de neurones qui doivent composer la couche cachée, ni sur les paramètres de poids.

4.3.2 Apprentissage du réseau de neurones

Étant donné un ensemble d'entraînement $D = (x_n, y_n)_{n=1, \dots, N}$, où x_n représente les vecteurs d'entrée et y_n les vecteurs cibles correspondants, le réseau de neurones effectue des prédictions \hat{y}_n . Pour que le modèle soit capable de généraliser et de faire des prédictions précises sur de nouvelles données, les paramètres du réseau (notés w) doivent être ajustés de manière appropriée. L'algorithme effectuant cette tâche est basé sur la minimisation d'une fonction dite fonction *de coût* (ou d'erreur), qui mesure l'erreur entre les prédictions et les cibles sur

l'ensemble d'apprentissage. L'expression suivante permet de définir la fonction de coût :

$$E(w) = \frac{1}{2} \sum_{n=1}^N \{y(x_n, w) - \hat{y}_n\}^2 \quad (4.4)$$

Cette expression peut varier en fonction de la tâche confiée au modèle. Par exemple, pour la tâche de classification binaire, qui nécessite une seule variable cible de la couche de sortie, la fonction de coût la plus utilisée est l'entropie croisée donnée par l'équation 4.5. Pour la classification multi-classe, la fonction d'erreur est l'entropie croisée multi-classe correspondante.

$$E_c(w) = - \sum_{n=1}^N y_i \ln y(x_i, w) + (1 - y_i) \ln(1 - y(x_i, w)) \quad (4.5)$$

Pour la tâche de régression, la fonction coût la plus utilisée est l'erreur quadratique moyenne, qui mesure la différence moyenne au carré entre les prédictions du modèle et les valeurs réelles de l'ensemble des données. Dans le cas de notre étude, on veut estimer les paramètres d'une distribution (e.g. la GEV). Donc la log-vraisemblance négative (donnée par l'équation 4.6) peut être utilisée pour minimiser l'erreur de prédiction et estimer les paramètres du modèle de manière à maximiser la probabilité de générer les données observées.

$$E_L(w) = - \sum_{i=1}^N \log(\mathbb{P}(y_i|x_i, w)) \quad (4.6)$$

où $\mathbb{P}(y_i|x_i, w)$ est la densité de probabilité conditionnelle de la valeur cible y_i étant donné l'entrée x_i .

Algorithme de descente de gradient

Ce problème de minimisation est un problème d'optimisation non-linéaire qui peut être résolu par la descente de gradient. L'algorithme est initialisé par un choix aléatoire de poids et se poursuit en apportant des modifications à ces poids de manière à les déplacer dans la direction de la valeur négative du gradient de la fonction d'erreur, jusqu'à ce que le vecteur de poids atteigne un minimum local ou global.

En effet, la fonction peut être considérée géométriquement comme une surface d'erreur située dans l'espace des poids, comme l'indique la Figure 32 : le vecteur des dérivées partielles ∇E pointe dans la direction de la plus grande pente. Le minimum se produit en un point tel que : $\nabla E(W) = 0$. Ainsi, le problème de l'entraînement d'un réseau correspond à la recherche du minimum local ou global de la surface d'erreur. Cela est réalisé en utilisant l'équation de la descente de gradient. $w_{(k+1)} = w_{(k)} - \eta \nabla E(w_{(k)})$, avec $\eta > 0$ le pas du gradient. Après chaque mise à jour, le gradient est recalculé pour les nouveaux poids du vecteur.




FIGURE 32 – Vue géométrique de la fonction d'erreur $E(w)$ en tant qu'une surface sur l'espace des poids. Le point W_A est un minimum local et W_B est le minimum global. En tout point W_C , le gradient local de la surface d'erreur est donné par le vecteur ∇E (Bishop, 2006).

Algorithme de rétro-propagation

Pour calculer le gradient de chaque couche par rapport à la fonction de coût, l'approche utilisée est l'algorithme de rétropropagation du gradient d'erreur (Rumelhart et al., 1986). C'est un algorithme qui s'appuie sur le théorème de dérivation en chaîne des fonctions composées. Pour cela, il faut commencer par calculer le gradient des paramètres de la dernière couche, puis propager le gradient vers la première. Ainsi, on peut calculer avec précision l'influence de chaque paramètre du réseau dans le résultat de la fonction de coût et les modifier en conséquence. Ceci est expliqué avec les équations suivantes :

$$\frac{\partial E(w)}{\partial a'_k} = a'_k(x_i) - y_{ik} \quad (4.7)$$

Donc pour la deuxième couche, on a :

$$\frac{\partial E(w)}{\partial w_{kj}^{(2)}} = \frac{\partial E(w)}{\partial a'_k} \times \frac{\partial a'_k}{\partial w_{kj}^{(2)}} \quad (4.8)$$

$$= (y_{nk} - a'_k(x_n)) \times z_j \quad (4.9)$$

et pour la première couche :

$$\frac{\partial E(w)}{\partial w_{ij}^{(1)}} = \sum_k \left[\frac{\partial E(w)}{\partial a'_k} \times \frac{\partial a'_k}{\partial z_j} \times \frac{\partial z_j}{\partial a_j} \times \frac{\partial a_j}{\partial w_{ij}^{(1)}} \right] \quad (4.10)$$

$$= \sum_k [(y_{nk} - a'_k(x_n)) \times (w_{jk}^{(2)})] \times \tanh'(a_j) \times x_i \quad (4.11)$$

Par conséquent, l'algorithme d'apprentissage d'un réseau de neurones peut être résumé comme suit :

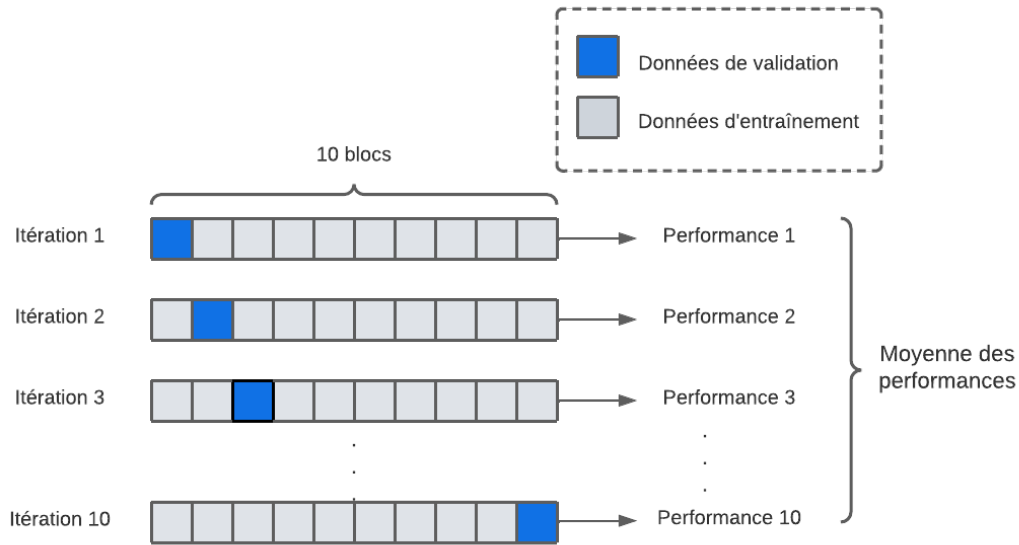
1. Initialisation aléatoire des paramètres.
2. Phase de propagation vers l'avant : les données d'entrée sont propagées à travers le réseau de neurones, depuis la couche d'entrée vers la sortie, en appliquant la fonction d'activation à chaque neurone et en multipliant les poids correspondants.
3. Phase de rétro-propagation de l'erreur : l'erreur est propagée de la couche de sortie vers la couche d'entrée en utilisant la dérivée partielle de la fonction de coût par rapport aux poids.
4. Les paramètres sont mis à jour à l'aide de l'algorithme d'optimisation par descente de gradient.
5. La procédure est répétée à partir de l'étape 2 jusqu'à ce que l'erreur soit minimisée ou qu'un critère d'arrêt soit atteint.

4.3.3 Procédure de validation pour la sélection du niveau de complexité, sous-apprentissage et sur-apprentissage

L'entraînement d'un réseau de neurones vise à ajuster ses poids et ses biais pour qu'il puisse effectuer la tâche spécifique pour laquelle il a été conçu. En effet, la capacité de généralisation nécessite de tester les performances du réseau sur des données qui n'ont pas été utilisées pendant l'entraînement. Pour ce faire, il est courant de découper la base de données en deux parties :

- Un ensemble de données d'entraînement utilisées durant l'apprentissage et permettant de mesurer la performance.
- Un ensemble de données de validation qui contient des données exclues lors de la mise à jour des paramètres du réseau. Il est généralement de taille plus réduite que l'ensemble d'entraînement.

Il est recommandé d'utiliser une validation croisée, ou méthode des *k-folds* (Goodfellow et al., 2016) pour ne pas se limiter à un seul découpage. Cette technique consiste à diviser l'ensemble de données en plusieurs sous-ensembles, puis entraîner et évaluer le modèle sur différentes combinaisons de ces sous-ensembles (voir Figure 33). Cela permet d'estimer les performances du modèle sur des données de validation et d'évaluer sa capacité à se généraliser au-delà des données d'entraînement.

FIGURE 33 – Schéma de la validation croisée K-fold, avec $K=10$

L'algorithme de validation croisée *k-fold* comprend les étapes suivantes :

1. Diviser l'ensemble des données en k sous-ensembles de taille égale.
2. Chaque sous-ensemble est considéré comme l'ensemble de validation et les $k-1$ sous-ensembles restants comme l'ensemble d'entraînement.
3. Mesurer la performance pour le modèle formé sur l'ensemble de validation.
4. Répéter les étapes, en utilisant à chaque fois un sous-ensemble différent comme ensemble de validation.
5. Calculer la performance moyenne sur les k -itérations pour obtenir une estimation de la performance globale du modèle.

Par la suite, on peut sélectionner le modèle ayant la meilleure performance sur les k itérations, sur la base de la mesure de performance choisie. En utilisant cette technique, il est possible de comparer les performances des modèles avec différents niveaux de complexité (nombre d'unités cachées) pour déterminer celui qui offre la meilleure capacité de généralisation. Cette même approche peut permettre aussi la sélection des covariables adéquates pour chaque modèle et chaque site d'étude, tel que présenté dans le Chapitre 5.

Cette mesure de performance globale nous permet de sélectionner le niveau de complexité optimal du modèle, qui est un compromis entre deux comportements à éviter : le sur-apprentissage et le sous-apprentissage (comme illustré dans la Figure 34). Ces comportements sont liés à la performance des modèles et à leur capacité à généraliser avec de nouvelles données en dehors de celles utilisées pour l'entraînement. L'erreur est élevée en sous-apprentissage et en sur-apprentissage à des causes différentes, mais les deux situations indiquent que le modèle ne généralise pas correctement. D'une part, dans le cas d'un sous-apprentissage, le modèle n'arrive pas à capturer les motifs présents dans les données. L'erreur est élevée à la fois sur les

données d'entraînement et celles de validation. D'autre part, dans le cas du sur-apprentissage, une erreur élevée se produit lorsque le modèle est trop complexe et parvient à mémoriser les données d'entraînement. Lorsqu'il est confronté à de nouvelles données, il peut mal interpréter les variations dues au bruit, ce qui se traduit par de mauvaises performances. Le problème passe d'un sous-apprentissage à cause du biais élevé, à un sur-apprentissage à cause d'une variance élevée. L'apprentissage optimal est celui qui vérifie le compromis biais-variance entre les deux cas.




FIGURE 34 – Courbes de l'erreur sur l'ensemble d'entraînement et l'ensemble de validation en augmentant la complexité du modèle ANN.

4.3.4 Rôle des unités cachées

Pendant la phase d'apprentissage d'un réseau de neurones, les unités cachées jouent un rôle fondamental en permettant de capturer les relations non-linéaires entre les entrées et les sorties du modèle. Elles ont la capacité d'apprendre et de reconnaître des motifs à partir des données d'entrée en ajustant leurs poids et biais au fil de l'apprentissage.

Le nombre des unités cachées représente un hyperparamètre déterminant pour la configuration d'un réseau de neurones. Pour illustrer l'impact de cette variable, considérons la Figure 35. Cette figure montre les résultats obtenus en faisant varier le nombre d'unités cachées dans le contexte d'un ajustement de fonction sinus. Les points rouges sont les données d'entraînement avec un bruit. La figure à gauche, correspond au cas où $nh = 2$: l'apprentissage n'est pas tellement atteint parce qu'il n'a pas assez de flexibilité, donc un réseau avec peu d'unités cachées est biaisé. Sur la figure au milieu, avec $nh = 3$, on voit une amélioration de l'apprentissage. Enfin, à droite, avec $nh = 4$ unités cachées, l'apprentissage est très sensible à la variance, le réseau est capable d'apprendre par cœur le jeu de données et on arrive au sur-apprentissage pour donner une fonction différente. Cette expérience nous permet de conclure que : plus on augmente le

nombre d'unités cachées, plus le nombre de poids (les paramètres) augmente, entraînant ainsi une augmentation de la complexité.




FIGURE 35 – Le rôle du nombre d'unités cachées nh dans l'ajustement d'un ANN sur un exemple de fonction sinus. Allant de gauche à droite : $nh=\{2,3,4\}$.

4.3.5 Saturation des unités cachées

Les fonctions d'activation utilisées dans l'architecture des ANN peuvent être sensibles aux valeurs des entrées. Lorsque les valeurs d'entrée sont de grande amplitude, les sorties des neurones peuvent s'approcher des extrémités des fonctions d'activation, ce qui entraîne une saturation et une diminution du gradient. Par exemple, pour le cas de la tangente hyperbolique, le choix des a_j fait en sorte que les $z_j = \tanh(a_j)$ tombent dans les zones de saturation, c'est-à-dire ($z_j = \pm 1$). Une telle situation peut engendrer une vitesse d'apprentissage réduite et une performance dégradée du modèle. Pour remédier à ces problèmes, il est généralement recommandé de centrer et de réduire les données d'entrée avant leur utilisation dans le processus d'entraînement. Cette approche est bien illustrée dans la Figure 36, où on voit une nette amélioration de l'ajustement avec des données d'entrée centrées réduites. Cette pratique permet d'homogénéiser les valeurs d'entrée, favorisant ainsi la convergence de l'algorithme d'optimisation




FIGURE 36 – Résultat de l'ajustement d'un sinus, avec les données d'entrée non transformées (figure à gauche) et avec des données d'entrée centrées réduites (figure à droite).

4.4 Comparaison avec un modèle linéaire généralisé

Le modèle linéaire généralisé (noté GLM pour *Generalized Linear Model*) est une famille de modèles statistiques qui permettent de modéliser la relation entre une variable de réponse et une ou plusieurs variables explicatives. En effet, il s'agit d'une généralisation du modèle linéaire classique, autorisant aux variables de réponse d'avoir n'importe quelle autre distribution de la famille exponentielle (e.g., gamma, poisson, binomiale) (McCullagh and Nelder, 1989). Contrairement au modèle linéaire classique où la moyenne n'est qu'une fonction linéaire des variables d'entrée, $E(Y|X) = X^T\beta$, le GLM intègre cette partie linéaire dans la régression en utilisant une fonction de lien. La relation entre la variable de réponse Y et la variable explicative X peut être exprimée sous la forme suivante :

$$g(E(Y|x)) = \beta_0 + \beta_1x_1 + \dots + \beta_nx_n \quad (4.12)$$

$E(Y|x)$ est donc liée à la combinaison linéaire par la fonction différentiable et monotone g , qui n'est pas nécessairement l'identité. Le choix de la fonction de lien est important car cette fonction permet de s'assurer que les valeurs prédites par le modèle respectent la nature de la variable Y . Par exemple, si la variable réponse suit une distribution exponentielle, choisir une fonction de lien appropriée telle que la fonction \log garantira que les valeurs attendues sont positives.

On se demande ici quelle est la relation du GLM avec les ANN, et en quoi cela peut servir à modéliser la non-stationnarité spatiale. En effet, le GLM peut être vu comme le schéma suivant (Figure 37). En s'inspirant du même principe de l'ANN, le lien entre les GLM et la non-stationnarité spatiale peut être établi en considérant que les variables d'entrée sont des covariables qui reflètent l'information spatiale et que le modèle effectue alors une opération non linéaire.

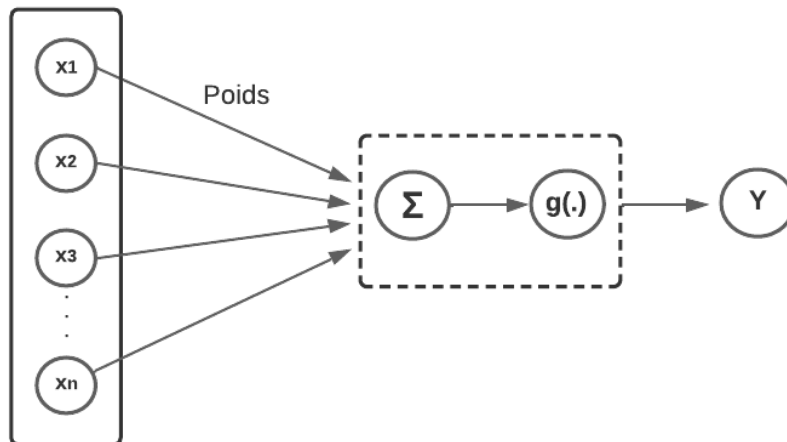


FIGURE 37 – La structure d'un GLM.

Supposons que $g(x) = (g_1(x), g_2(x), g_3(x))$, alors le GLM appliqué à la distribution GEV peut être écrit comme suit :

$$g_1(\mu(Y, \beta_\mu)) = \beta_{\mu_0} + \sum_{i=1}^n \beta_{\mu_i} x_i \quad (4.13)$$

$$g_2(\sigma(Y, \beta_\sigma)) = \beta_{\sigma_0} + \sum_{i=1}^n \beta_{\sigma_i} x_i \quad (4.14)$$

$$g_3(\xi(Y, \beta_\xi)) = \beta_{\xi_0} + \sum_{i=1}^n \beta_{\xi_i} x_i \quad (4.15)$$

Dans cette étude, on suppose que $g(x) = (x, \log(x), \log(x + 0, 5))$. La fonction de lien pour le paramètre d'échelle est la fonction log pour assurer sa positivité. Pour le paramètre de forme, nous supposons que $\xi > -0.5$, car le cas où $\xi \leq -0.5$ correspond à des distributions avec une queue supérieure bornée très courte, difficile à rencontrer pour les extrêmes [Coles \(2001\)](#).

Le point commun entre l'ANN et le GLM est qu'ils sont deux techniques qui cherchent à identifier un schéma spécifique au sein d'un ensemble de données. Dans les deux cas, le résultat final est un modèle qui peut ensuite être utilisé pour faire des estimations. Par contre, l'une des principales différences est que les GLM sont limités à certaines catégories de modèles, avec une évaluation ultérieure de l'ajustement. Alors que les ANN parviennent à modéliser efficacement les données sur lesquelles ils sont entraînés, avec une meilleure flexibilité mais d'une manière plus complexe.

4.5 Synthèse

La modélisation de la non-stationnarité spatiale est un processus qui vise à capturer les variations spatiales des phénomènes étudiés, en reconnaissant que les propriétés statistiques peuvent changer d'un point de l'espace à un autre. Cela revient à dire que les relations et les caractéristiques des données peuvent varier en fonction de la position géographique, intégrées dans la modélisation à travers les covariables. Deux approches ont été proposées pour faire varier les paramètres des modèles suivant ces covariables :

1. Les ANN, qui ont la capacité d'apprendre à partir de données d'une façon implicite et d'extraire une information pertinente à partir de très grands jeux de données.
2. Les GLM offrent une transparence intermédiaire par rapport aux techniques univariées plus simples et aux méthodes avancées et complexes telles que les ANN.

Les ANN ne sont à la base rien d'autre que des modèles paramétriques, potentiellement complexes, permettant de construire facilement des modèles très flexibles. Cependant, l'utilisation de ces modèles présente diverses difficultés, notamment l'ajustement des paramètres et des hyperparamètres ainsi que les risques de sous-apprentissage et sur-apprentissage.

Article : Smooth spatial modeling of extreme Mediterranean precipitation

5.1 Résumé de l'article

Les régions méditerranéennes sont particulièrement vulnérables aux risques naturels, en particulier aux inondations dévastatrices causées par les précipitations extrêmes. Il est donc crucial d'effectuer une caractérisation précise de ces événements, afin de mieux comprendre leurs mécanismes et leurs impacts potentiels. Les événements extrêmes, définis comme des maxima annuels, peuvent être modélisés à l'aide de la distribution des valeurs extrêmes généralisées (GEV). En raison de l'hétérogénéité spatiale, la distribution des extrêmes est non-stationnaire dans l'espace. Pour tenir compte de la non-stationnarité, les paramètres de la distribution GEV peuvent être considérés comme des fonctions de covariables qui contiennent les informations spatiales. Ces fonctions peuvent être mises en œuvre sous la forme d'un modèle linéaire généralisé (GLM) ou d'un modèle non-linéaire non-paramétrique, tel qu'un réseau de neurones artificiel (ANN). Dans ce travail, nous évaluons plusieurs modèles statistiques qui combinent la distribution GEV avec un GLM ou un ANN, pour avoir des surfaces de réponses des paramètres de la GEV. Les points clés sont la sélection appropriée du niveau de complexité du ANN (e.g le nombre d'unités cachées) et la sélection appropriée des covariables. Trois sites sont inclus dans notre étude : une région de la Méditerranée française, la région du Cap Bon dans le nord-est de la Tunisie et le bassin versant de Merguellil dans le centre de la Tunisie.

Article

Smooth Spatial Modeling of Extreme Mediterranean Precipitation

Hela Hammami ^{1,2,*} , Julie Carreau ³ , Luc Neppel ¹ , Sadok Elasmî ² and Haifa Feki ⁴¹ HydroSciences Montpellier, Université de Montpellier, CNRS, IRD, 34093 Montpellier, France² COSIM Laboratory, Higher School of Communication of Tunis, University of Carthage, Ariana 2083, Tunisia³ Department of Mathematics and Industrial Engineering, Polytechnique Montreal, Montreal, QC H3T 1J4, Canada⁴ GREEN-TEAM Laboratory, LR17AGR01, University of Carthage, Tunis 1082, Tunisia

* Correspondence: hela.hammami@supcom.tn; Tel.: +216-53-982-747

Abstract: Extreme precipitation events can lead to disastrous floods, which are the most significant natural hazards in the Mediterranean regions. Therefore, a proper characterization of these events is crucial. Extreme events defined as annual maxima can be modeled with the generalized extreme value (GEV) distribution. Owing to spatial heterogeneity, the distribution of extremes is non-stationary in space. To take non-stationarity into account, the parameters of the GEV distribution can be viewed as functions of covariates that convey spatial information. Such functions may be implemented as a generalized linear model (GLM) or with a more flexible non-parametric non-linear model such as an artificial neural network (ANN). In this work, we evaluate several statistical models that combine the GEV distribution with a GLM or with an ANN for a spatial interpolation of the GEV parameters. Key issues are the proper selection of the complexity level of the ANN (i.e., the number of hidden units) and the proper selection of spatial covariates. Three sites are included in our study: a region in the French Mediterranean, the Cap Bon area in northeast Tunisia, and the Merguellil catchment in central Tunisia. The comparative analysis aim at assessing the genericity of state-of-the-art approaches to interpolate the distribution of extreme precipitation events.

Keywords: intense precipitation events; non-stationarity in space; generalized extreme value distribution; spatial interpolation; generalized linear models; artificial neural networks



Citation: Hammami, H.; Carreau, J.; Neppel, L.; Elasmî, S.; Feki, H. Smooth Spatial Modeling of Extreme Mediterranean Precipitation. *Water* **2022**, *14*, 3782. <https://doi.org/10.3390/w14223782>

Academic Editor: Pankaj Kumar

Received: 18 October 2022

Accepted: 16 November 2022

Published: 21 November 2022

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

The increasing hazard triggered by extreme precipitation events heightens the need to develop risk estimation approaches. The last decades have seen several deadly floods caused by extreme rainfall, particularly in the Mediterranean region (e.g., [1,2]). For example, during a heavy flood event in northeastern Tunisia in 2018, precipitation of around 200 mm occurred on a regional scale, producing a record of 297 mm in the Beni Khalled station in just a few hours [3]. The south of France was affected by a similar event in 2014 that left the city underwater with a record equivalent to more than six months of precipitation [4]. Every autumn, regions around the Mediterranean are affected by floods. The consequences of these phenomena are sometimes dramatic, including human and material losses, pollution of water resources and destruction of agricultural farms. Therefore, an effective forecasting system is essential to reduce the impacts of these disasters and to make the right decisions regarding flood risk assessment.

Extreme value theory (EVT) provides a proper parametric framework to model the distribution of extremes, particularly in hydrology [5]. The distribution of maxima over blocks of observations, often chosen to correspond to a time period of length one year, can be approximated by the generalized extreme value (GEV) family of distributions [6]. To convey information on the probability of extreme events, quantiles of the GEV distribution function are of particular interest because of their interpretation as return levels. This value

is defined as the level of rainfall intensity that is expected to be exceeded on average once in a given year.

A major challenge in investigating the distribution of extreme rainfall events is to define a spatial representation at ungauged sites. Rainfall data are usually recorded from networks of rainfall stations in the study area. The spatial interpolation process involves using point data to find estimates at surrounding locations for which observations are not available. Several interpolation schemes have been proposed in the literature [7–11]. In classical initial interpolation approaches, the distribution parameters are estimated locally and then interpolated to obtain return level maps. For instance, in [12], local estimates of extreme rainfall intensities are interpolated to perform a regional analysis. Among others, the Inverse Distance Weighting (IDW) [13] and classical Kriging techniques [10,11], such as Ordinary Kriging [14], are frequently used. In this case, the grid estimate is obtained by the weighted average of the relevant observations, and each of the techniques uses a different weight calculation method.

More recent approaches, called “response surfaces”, consider that the distribution parameters vary according to geographical covariates. For instance, a smooth GEV fitting was proposed in [15] for mapping snow depth where parameters are directly modeled as function in space. In particular, the authors in [16] highlighted the use of several stations in regional approaches, known as region-of-influence, to reduce variance. Response surfaces provide a more flexible alternative to the regional approach by allowing the parameters to vary more flexibly in space. The relationship between GEV parameters and spatial covariates can be described by a regression model. Artificial neural networks (ANNs) can offer greater accuracy in estimating climate variables due to their ability to recognize patterns in the data [17]. As universal approximators, ANNs can model non-linear relationships between a set of inputs without making assumptions regarding the nature of data [18]. Owing to their flexible structure, neural networks can be related to other regression methods, such as the generalized linear model (GLM). For example, the authors in [19] conducted a spatial regression model with a GLM for the estimation of the GEV parameters to model the univariate marginal distributions. In this work, spatial modeling is carried out using response surfaces.

In order to obtain a spatial mapping of the extreme distribution at ungauged locations, covariates must be known everywhere in the study area. The main way to incorporate non-stationarity into the modeling of extreme events is to assume that the distribution parameters are no longer constant but vary as a function of covariates [5]. Researchers have highlighted the need to incorporate climatic and hydrological-based variables as covariates [20]. For example, in [21], an evaluation of several climatic covariates has been presented (altitude, longitude, latitude, mean annual rainfall, mean number of daily rainfall and mean daily rainfall). In [22], the authors proposed a model with annual precipitation as a covariate that exhibits good performance. We can also refer to the use of the North Atlantic Oscillation and Mediterranean Index in [23], the frequency of southern-type circulation patterns and air temperature in [20] and the Southern Oscillation Index in [24]. Satellite-based rainfall data are increasingly used, since they provide spatially detailed information about rainfall distribution [25].

The main objective of this work is to propose a smooth spatial modeling framework based on GEV response surfaces to interpolate extreme Mediterranean precipitation hazard. In Section 2, we described the three selected Mediterranean study areas and the used data set. We presented two techniques for modeling the relationship between GEV parameters and spatial covariates (GLM and ANN) (see Section 3). The model selection strategy involved determining the complexity level (i.e., the number of parameters in the model) by satisfying a trade-off between bias and variance, and finding the optimal set of covariates using a cross-validation technique. In Section 4, we presented the pointwise and the smooth spatial GEV parameters estimation. An assessment of the goodness-of-fit of each spatial model is conducted by comparing the confidence bands of the return levels at test stations.

2. Study Area and Data

We consider three study areas marked by a Mediterranean climate: a region in the French Mediterranean, the Cap Bon area in northeast Tunisia, and the Merguellil catchment area in central Tunisia, which are located in Figure 1. These three Mediterranean regions are characterized by a north–south aridity gradient [26] and by a high spatial variability of precipitation with the occurrence of extreme events such as floods and droughts. The rainy season for the three study areas was fixed as the period from September to April (241 or 242 days per season). For each month of the year, the average rainfall totals show an increase between September and April and a decrease for the other months. For regions around the Mediterranean, other authors have considered the same rainy season (e.g., [10,27]). We note that all gauging stations in Figure 2 were selected by having at least 30 years of observations with less than 10% missing values per rainy season.




Figure 1. Localization of the selected study areas around the Mediterranean region.

2.1. Rainfall Station Data

The French Mediterranean region is bounded on the south by the Mediterranean sea, on the west by the Cevennes mountain range (maximum elevation around 1687 m), and on the east by the Southern Alps (maximum elevation around 2694 m) (see the rightmost panel of Figure 2). Severe flooding, known as the “Cévenole”, occurs in this region, especially in the fall season [1]. From a climatic point of view, this study area is not homogeneous, since it contains two types of climate: the Mediterranean climate and the mountain climate [28]. Compared to the Mediterranean climate, the mountain climate is characterized by colder winters and milder summers. The hydrological processes are different due to the high variability of the rainfall regime, which means that the rainy season can be different. In order to work on a spatially homogeneous region and to define the same season for all study sites, we have chosen to classify the stations by climate type. We are only interested in the Mediterranean climate because of its high vulnerability to flooding. We selected stations by identifying sub-regions similar in terms of extreme rainfall behavior, inspired by the climatic regionalization approach presented in [29]. Each station was described by a vector containing 15 elements: the 95% quantiles of the monthly maxima of daily precipitation for each of the 12 months of the year and the three corresponding geographical coordinates (longitude, latitude, altitude). Then, the K-means clustering method was applied to split the stations into two groups. Stations with a Mediterranean climate were retained. Those data were collected by Météo-France, with a spatial resolution of 0.4 km, and they consist of daily precipitation records measured at 183 rainfall stations from 1958 to 2019. Average annual rainfall totals in this region over the rainy season vary from 433.4 to 1697.3 mm (see the rightmost panel of Figure 2). There are 20 stations with a complete number of observations and missing data for the remaining stations are up to 50.8%.

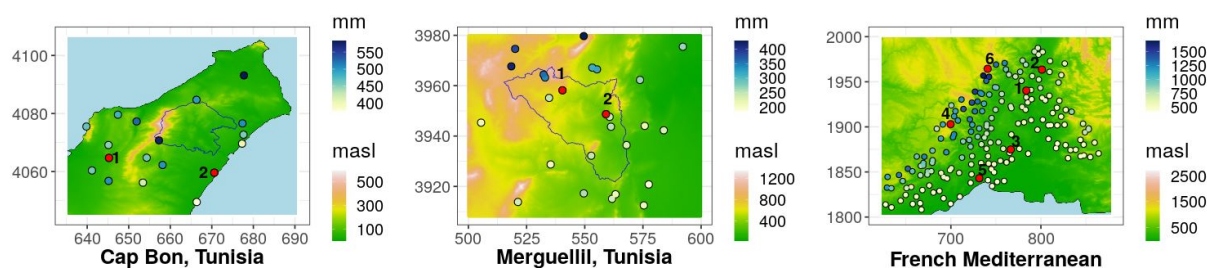


Figure 2. DEMs for the three study sites. The selected stations are represented with average annual rainfall totals over rainy season represented by the blue scale. The stations numbered in red will serve as test stations. The sky blue area represents the Mediterranean Sea and the blue lines delimit the catchment areas.

The region in central Tunisia, west of Kairouan, includes the Merguellil catchment, which covers an area of about 1200 km² upstream of El Haouareb dam [2,30] (see the central panel in Figure 2). Average annual rainfall totals over the rainy season vary from 185.6 mm in the plain to 430.2 mm in the highest part of the catchment. In this region, observations are available from 1900 to 2014 in 26 gauging stations, and the percentage of missing data varies between 40.35% to 72.45%. We have also considered the Cap Bon region in northeastern Tunisia, which contains the Lebna catchment that covers an area of about 210 km² (see the leftmost panel of Figure 2). The maximum altitude is located in the mountainous region known as Djebel Abderrahmane and then decreases toward the coast. Daily precipitation data are available from 1919 to 2014 in 18 stations, with a percentage of missing data that varies between 19.29% and 67.5%. Average annual rainfall totals over the rainy season range from 377.3 to 583.2 mm. Both daily rainfall data sets in Tunisia were collected from the Tunisian General Directorate of Water Resources.

2.2. CHIRPS Data Set

In addition to the covariates extracted from the geographical coordinates (longitude, latitude, altitude), we proposed to integrate the climatic variable obtained from the CHIRPS data set. Climate Hazards Group InfraRed Precipitation with Station data (CHIRPS) is a precipitation dataset developed by combining real-time observations with infrared data [31]. It is derived from three products: global climatologies, satellite estimates and gauge observations with daily, monthly and yearly temporal resolutions. From 1981 to the near present, CHIRPS data offer precipitation records with a spatial resolution (0.05 × 0.05 degree) and a quasi-global coverage 50° N to 50° S. This type of data will permit depicting the spatial pattern of precipitation in different regions. This information is not used directly to analyze extreme events because of its low spatial resolution and the existing bias between this data and local observations.

Daily CHIRPS GeoTIFF data were retrieved for the selected study area from <https://climateserv.servirglobal.net/> (accessed on 17 November 2022). Average annual totals per rainy season (September to April) were computed from 1981 to 2019. The longitude and latitude coordinates were projected onto Lambert 2 coordinates. Bi-linear interpolation was applied to the averaged annual total values to match the DEM grid. The results of the interpolation are presented in Figure 3. For each gauged station, we assigned the value of the nearest grid cell in order to obtain the “chirps” covariate, which will be used as a spatial covariate.




Figure 3. Interpolated average seasonal precipitation totals computed from the CHIRPS data constituting the CHIRPS spatial covariate. The gauging stations are depicted as black points, and contour lines from DEM are represented by the gray lines.

2.3. Inter-Covariate Correlation Analysis

Kendall correlation coefficients between each pair of covariates were computed as a preliminary analysis to assess the amount of inter-dependence present in the covariates. Kendall’s coefficient varies from -1 and $+1$ and can be interpreted as follows: the closer it is to 1 , the stronger the positive association is (variation in the same direction), and the closer it is to -1 , the stronger the negative association. However, if the coefficient is close to zero, it means that there is no association. The correlation matrix for the three study regions is presented in Figure 4. For the French Mediterranean region, we observe a correlation coefficient that exceeds 0.5 for (x,y) , $(z,chirps)$, and $(y,chirps)$; see the rightmost panel of the Figure 4. For Merguellil, see the central panel of Figure 4, where the covariate x has a negative correlation coefficient with all other covariates, especially a strong negative value with z -coordinate, which is obvious on the elevation map of the region (in Figure 2). For the Cap Bon region, see the leftmost panel of Figure 4: there is a moderate negative correlation coefficient for $(x,chirps)$ and a lack of association for the other covariates.




Figure 4. Kendall’s correlation matrix for the covariates corresponding to the three study areas.

3. Statistical Methods

3.1. Extreme Value Theory

As we are interested in extreme events, we need to focus on the behavior of the upper tail of the distribution. Extreme value theory (EVT) is a classical set of tools used to analyze extreme values [6]. We suppose that $X_1 \dots X_n$ is a sequence of independent random variables and that $M_n = \max\{X_1 \dots X_n\}$ is their maximum values. In this paper, the random variables are time series of daily rainfall observations from several gauged stations.

The fundamental theorem of [32] gives an asymptotic result allowing us to characterize the distribution of M_n . Suppose that there exists $c_n > 0$ and $d_n \in \mathbb{R}$, two sequences of real numbers, such that:

$$\lim_{n \rightarrow \infty} P\left(\frac{M_n - d_n}{c_n} \leq x\right) = G(x) \tag{1}$$

where G is a non-degenerate distribution function that can be expressed as the generalized extreme value (GEV) distribution:

$$G(z) = \exp - \left[1 + \zeta \left(\frac{z - \mu}{\sigma} \right) \right]_+^{-1/\zeta} \quad (2)$$

defined for the values of z for which $1 + \zeta(z - \mu)/\sigma > 0$ and (μ, σ, ζ) are the location, scale and shape parameters, respectively. The GEV distribution encompasses the three different behaviors of the maximum as controlled by the shape parameter. If $\zeta > 0$, the tail decays as a polynomial function; if $\zeta = 0$, the tail decays exponentially, and if $\zeta < 0$, the upper tail is bounded. The shape parameter is often assumed to be constant because it is difficult to estimate [6,33]. However, it would be advantageous to allow all GEV parameters to vary as a function of covariate [15,34].

The quantiles of the GEV distribution function are particularly significant because of their interpretation as return levels. The behavior of the extremes of the distribution function can be seen as the upper quantiles of a high order. To estimate these quantiles for the GEV, we invert Equation (2) such that $G(z_p) = 1 - p$ to obtain a return level z_p , with a return period $T = 1/p$ which should be exceeded by the annual maximum with a probability p . The return level is given as follows:

$$z_p = \begin{cases} \mu - \frac{\sigma}{\zeta} [1 - (-\log(1 - p))^{-\zeta}] & \text{if } \zeta \neq 0 \\ \mu - \sigma \log(-\log(1 - p)) & \text{if } \zeta = 0 \end{cases} \quad (3)$$

The block maxima approach consists of sampling the observed maximum over a block, which is often chosen to correspond to a period of one year. In this paper, the block is considered as the rainy season in order to reduce the effect of temporal non-stationarity.

Several approaches have been proposed to estimate the parameters of the GEV distribution, including maximum likelihood (ML) or L-moments. The L-moment method estimates the set of parameters by matching the L-moments of the model to the L-moments of the empirical distribution [35,36]. It generally performs well with small samples and is usually more robust and less biased than the ML. However, applying the L-moment estimator is almost limited to stationary data. We will use the L-moment for the pointwise estimation and the ML for the spatial estimation.

3.2. Smooth Spatial Modeling for Extremes

3.2.1. Generalized Linear Models

The generalized linear model (GLM) is an extension of ordinary linear regression [37]. This model is widely used to model hydrometeorological variables [38,39]. The main idea of GLMs is to allow the linear model to be related to a response variable through a link function. These variables are no longer limited to the normal distribution, as assumed in linear regression, and they can come from any exponential family distribution (e.g., Gamma, Poisson). We consider that for a response variable Y assumed to follow the same exponential family distribution, and for x_n a set of covariates, there exists the following relation:

$$g(E(Y|x)) = \beta_0 + \sum_{i=1}^n \beta_i x_i. \quad (4)$$

The link function $g(\cdot)$ is used to define a relationship between the linear predictor $\beta_0 + \sum_{i=1}^n \beta_i x_i$ and the conditional mean of the distribution $E(Y|x)$. The choice of this function depends on the nature of the response variable (e.g., identity, log). The set of parameters β is estimated by the maximum likelihood [40].

Smooth spatial modeling can be achieved by considering that the input variables x are covariates reflecting spatial information. Suppose that $g(z) = (g_1(z), g_2(z), g_3(z))$. The GLM applied to the GEV distribution can be written as follows:

$$g_1(\mu(Y, \beta_\mu)) = \beta_{\mu_0} + \sum_{i=1}^n \beta_{\mu_i} x_i \tag{5}$$

$$g_2(\sigma(Y, \beta_\sigma)) = \beta_{\sigma_0} + \sum_{i=1}^n \beta_{\sigma_i} x_i \tag{6}$$

$$g_3(\xi(Y, \beta_\xi)) = \beta_{\xi_0} + \sum_{i=1}^n \beta_{\xi_i} x_i, \tag{7}$$

where $g(z) = (z, \log(z), \log(z + 0.5))$. The link function for the scale parameter is the log function to ensure its positivity. For the shape parameter, it is assumed that $\xi > -0.5$ to ensure the regularity of the maximum likelihood estimators. The GLM is implemented by the VGAM package [41] for the R statistical computing environment.

3.2.2. Artificial Neural Networks

The artificial neural network (ANN) is a flexible model capable of identifying complex non-linear relationships between inputs and outputs [18], without predefined information about the underlying process involved. They are composed of a set of stacked and interconnected layers: the first layer contains inputs, the last layer contains outputs, and the layers in between are called hidden layers. In this work, we will use a feed-forward neural network with one hidden layer, i.e., the information flow is unidirectional from input to output. The neurons feed the neurons of the following layers to obtain final output data. Associating an ANN with the GEV distribution is equivalent to considering that the parameters (μ, σ, ξ) are the outputs of the network.

The first step of training the neural network (forward phase) is presented as follows. Suppose that $x = \{x_1, \dots, x_n\}$ are the input variables (or covariates). Each neuron j of the hidden layer transforms m linear combination of inputs to give an output:

$$z_j = h\left(\sum_{i=1}^n w_{ji} x_i + w_{j0}\right), \tag{8}$$

with $j = 1, \dots, m$. w_{ji} is the weight between two neurons i and j , and w_{j0} is the bias of the neuron j . We took the hyperbolic tangent as the activation function $h(\cdot)$ of the hidden layer. To obtain the outputs $\theta_k = (\mu, \sigma, \xi)$, we proceed to another linear combination with the activation function $f(\cdot)$ over z_j :

$$\theta_k = f\left(\sum_{j=1}^m w_{kj} z_j + w_{k0}\right). \tag{9}$$

For $y = \{y_1, \dots, y_n\}$ that comes from a GEV distribution, the conditional log likelihood is defined as a cost function to optimize the parameter values. To ensure that $-0.5 < \xi < 0.5$, we assumed that $\xi = \frac{2}{k} - 0.5$ for all $k > 2$. The cost function can be written as follows:

$$\begin{aligned} l(\theta; y) &= \log \sigma + \left(1 + \frac{1}{\xi}\right) \sum_{i=1}^n \log \left[1 + \xi \left(\frac{y_i - \mu}{\sigma}\right)\right] + \sum_{i=1}^n \left[1 + \xi \left(\frac{y_i - \mu}{\sigma}\right)\right]^{-\frac{1}{\xi}} \\ &= \log \sigma + \left(\frac{2 + 0.5k}{2 - 0.5k}\right) \sum_{i=1}^n \log \left[1 + \frac{(2 - 0.5k)(y_i - \mu)}{k\sigma}\right] + \sum_{i=1}^n \left[1 + \frac{(2 - 0.5k)(y_i - \mu)}{k\sigma}\right]^{-\left(\frac{k}{2 - 0.5k}\right)}. \end{aligned} \tag{10}$$

The second step (the backward phase) consists of the computation of the gradient of the log-likelihood in Equation (10) with respect to all the weights of the network using the

back-propagation algorithm, and the optimization is completed with a gradient descent algorithm. Weights are given randomly at the first step of the training and then updated until convergence.

The complexity level is controlled by the number of hidden units of the neural network. Indeed, the number of hidden units directly influences the number of weights in the ANN and hence its flexibility. The choice of the number of hidden units must satisfy the bias–variance trade-off: if it is too small, the ANN is biased (a phenomenon also called under-fitting), if it is too high, the ANN has a large variance (a phenomenon also called over-fitting). Therefore, the selected number of hidden units must simultaneously minimize the bias and variance of the ANN. One way to do this is to use cross-validation, which is a process that aims to estimate the generalization capability, i.e., the ability to perform well on unseen data.

In this work, to estimate the generalization capability, we will use the 10-fold cross-validation technique summarized in the following steps:

- Shuffle the data set randomly.
- Split the data set into $k = 10$ folds.
- For each fold:
 - Define that fold as the validation data set.
 - Define the remaining folds as the training data set.
 - Fit the model on the training set and evaluate on the validation set.
- The error is calculated as the average of the error over all validation sets. The optimal number of hidden units corresponds to the minimum of errors.

4. Results

The present research compares two spatial models (GLM and ANN), which are defined in Section 3, applied to the daily rainfall data sets described in Section 2. In Section 4.1, we explored the estimation of the GEV parameters locally (i.e., for each gauging station) to gain insight into the spatial estimation. Then, in Section 4.2, we proceeded to build the two spatial models by identifying the covariates and the appropriate level of complexity (i.e., the number of hidden units). Finally, comparison and evaluation were dedicated in Section 4.3.

4.1. Pointwise GEV Parameters Estimation

Once the maxima per rainy season have been fixed for each station s , the GEV distribution parameters (μ_s, σ_s, ξ_s) are estimated locally by the L-moments method. The 100-year return levels were computed from these estimates by Equation (3). A summary of all point estimates is presented in Figure 5. All shape parameter estimates are between -0.5 and 0.5 . Indeed, the majority of stations have positive values of the shape parameter indicating the heaviness of the tail of the distribution (very large rainfall events can occur). However, fewer stations have negative values in the Merguellil and Cap Bon region compared to the French Mediterranean (32 stations).

Pointwise parameter estimates can only give information for the few stations where data are available. It will be more interesting to investigate the spatial variation of these parameters at any point in space. The following part of this article will focus on this issue.

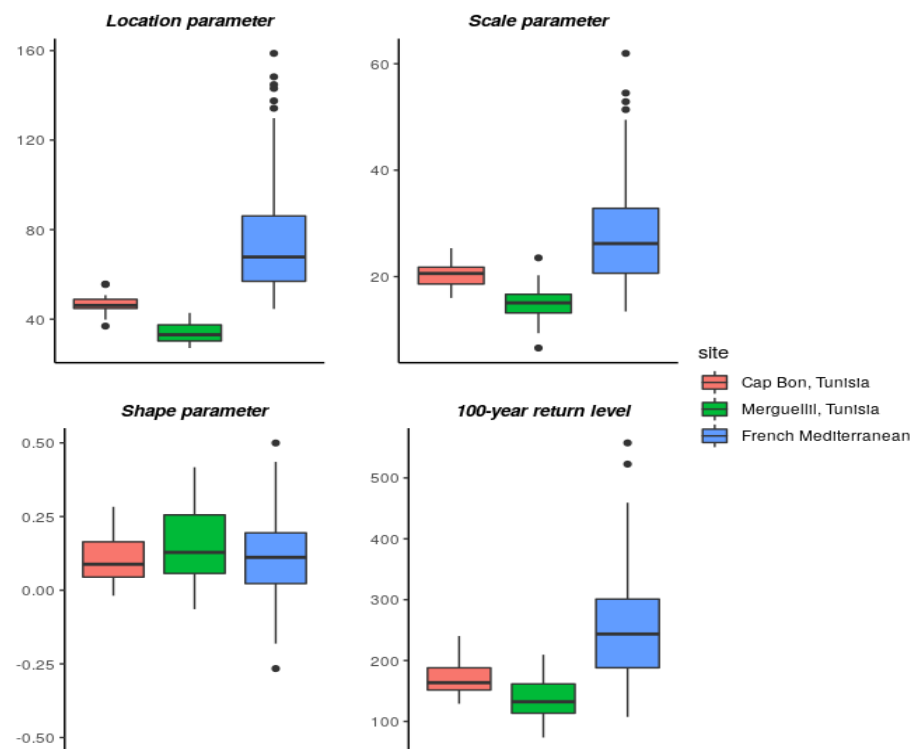


Figure 5. Box-plots of estimated L-moments parameters of GEV distribution (μ, σ, ξ) and 100-year return level.

4.2. Spatial GEV Parameters Estimation

Two spatial tools have been proposed, acting as a bridge between local rainfall information to a smooth spatial mapping. For both models, the choice of covariates was made by 10-fold cross-validation (as explained in Section 3.2.2). The models are fitted for all possible combinations of the selected covariates (see row names of Table 1). Validation error values that resulted from the cross-validation technique by fitting the GLM are presented in Table 1. For the ANN, there is an additional choice of the number of hidden units. We therefore have more validation errors to compare corresponding to the fitted ANN model with $nh = (0, 1, 2, 4, 6, 8, 12)$ hidden units. Results of covariate selection and the optimal number of hidden units for each region are summarized in Table 2.

Results of the 10-fold cross-validation error curves by fitting the ANN model are presented in Appendix A.2. For the French Mediterranean site, we notice that the error curves do not rise with increasing the complexity level to 12 hidden units. According to the theory, the validation error curves tend to decrease until they reach a minimum and then increase again as we add complexity to the model. While performing some preliminary tests, we discovered that the data set is so large that we do not reach the overfitting area. Regarding the number of hidden units, the difference in terms of validation error is tiny, between 4 and 8 hidden units, so the optimal number was chosen where the descent stops (4 hidden units). We can also learn from these curves that using a unique covariate will give the worst models. So, it is recommended to select at least two covariates. When the four proposed covariates (x, y, z, chirps) are used simultaneously, the best model with the lowest validation error was obtained compared to the results produced by applying the other set of covariates. This finding emphasizes the interest in considering the climate variable CHIRPS. For both Tunisian regions, a single hidden unit corresponds to the model with the least errors. The selected covariates for the region of Merguellil are (y, chirps), and those for the Cap Bon region are (y, z). Compared with the French region, the model with the four covariates increases the error value, and that using two covariates is required to obtain a good performance.

Table 1. Validation error values for the GLM model resulted from the 10-fold cross-validation.

Covariate	French Mediterranean	Merguellil	Lebna
x	4341.18	488.39	364.70
y	4382.88	488.36	367.07
z	4341.94	488.46	366.97
chirps	4326.7	488.56	365.08
(x,y)	4305.67	487.34	361.42
(x,z)	4301.3	487.21	364.51
(y,z)	4340.35	488.63	363.98
(x,chirps)	4296.11	486.64	364.42
(y,chirps)	4313.43	487.00	364.65
(z,chirps)	4314.11	487.50	363.04
(x,y,z)	4275.84	486.52	360.75
(x,y,chirps)	4295.64	486.93	360.91
(y,z,chirps)	4301.79	487.46	361.89
(x,z,chirps)	4277.24	486.60	362.39
(x,y,z,chirps)	4274.04	486.55	361.25

Table 2. The selected covariates for the spatial model (GLM and ANN) of the GEV parameters over the three sites. The number of hidden units concerns only the ANN model.

Site	GLM Covariate	ANN Covariate	Number of Hidden Units
French Mediterranean	(x,y,z,chirps)	(x,y,z,chirps)	4
Merguellil	(x,y,z)	(y,chirps)	1
Lebna	(x,y,z)	(y,z)	1

4.3. Model Evaluation

After selecting the covariates and the number of hidden units, we want to compare the two models (ANN versus GLM). For this purpose, negative log-likelihood values were calculated for each station and each study site. The number of stations that verified a minimum negative log-likelihood value with the neural network model was then calculated. The ratio over the total number of stations is given in Table 3. In addition, the goodness-of-fit was evaluated by the non-parametric Kolmogorov–Smirnov (Ks) test. The percentage of stations with a lower Ks distance using the ANN model was computed. These two values prove that the neural network model performs better on more than 60% of the stations compared to the GLM model.

Table 3. The rate of the number of stations with a better performance with the ANN model.

Site	Negative Log-Likelihood	Kolmogorov–Smirnov
French Mediterranean	72.67%	74.35%
Merguellil	61.53%	65.38%
Lebna	61.1%	61.1%

To support this evaluation, we selected test stations (six stations for the French Mediterranean region and two stations for each Tunisian region) having a large number of observations and well distributed in space (see the stations depicted with red points in Figure 2). The Bootstrap resampling method was used to construct the 95% confidence bands of the return level curves. This technique was applied to both selected models (ANN and GLM)

at the stations that were kept aside for testing. In total, 1000 replications were obtained by sampling with replacement years of annual maxima. The estimated return levels are represented by curves with the corresponding confidence bands. The evaluation consists of comparing the bands with the empirical return levels (black dots) based on observations.

For the French Mediterranean region, return level curves are presented in Figure 6. Confidence intervals represent the range of uncertainty associated with the estimate. The width of the GLM confidence intervals is narrow for most test stations compared to the ANN bands. In this case, the margin of error is smaller, and the model offers more precision. However, the GLM presents overestimation in St-Montan and Marsanne (stations 1 and 2, respectively, in Figure 2) or an underestimation in Nimes-courbessac and Mayres (station 3 and 6, respectively, in Figure 2) of the empirical estimates. Although the confidence bands are wider for the ANN, it can better capture empirical values.

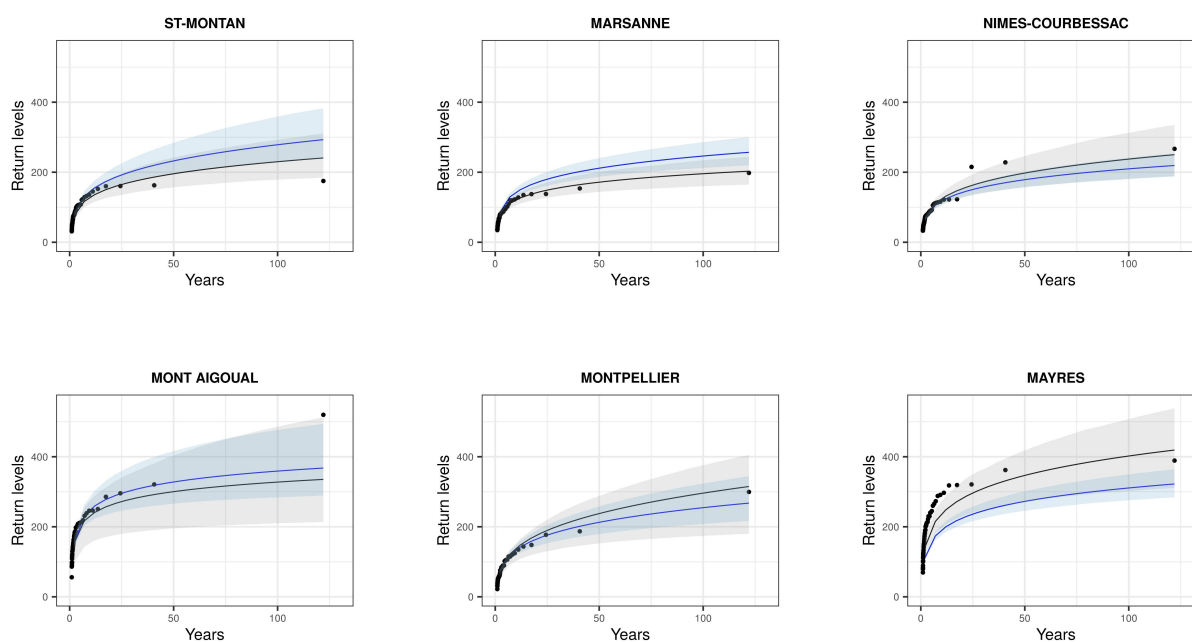


Figure 6. Return levels at the selected test stations for the French Mediterranean region. The 95% bootstrap confidence bands of the return levels obtained from the fitted models: the ANN in gray and the GLM in blue. The dots represent the empirical return levels.

For the Tunisian sites, return level curves are presented in Figures 7 and 8. For these regions, the low density of the network of gauging stations implies that stations at the limit of the studied domain may suffer from a high estimation uncertainty because the regression model extrapolates outside its knowledge. The same evaluation process was applied to different selected test stations in each Tunisian region. An increase in the variation of the confidence bands was observed.

The test stations chosen in France have a complete number of observations, while in Capbon, we have an average of 19.29% of missing values on the two test stations (46.79% on all stations), and for Merguellil, we have an average of 46.3% of missing values (59.74% on all stations). The large number of stations in the French region, as well as the density of the hydro-meteorological station network, means that the model has more training data. This may affect the choice of model in terms of covariates and hidden units, which generates models with more accuracy when compared with the Tunisian data.




Figure 7. Return levels at the selected test stations for the Merguellil region, showing 95% bootstrap confidence bands of the return levels obtained from the fitted models: the ANN in gray and the GLM in blue. The dots represent the empirical return levels.




Figure 8. Return levels at the selected test stations for the Cap Bon region, showing 95% bootstrap confidence bands of the return levels obtained from the fitted models: the ANN in gray and the GLM in blue. The dots represent the empirical return levels.

Given the difference between the results obtained for the French Mediterranean and Tunisia, a relationship was suspected between the density of the networks of the gauging station and the obtained results. It is certain that the quality of the data plays a major factor in the modeling. We performed a downgrading of the French dataset to become closer to the Tunisian dataset. For the French Mediterranean, the number of stations per 1000 km² is 6.57, i.e., 1 station per 152 km². For Merguellil, the number of stations per 1000 km² is 3.6, i.e., 1 station per 277 km². To have approximately the same density, we selected 100 stations instead of 183. The selection of covariates in this case for the ANN model is 4 hidden units and the covariates (x,y,z). We even attempted to take the same number of stations, i.e., 26 stations for the French Mediterranean region. In this case, the result of the cross-validation for the ANN model is to use (x,y,z,chirps) as covariates and 2 hidden units. From these experiments, we can deduce that there is a close relationship between model complexity and input size, which explains the difference between the number of hidden units in Table 2 (four for the French Mediterranean and one for each Tunisian site).

To review, the evaluation of the performance of the two models shows that the ANN model is considered to be more accurate than the GLM model for spatially approximating the risk of extreme events for these three study sites. The choice of covariates and the number of hidden units is different from one study site to another due to the difference in sample size as well as the difference in the inter-covariate association. By the 10-fold cross-validation, it was observed that the validation error is high when we fit a model with one covariate, and it is less obvious for two or more covariates.

In Figure 9, we present ANN spatial estimates within a radius of 15 km around the gauging stations of the French Mediterranean site. Pointwise estimates are illustrated by

points for each station. The location and scale parameters show the highest values in the northwestern mountainous region, corresponding to the same variation in local estimates. For the shape parameter, a different spatial representation is shown with the highest values at the lowest altitude. Spatially, there are only positive values of the shape parameter, unlike the results of the local estimation. The results of the spatial estimation by ANN on the Tunisian sites are shown in Appendix A.1.

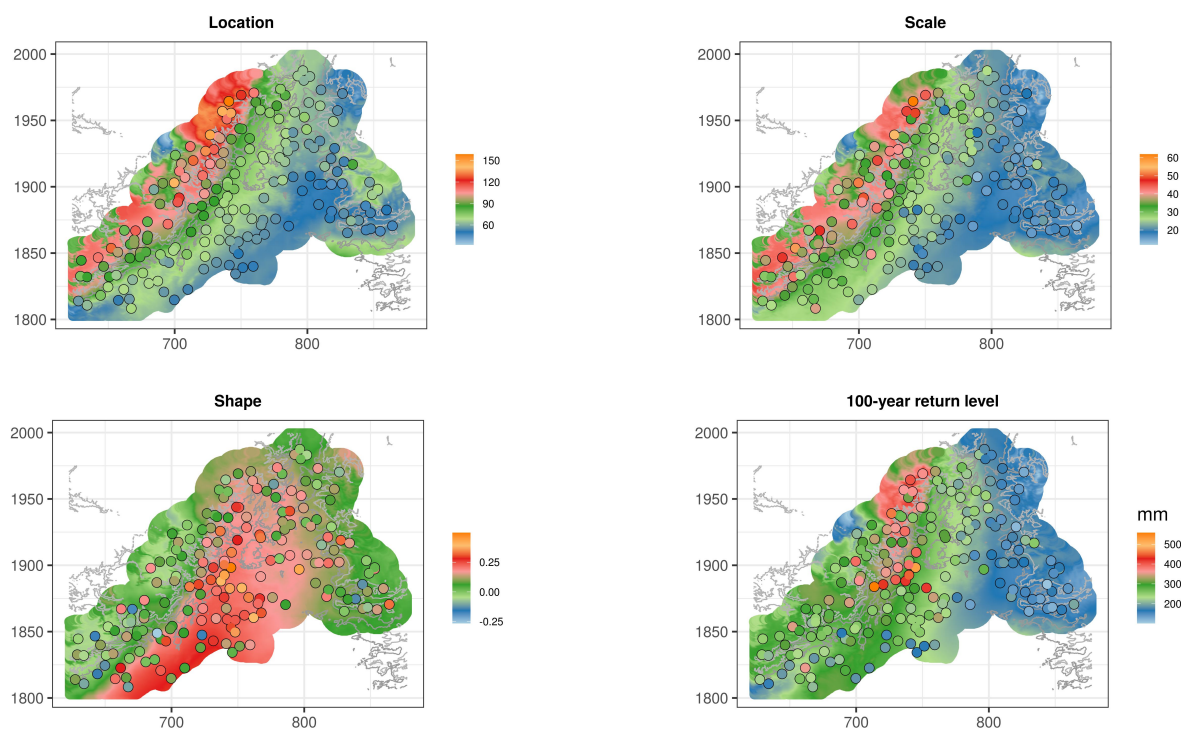


Figure 9. Estimates of the GEV parameters (μ, σ, ξ) and the 100-year return level over the French Mediterranean region. Spatial estimates result from an ANN using (x, y, z, chirps) as covariates with four hidden units, and the point estimations are obtained by the L–moments method.

5. Discussion

In this work, we have emphasised the use of response surfaces for a smooth spatial representation of extreme events. This choice was motivated by the outcomes of [15,16]. It has been explicitly stated that it will be more efficient to bypass conventional spatial interpolation methods. Regional methods are more stable than methods based on spatial interpolation. It is of great benefit to take the surrounding area into account in order to ensure a smooth spatial variation of the parameters.

ANNs have proven their performance as a modern machine learning technique in several research areas and are gaining more and more popularity in hydrological studies. They overcome some of the weaknesses, such as linearity assumptions, of more classical methods. However, they are often seen as “black box” models in the sense that, while approximating a function, studying its structure will not provide any insight into the structure of the approximated function. Hence, the influence of each parameter estimate on covariates is difficult to interpret. For this purpose, it would be worth investigating the use of so-called interpretive machine learning (ML) models, where ANNs can be enhanced to highlight the understanding of relevant relationships in the data. For instance, the authors in [42,43] have built a flexible modeling framework by applying ML models to induce physically consistent models with high predictive accuracy. The idea is to combine a data-driven method (such as ANNs) with the understanding of physical process models: the training could be guided to mimic a physical phenomenon by specifying a physical law, serving as prior knowledge and added into the loss function.

Furthermore, we have focused on the analysis of extreme rainfall events that occur on a daily time scale. In fact, daily records are more widely available and usually exceed the length of the sub-daily observations. However, hydrological estimations often require long time series at high temporal resolution. The issue can be overcome by disaggregating daily into sub-daily values. Several resampling methods have been proposed to simulate a range of possible disaggregation scenarios that could occur at finer time scales. For example, non-parametric resampling models based on methods of fragments (MOF) (also called the analog method) have been shown to perform well compared to other disaggregation approaches [44,45]. In particular, [46] presented a space-time approach based on the MOF to convert daily-to-hourly precipitation. It would be interesting to follow up this idea by applying the proposed model to finer time scale data. Along the same lines, it would be interesting to perform a spatial estimation of the intensity–duration–frequency (IDF) curves in order to estimate the distribution of extreme precipitation of any duration at ungauged locations [47,48]. This could be seen as a starting point for building stochastic weather generators [49,50] that takes in account extreme events.

6. Conclusions

The main challenge of this work is to map the risk of extreme rainfall events taking into account spatial non-stationarity. To achieve this goal, two spatial estimation approaches are proposed to be applied to GEV parameters to assess the risk through the associated return levels. It has been shown that smooth spatial modeling by ANN gives better results on more than 60% of the stations compared to the GLM model.

One critical issue is to control the complexity level and the bias–variance trade-off. It was identified by optimizing the number of hidden neurons by a cross-validation method. Using a high variance model may not adequately capture the structure of the underlying phenomenon and become too dependent on training data. By contrast, a simpler model may lack flexibility and fail to capture the full complexity of the phenomenon. The trade-off between bias and variance occurs at the minimum of the generalization error.

The other issue concerns the choice of appropriate covariates that serve to add a geographical influence in the modeling of spatial non-stationarity. The CHIRPS climate variable is an effective source of information on the spatial distribution of rainfall. It was initially used in this study to compare the spatial behavior of observations. We checked the inter-annual totals of the gauging stations against the CHIRPS covariate, and we noticed that the local observations are globally higher than the CHIRPS rains, which is expected since it is an average over a 4 km grid. We included the CHIRPS data as a covariate with the geographical coordinates to provide a spatial description of the three Mediterranean regions.

Author Contributions: Conceptualization, H.H., J.C., L.N. and S.E.; Data curation, H.H., J.C. and H.F.; Formal analysis, H.H. and J.C.; Funding acquisition, J.C. and L.N.; Investigation, H.H., J.C. and L.N.; Methodology, H.H., J.C. and L.N.; Resources, J.C. and L.N.; Software, H.H. and J.C.; Supervision, J.C., L.N. and S.E.; Validation, J.C., L.N. and S.E.; Visualization, J.C., L.N. and S.E.; Writing—original draft preparation, H.H.; Writing—review and editing, H.H., J.C., L.N., S.E. and H.F. All authors have read and agreed to the published version of the manuscript.

Funding: This publication was made possible through support provided by the IRD. The second author was supported by the starting grants from Polytechnique Montreal and IVADO. In addition, she acknowledges the support of the Natural Sciences and Engineering Research Council of Canada (NSERC), [funding reference number RGPIN-2022-0405].

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: Not applicable.

Conflicts of Interest: The authors declare no conflict of interest.

Appendix A

Appendix A.1. Estimation of the GEV Parameters Using ANN on the Tunisian Sites

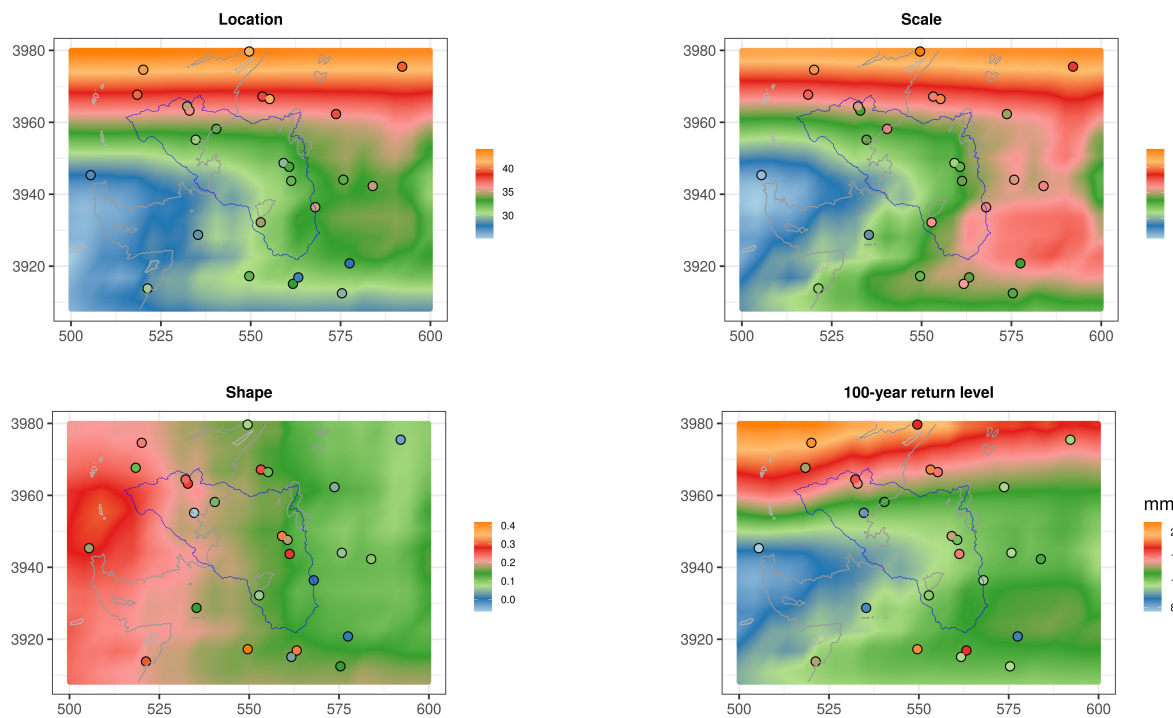


Figure A1. Estimates of the GEV parameters (μ, σ, ξ) and the 100-year return level over the Merguellil region. The spatial estimates are resulted from an ANN using (y, chirps) as covariates with 1 hidden unit and the point estimations are obtained by the L-moments method.

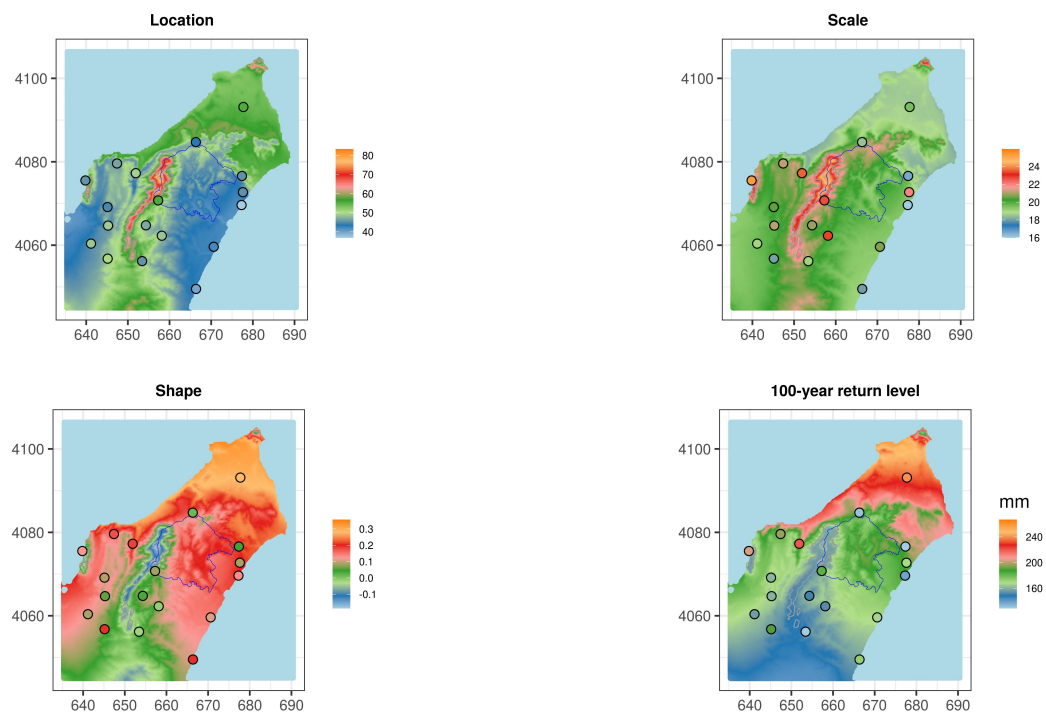


Figure A2. Estimates of the GEV parameters (μ, σ, ξ) and the 100-year return level over the Cap Bon region. The spatial estimates are resulted from an ANN using (y, z) as covariates with 1 hidden unit, and the point estimations are obtained by the L-moments method.

Appendix A.2. 10-Fold Cross-Validation Results




Figure A3. Result of the 10-fold cross-validation with the ANN model for the French Mediterranean site.

References

- Gaume, E.; Borga, M.; Llassat, M.; Maouche, S.; Lang, M.; Diakakis, M. Sub-chapter 1.3.4. Mediterranean extreme floods and flash floods. In *The Mediterranean Region under Climate Change*; Collection Synthèses; IRD Editions: Marseille, France, 2016; pp. 133–144. [\[CrossRef\]](#)
- Leduc, C.; Ammar, S.B.; Favreau, G.; Beji, R.; Virrion, R.; Lacombe, G.; Tarhouni, J.; Aouadi, C.; Chelli, B.Z.; Jebnoun, N.; et al. Impacts of hydrological changes in the Mediterranean zone: Environmental modifications and rural development in the Merguellil catchment, central Tunisia/Un Ex. D'évolution Hydrol. En Méditerranée: Impacts Des Modif. Environnementales Et Du Développement Agric. Dans Le Bassin-Versant Du Merguellil (Tunisie Cent. *Hydrol. Sci. J.* **2007**, *52*, 1162–1178. [\[CrossRef\]](#)
- Hmidi, N.; Fehri, N.; Baccar, A. Inondation devastatrice dans la ville de Soliman (Tunisie): Cas de sa zone industrielle lors de l'événement pluviométrique du 22 septembre 2018. In *Le Changement Climatique, la Variabilité et les Risques Climatiques*; AIC: Aix-en-Provence, France, 2019; p. 199.
- Brunet, P.; Bouvier, C.; Neppel, L. Retour d'expérience sur les crues des 6 et 7 octobre 2014 à Montpellier-Grabels (Hérault, France) : Caractéristiques hydro-météorologiques et contexte historique de l'épisode. *Physio-Géo* **2018**, *12*, 43–59. [\[CrossRef\]](#)
- Katz, R.W.; Parlange, M.B.; Naveau, P. Statistics of extremes in hydrology. *Adv. Water Resour.* **2002**, *25*, 1287–1304. [\[CrossRef\]](#)
- Coles, S. *An Introduction to Statistical Modeling of Extreme Values*; Springer Series in Statistics; Springer: Berlin/Heidelberg, Germany, 2001. [\[CrossRef\]](#)
- Vicente-Serrano, S.M.; Saz-Sánchez, M.A.; Cuadrat, J.M. Comparative analysis of interpolation methods in the middle Ebro Valley (Spain): Application to annual precipitation and temperature. *Clim. Res.* **2003**, *24*, 161–180. [\[CrossRef\]](#)
- Li, J.; Heap, A.D. *A Review of Spatial Interpolation Methods for Environmental Scientists*; Geoscience Australia: Canberra, Australia, 2008; p. 154.
- Kumar Adhikary, S.; Muttill, N.; Gokhan Yilmaz, A. Ordinary kriging and genetic programming for spatial estimation of rainfall in the Middle Yarra River catchment, Australia. *Hydrol. Res.* **2016**, *47*, 1182–1197. [\[CrossRef\]](#)
- Feki, H.; Slimani, M.; Cudennec, C. Incorporating elevation in rainfall interpolation in Tunisia using geostatistical methods. *Hydrol. Sci. J.* **2012**, *57*, 1294–1314. [\[CrossRef\]](#)
- Feki, H.; Slimani, M.; Cudennec, C. Geostatistically based optimization of a rainfall monitoring network extension: Case of the climatically heterogeneous Tunisia. *Hydrol. Res.* **2017**, *48*, 514–541. [\[CrossRef\]](#)

12. Ceresetti, D.; Ursu, E.; Carreau, J.; Anquetin, S.; Creutin, J.D.; Gardes, L.; Girard, S.; Molinié, G. Evaluation of classical spatial-analysis schemes of extreme rainfall. *Nat. Hazards Earth Syst. Sci.* **2012**, *12*, 3229–3240. [[CrossRef](#)]
13. Shepard, D. A two-dimensional interpolation function for irregularly-spaced data. In Proceedings of the 1968 23rd ACM National Conference, New York, NY, USA, 27–29 August 1968; ACM Press: New York, NY, USA, 1968; pp. 517–524. [[CrossRef](#)]
14. Goovaerts, P. Geostatistical approaches for incorporating elevation into the spatial interpolation of rainfall. *J. Hydrol.* **2000**, *228*, 113–129. [[CrossRef](#)]
15. Blanchet, J.; Lehning, M. Mapping snow depth return levels: Smooth spatial modeling versus station interpolation. *Hydrol. Earth Syst. Sci.* **2010**, *14*, 2527–2544. [[CrossRef](#)]
16. Neppel, L.; Arnaud, P.; Borch, F.; Carreau, J.; Garavaglia, F.; Lang, M.; Paquet, E.; Renard, B.; Soubeyroux, J.; Veysseire, J. Résultats du projet Extraflo sur la comparaison des méthodes d'estimation des pluies extrêmes en France. *Houille Blanche-Rev. Int. L'eau* **2014**, *2*, 14–19. [[CrossRef](#)]
17. Chowdhury, M.; Alouani, A.; Hossain, F. Comparison of ordinary kriging and artificial neural network for spatial mapping of arsenic contamination of groundwater. *Stoch. Environ. Res. Risk Assess.* **2010**, *24*, 1–7. [[CrossRef](#)]
18. Bishop, C.M. *Pattern Recognition and Machine Learning*; Information Science and Statistics; Springer: Berlin/Heidelberg, Germany, 2006.
19. Carreau, J.; Toulemonde, G. Extra-parametrized extreme value copula: Extension to a spatial framework. *Spat. Stat.* **2020**, *40*, 100410. [[CrossRef](#)]
20. Trambly, Y.; Neppel, L.; Carreau, J.; Najib, K. Non-stationary frequency analysis of heavy rainfall events in southern France. *Hydrol. Sci. J.* **2013**, *58*, 280–294. [[CrossRef](#)]
21. Panthou, G.; Vischel, T.; Lebel, T.; Blanchet, J.; Quantin, G.; Ali, A. Extreme rainfall in West Africa: A regional modeling. *Water Resour. Res.* **2012**, *48*, 8. [[CrossRef](#)]
22. Šraj, M.; Viglione, A.; Parajka, J.; Blöschl, G. The influence of non-stationarity in extreme hydrological events on flood frequency estimation. *J. Hydrol. Hydromech.* **2016**, *64*, 426–437. [[CrossRef](#)]
23. Villarini, G.; Smith, J.; Serinaldi, F.; Ntelekos, A.; Schwarz, U. Analyses of extreme flooding in Austria over the period 1951–2006. *Int. J. Climatol.* **2012**, *32*, 1178–1192. [[CrossRef](#)]
24. Aissaoui-Fqayeh, I.; El-Adlouni, S.; Ouarda, T.B.M.J.; St-Hilaire, A. Non-stationary lognormal model development and comparison with the non-stationary GEV model. *Hydrol. Sci. J.* **2009**, *54*, 1141–1156. [[CrossRef](#)]
25. Wagner, P.D.; Fiener, P.; Wilken, F.; Kumar, S.; Schneider, K. Comparison and evaluation of spatial interpolation schemes for daily rainfall in data scarce regions. *J. Hydrol.* **2012**, *464*, 388–400. [[CrossRef](#)]
26. Slimani, M.; Cudennec, C.; Feki, H. Structure du gradient pluviométrique de la transition Méditerranée-Sahara en Tunisie: Déterminants géographiques et saisonnalité/Structure Rainfall Gradient Mediterranean-Sahara Transit. Tunisia: Geogr. Determ. Seas. *Hydrol. Sci. J.* **2007**, *52*, 1088–1102. [[CrossRef](#)]
27. Raymond, F. and Ullmann, A.; Trambly, Y.; Drobinski, P.; Camberlin, P. Evolution of Mediterranean extreme dry spells during the wet season under climate change. *Reg. Environ. Chang.* **2019**, *19*, 2339–2351. [[CrossRef](#)]
28. Joly, D.; Brossard, T.; Cardot, H.; Cavailles, J.; Hilal, M.; Wavresky, P. Les types de climats en France, une construction spatiale. *Cybergeo* **2010**, *501*, 34–42. [[CrossRef](#)]
29. Pujol, N.; Neppel, L.; Sabatier, R. Approche régionale pour la détection de tendances dans des séries de précipitations de la région méditerranéenne française. *Comptes Rendus Geosci.* **2007**, *339*, 651–658. [[CrossRef](#)]
30. Lacombe, G.; Cappelaere, B.; Leduc, C. Hydrological impact of water and soil conservation works in the Merguellil catchment of central Tunisia. *J. Hydrol.* **2008**, *359*, 210–224. [[CrossRef](#)]
31. Funk, C.; Peterson, P.; Landsfeld, M.; Pedreros, D.; Verdin, J.; Shukla, S.; Husak, G.; Rowland, J.; Harrison, L.; Hoell, A.; et al. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. *Sci. Data* **2015**, *2*, 150066. [[CrossRef](#)] [[PubMed](#)]
32. Fisher, R.A.; Tippett, L.H.C. Limiting forms of the frequency distribution of the largest or smallest member of a sample. *Math. Proc. Camb. Philos. Soc.* **1928**, *24*, 180–190. [[CrossRef](#)]
33. Pujol, N.; Neppel, L.; Sabatier, R. Regional tests for trend detection in maximum precipitation series in the French Mediterranean region. *Hydrol. Sci. J.* **2007**, *52*, 956–973. [[CrossRef](#)]
34. Cooley, D.; Nychka, D.; Naveau, P. Bayesian Spatial Modeling of Extreme Precipitation Return Levels. *J. Am. Stat. Assoc.* **2007**, *102*, 824–840. [[CrossRef](#)]
35. Hosking, J. L-moments: Analysis and Estimation of Distribution us sing Linear Combinations of Order Statistics. *J. R. Stat. Soc. Ser. B Methodol.* **1990**, *52*, 105–124. [[CrossRef](#)]
36. Hosking, J.R.M.; Wallis, J.R. *Regional Frequency Analysis: An Approach Based on L-Moments*, 1st ed.; Cambridge University Press: Cambridge, UK, 1997. [[CrossRef](#)]
37. McCullagh, P. *Generalized Linear Models*; Routledge: London, UK, 2019.
38. Chandler, R. On the use of generalized linear models for interpreting climate variability. *Environmetrics* **2005**, *16*, 699–715. [[CrossRef](#)]
39. Yan, Z.; Bate, S.; Chandler, R.E.; Isham, V.; Wheeler, H. An Analysis of Daily Maximum Wind Speed in Northwestern Europe Using Generalized Linear Models. *J. Clim.* **2002**, *15*, 2073–2088. [[CrossRef](#)]

40. McCullagh, P.; Nelder, J.A. *Generalized Linear Models*; Monographs on statistics and applied probability; Chapman and Hall: New York, NY, USA, 1989.
41. Yee, T.W.; Stephenson, A. Vector generalized linear and additive extreme value models. *Extremes* **2007**, *10*, 1–19. [[CrossRef](#)]
42. Herath, H.; Chadalawada, J.; Babovic, V. Hydrologically informed machine learning for rainfall–runoff modelling: Towards distributed modelling. *Hydrol. Earth Syst. Sci.* **2021**, *25*, 4373–4401. [[CrossRef](#)]
43. Jiang, S.; Zheng, Y.; Wang, C.; Babovic, V. Uncovering flooding mechanisms across the contiguous United States through interpretive deep learning on representative catchments. *Water Resour. Res.* **2022**, *58*, e2021WR030185. [[CrossRef](#)]
44. Mezghani, A.; Hingray, B. A combined downscaling-disaggregation weather generator for stochastic generation of multisite hourly weather variables over complex terrain: Development and multi-scale validation for the Upper Rhone River basin. *J. Hydrol.* **2009**, *377*, 245–260. [[CrossRef](#)]
45. Carreau, J.; Mhenni, N.; Huard, F.; Neppel, L. Exploiting the spatial pattern of daily precipitation in the analog method for regional temporal disaggregation. *J. Hydrol.* **2019**, *568*, 780–791. [[CrossRef](#)]
46. Li, X.; Meshgi, A.; Wang, X.; Zhang, J.; Tay, S.H.X.; Pijcke, G.; Manocha, N.; Ong, M.; Nguyen, M.; Babovic, V. Three resampling approaches based on method of fragments for daily-to-subdaily precipitation disaggregation. *Int. J. Climatol.* **2018**, *38*, e1119–e1138. [[CrossRef](#)]
47. Mélése, V.; Blanchet, J.; Creutin, J. A Regional Scale-Invariant Extreme Value Model of Rainfall Intensity-Duration-Area-Frequency Relationships. *Water Resour. Res.* **2019**, *55*, 5539–5558. [[CrossRef](#)]
48. Ulrich, J.; Jurado, O.; Peter, M.; Scheibel, M.; Rust, H. Estimating IDF Curves Consistently over Durations with Spatial Covariates. *Water* **2020**, *12*, 3119. [[CrossRef](#)]
49. Fatichi, S.; Ivanov, V.; Caporali, E. Simulation of future climate scenarios with a weather generator. *Adv. Water Resour.* **2011**, *34*, 448–467. [[CrossRef](#)]
50. Li, X.; Babovic, V. A new scheme for multivariate, multisite weather generator with inter-variable, inter-site dependence and inter-annual variability based on empirical copula approach. *Clim. Dyn.* **2019**, *52*, 2247–2267. [[CrossRef](#)]

5.2 Résultats complémentaires

5.2.1 Choix des covariables et du niveau de complexité

La procédure de validation croisée a été utilisée dans cet article pour la sélection des covariables géographiques et la détermination du niveau de complexité du modèle ANN. Dans ce cas, l'évaluation d'un modèle influe directement sur la capacité du modèle à généraliser efficacement sur de nouvelles ensembles données (comme détaillé dans la Section 4.3.3). Théoriquement, les courbes d'erreur de validation ont tendance à diminuer jusqu'à atteindre un minimum, puis à augmenter à nouveau à mesure que nous ajoutons de la complexité au modèle. Le point où l'erreur de validation est la plus basse est généralement considéré comme le niveau optimal de complexité du modèle (Bishop, 2006). Cette observation est clairement mise en évidence par les deux figures 38 et 39, où nous avons ajusté un ANN en faisant varier le nombre d'unités cachées $nh = (0, 1, 2, 4, 6, 8, 12)$, explorant ainsi toutes les combinaisons possibles de covariables. Ce processus nous a permis d'identifier la configuration optimale en termes de complexité pour obtenir les meilleures performances de généralisation.

La Figure 38, présentant les résultats de la validation croisée pour le site de Merguelil, montre que l'erreur de validation atteint son minimum lorsque l'ensemble de covariables ($y, chirps$) est associé à une seule unité cachée. Ces résultats ont permis d'ajuster le modèle ANN et de générer les cartes d'estimations spatiales des paramètres de la GEV ainsi que l'estimation du niveau de retour 100 ans (Figure A1 dans l'article). Dans cette figure, nous avons superposé ces estimations en ponctuelle et en spatiale. Une observation remarquable concerne l'estimation sur les points de mesures, où deux stations au sud de la région, situées à une proximité d'environ 3 km l'une de l'autre, présentent des valeurs d'estimation du niveau de retour 100 ans assez éloignées (209.6 mm par rapport à 113.4 mm). Cette disparité peut s'expliquer par les mesures de maxima atteintes par chaque station, qui ont exercé une influence significative sur l'estimation du niveau de retour (278.3 mm contre 101.5 mm). Cette observation souligne la sensibilité des estimations aux conditions locales et met en évidence l'importance d'une analyse spatiale pour une meilleure interprétation des résultats. En ce qui concerne l'estimation spatiale du niveau de retour 100 ans, on constate une distribution asymétrique des estimations. Cette particularité peut être attribuée à l'effet orographique prédominant dans la région, où la topographie exerce une influence significative sur les précipitations. Il est remarquable de noter que cette observation persiste même en l'absence d'une prise en compte explicite de la covariable de l'altitude lors de la validation croisée.

La Figure 39, qui représente les résultats de la validation croisée pour le site du Cap Bon, montre que l'erreur de validation atteint son minimum lorsque l'ensemble de covariables (y, z) est associé à une seule unité cachée. Les estimations du niveau de retour 100 ans sur les points de mesures (Figure A2 de l'article) montre une bonne cohérence avec les estimations spatiale avec le modèle ANN ajusté. Il est intéressant de noter que les valeurs les plus élevées du niveau de retour ne correspondent pas à l'altitude la plus élevée de la région, à savoir Djebel Abderrahmen

(voir Figure 18). Au contraire, elles se situent davantage dans la zone de la pointe de la péninsule du Cap Bon. Cette observation souligne la particularité géographique de la région, suggérant que d'autres facteurs, tels que l'influence des masses d'air, peuvent jouer un rôle significatif dans la répartition des précipitations extrêmes. En effet, les régions côtières, en raison de leur proximité de la mer, sont souvent davantage influencées par les masses d'air en provenance de la mer, ce qui favorise la génération de précipitations extrêmes. Ainsi, cette tendance à recevoir plus de pluie que les régions intérieures peut être expliquée par les dynamiques atmosphériques liées à la proximité de la côte, comme démontré par les résultats des estimations du niveau de retour.

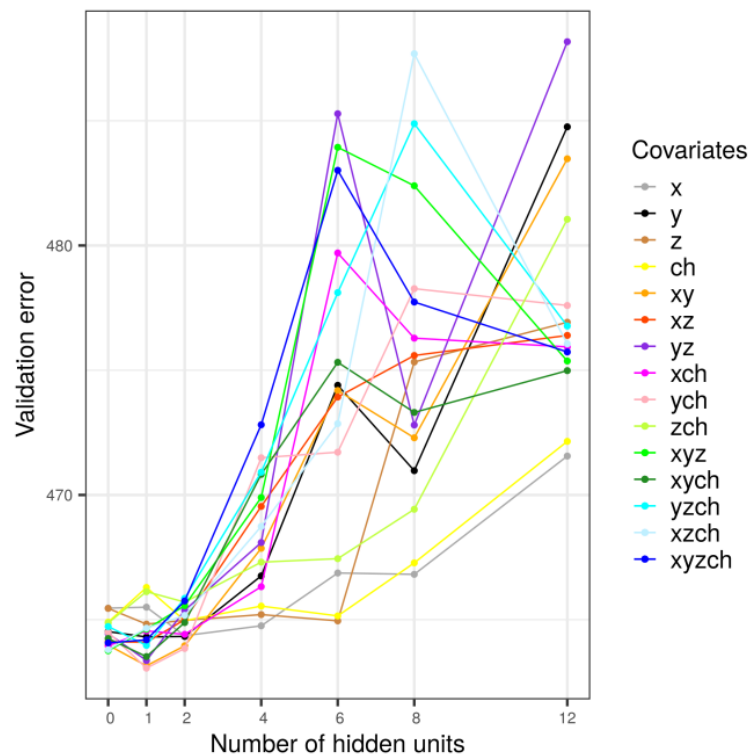


FIGURE 38 – Résultat des courbes de la validation croisée avec le modèle ANN pour le site du Merguellil.

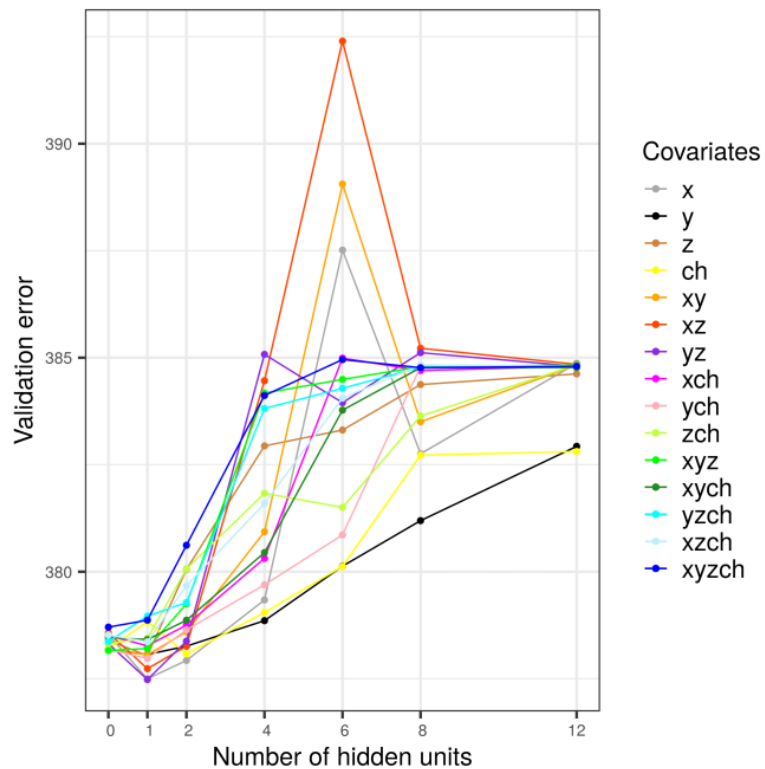


FIGURE 39 – Résultat des courbes de la validation croisée avec le modèle ANN pour le site du Cap Bon.

Modélisation des intensités de précipitations ordinaires et extrêmes

6.1 Introduction

Les approches basées sur les distributions de valeurs extrêmes GEV et GPD sont des outils puissants pour modéliser les phénomènes hydrométéorologiques extrêmes. Cependant, ces approches ont leurs limites car elles se concentrent uniquement soit sur les maxima par blocs, soit sur les valeurs dépassant un seuil spécifique. Dans certaines applications, notamment celles liées à la gestion des ressources en eau et des risques naturels, cette focalisation peut se révéler insuffisante. Prenons l'exemple des générateurs stochastiques, où il est nécessaire d'avoir des distributions marginales complètes pour l'ensemble des précipitations positives (e.g. (Evin et al., 2018)). Dans de tels contextes, il est crucial de prendre en compte l'ensemble des données disponibles afin d'obtenir une vision globale des caractéristiques climatiques et des schémas de précipitations. Dans cette optique, plusieurs modèles ont été proposés (voir section 1.4.2), en particulier les modèles de mélange. Cependant, ces modèles rencontrent plusieurs limitations, telles que le nombre élevé de paramètres impliqués, les fortes contraintes de continuité et les défis liés à l'inférence.

Ce chapitre se concentre donc sur la modélisation de la distribution complète des précipitations, qu'il s'agisse d'événements extrêmes ou ordinaires. L'objectif est de présenter un modèle capable de représenter de manière adéquate toutes les valeurs observées, en tenant compte à la fois des événements rares et intenses et des événements plus courants. On va commencer par une analyse comparative des résultats issus de la modélisation des valeurs extrêmes avec la GPD et la GEV, comme décrit dans la Section 6.2. Par la suite, une application de cette approche sur les trois sites d'études avec une comparaison des résultats sur les trois sites est présentée dans la Section 6.3.

6.2 Modélisation des valeurs extrêmes avec la GPD

Le choix du seuil est une étape cruciale dans l'application de la GPD pour modéliser les valeurs extrêmes. Ce choix peut avoir un impact significatif sur les résultats de la modélisation, notamment sur les estimations des paramètres et les prédictions des quantiles extrêmes. Il est important de choisir un seuil suffisamment élevé pour que la distribution des valeurs considérées comme "extrêmes" soit suffisamment représentative de la queue de la distribution, mais pas trop élevé pour éviter d'inclure des valeurs qui ne sont pas vraiment extrêmes et qui peuvent biaiser les estimations des paramètres de la distribution (Coles, 2001; Papalexiou et al., 2013). Plusieurs méthodes ont été conçues pour sélectionner le seuil approprié. Nous avons opté pour un seuil dépendant des stations qui correspond au quantile 98% des intensités de précipitations (>0.1 mm) pour chaque station. Le tableau 6.1 présente un résumé des valeurs de seuil choisies pour les stations de chaque site d'étude. Les résultats montrent que la région française se démarque par une valeur de seuil moyenne plus élevée que les deux autres sites. Par ailleurs, la moyenne du nombre de dépassements par saison des pluies varie également d'un site à l'autre, avec la valeur la plus faible observée au site Merguellil et la plus élevée à la région de la Méditerranée française. Ces différences dans les nombres de dépassements peuvent refléter les variations des régimes de précipitations entre les différents sites, ce qui peut à son tour affecter les estimations des paramètres de la GPD.

	La Méditerranée française	Merguellil, Tunisie	Cap Bon, Tunisie
<i>Seuil en mm (min-max)</i>	38.39 - 135	29 - 70.23	40.3 - 56
<i>La moyenne de nombre de dépassements par saison des pluies (min-max)</i>	0.49 - 2.42	0.12 - 0.52	0.32 - 0.91

TABLEAU 6.1 – Récapitulatif des valeurs de seuil et du nombre de dépassements pour les trois sites d'étude.

Une comparaison est effectuée entre les résultats de l'ajustement de la GPD en utilisant le choix de seuils décrit ci-dessus et les résultats obtenus à partir de l'ajustement de la GEV présenté au Chapitre 5. Comme leurs ajustements ne reposent pas sur le même ensemble de données, ils peuvent donner des résultats différents. Cette comparaison est résumée graphiquement, dans les Figures 40 et 41, pour les trois sites d'étude. En se focalisant particulièrement sur l'estimation des paramètres de forme et le niveau de retour 100 ans, nous avons pu observer que les valeurs estimées pour ces paramètres varient dans des intervalles similaires. Les résultats obtenus pour le site de la Méditerranée française montrent une moyenne du quantile de niveau de retour 100 ans de 248.7 mm avec les estimations GEV, tandis que les estimations GPD donnent une moyenne de 275 mm. Environ 83% des cas sur le site français montrent que les estimations du niveau de retour obtenues avec la loi GPD sont supérieures à celles obtenues

6.2. Modélisation des valeurs extrêmes avec la GPD

avec la loi GEV. Des comportements similaires ont été observés pour les sites de Merguellil (69%) et de Cap Bon (72%).

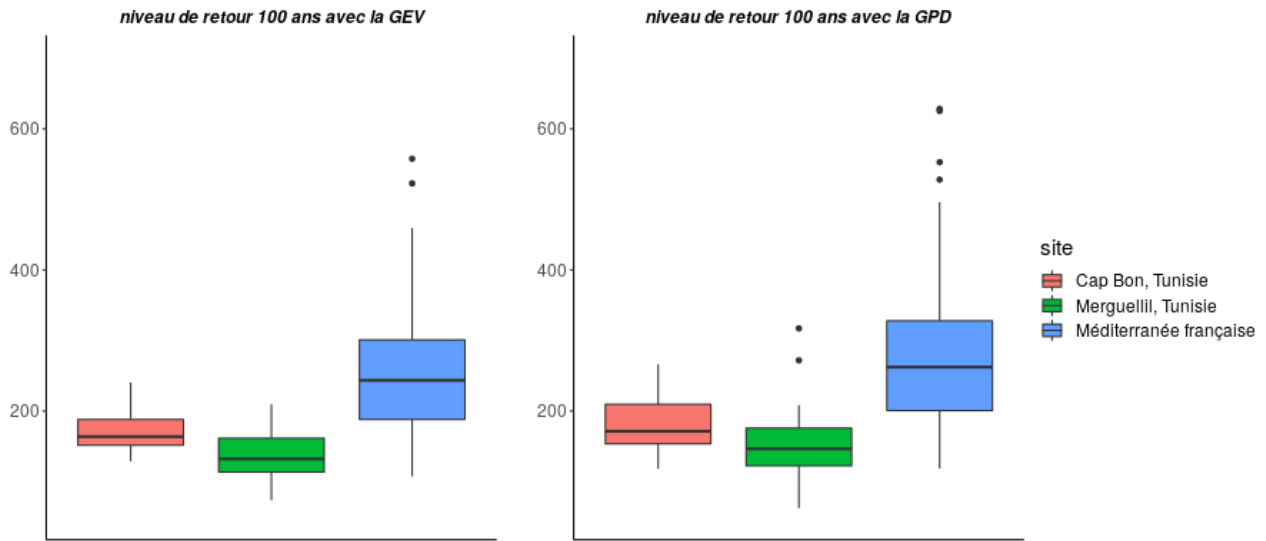


FIGURE 40 – Boxplots des estimations des niveaux de retour 100 ans avec la GEV et la GPD pour les trois sites d'étude.

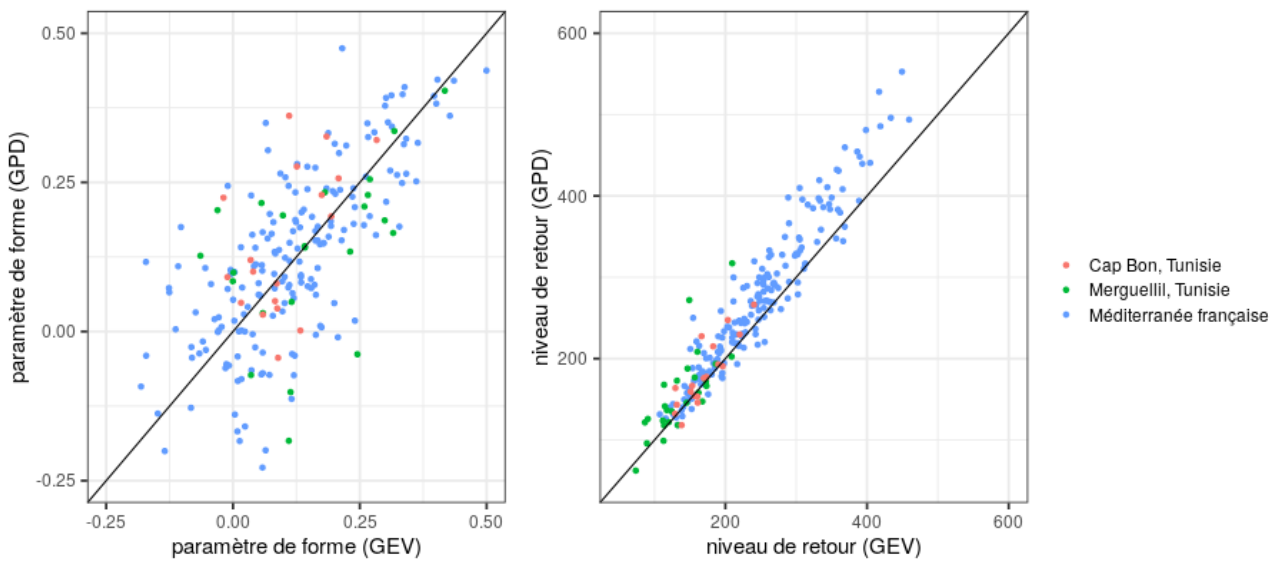


FIGURE 41 – Comparaison des estimations des paramètres de forme et les calculs des niveaux de retour 100 ans avec la GEV et la GPD pour les trois sites d'étude.

6.3 Application de l'EGPD sur les données de précipitations

6.3.1 Cas de la région de la Méditerranée Française

Afin d'échantillonner les séries de précipitations positives, il est courant de fixer un seuil de $1mm$ ou $2mm$ (e.g (Tencaliec et al., 2020)) ce qui permet de modéliser les données qui dépassent ce seuil. La censure des données peut avoir un impact significatif sur l'amélioration de l'ajustement de l'EGPD. Afin de démontrer cette affirmation, plusieurs tests ont été effectués en éliminant les valeurs inférieures aux seuils de précipitations négligeables. Lors de la comparaison des ajustements de l'EGPD en excluant les valeurs inférieures à différents seuils ($1mm$, $2mm$, $5mm$), il a été observé que la censure à $5mm$ donnait le critère NSE le plus proche de 1, ce qui correspondait à la meilleure estimation (voir Figure 42).




FIGURE 42 – Boxplot des valeurs de critères de Nash-Sutcliffe, en variant le seuil de censure pour l'ajustement EGPD (1mm, 2mm, 5mm), pour les stations sur le site de la Méditerranée Française.

Il est également important de comparer les quantiles générés par ces modèles, car ils fournissent une indication directe sur les valeurs extrêmes estimées. La Figure 43 présente la localisation des stations de test sélectionnées sur la région française. Les graphiques quantiles-quantiles présentés à la Figure 44 offrent une comparaison visuelle entre les valeurs observées et les valeurs estimées par les modèles, permettant ainsi d'évaluer leur adéquation.

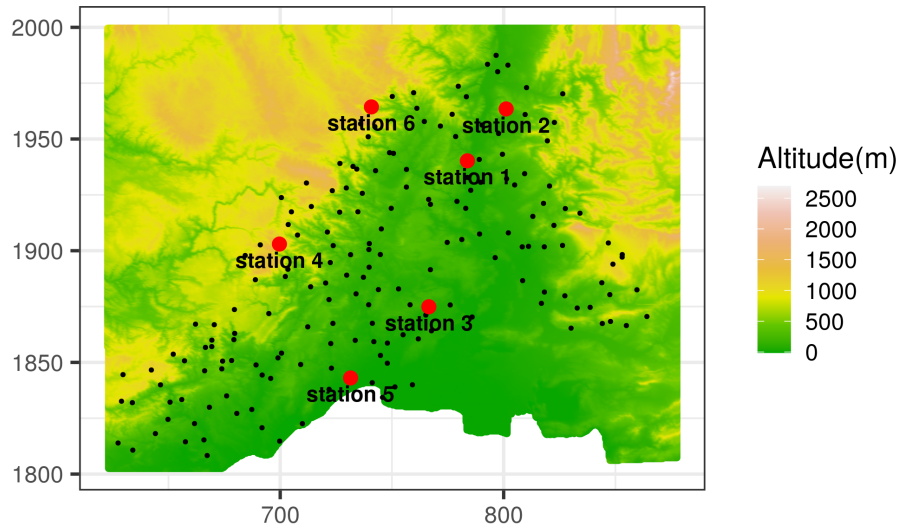


FIGURE 43 – Localisation des stations de tests (les points en rouge) sur le site de de la Méditerranée Française.

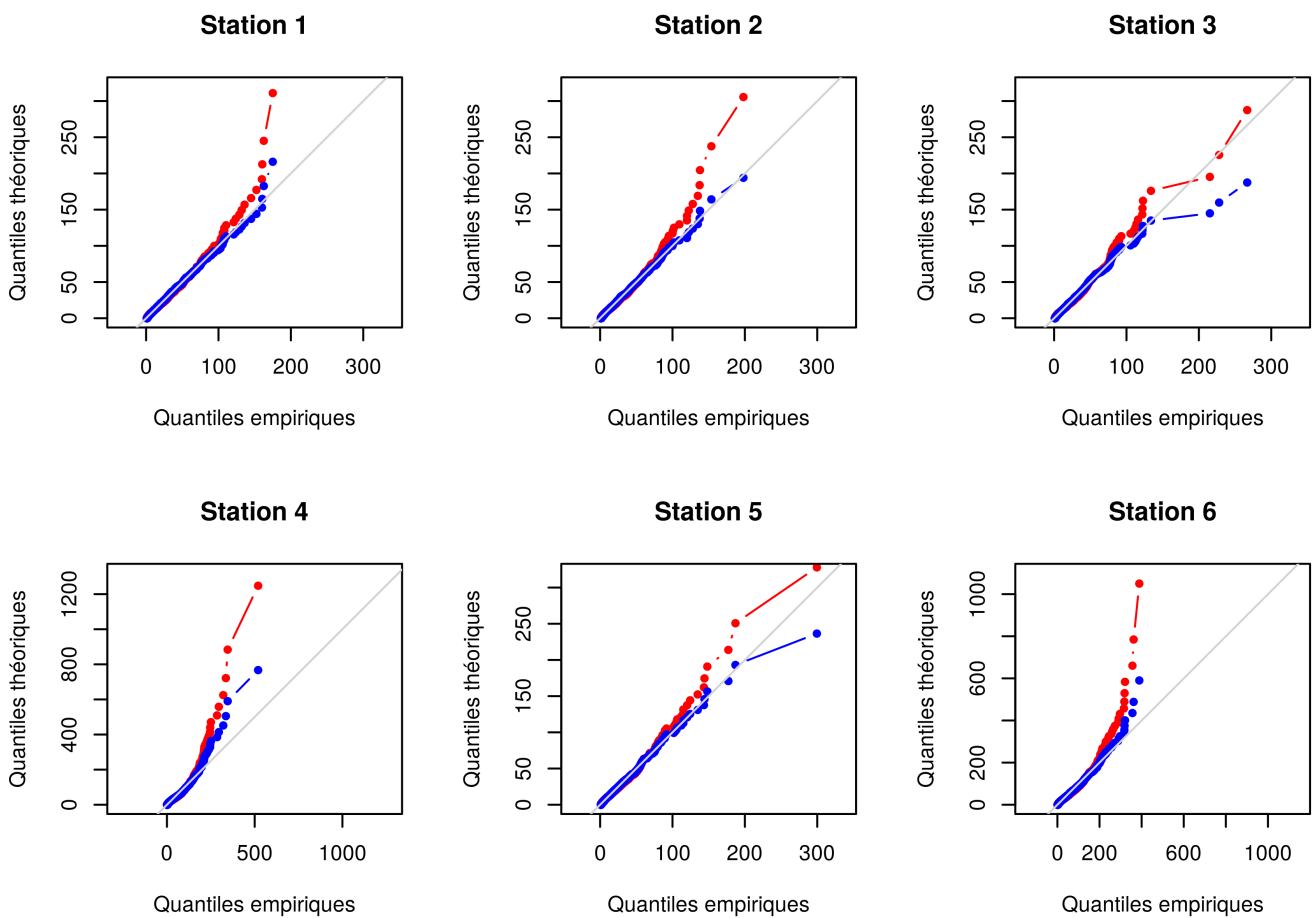


FIGURE 44 – Graphiques quantiles-quantiles sur les 6 stations de tests. Les points rouges correspondent aux modèles EGPD avec un seuil de 1mm, tandis que les points bleus représentent les modèles avec une censure de 5mm.

De manière générale, les résultats obtenus avec une censure à $5mm$ sont meilleurs que ceux obtenus avec une censure à $1mm$. En comparant les résultats du modèle EGPD avec ceux du modèle Gamma, la Figure 45 met en évidence les stations pour lesquelles chaque modèle offre le meilleur ajustement en termes de critère NSE. Cette analyse permet de déterminer quel modèle est le plus adapté pour représenter au mieux les observations de précipitations dans chaque station. Sur des données censurées à $1mm$ (Figure à gauche), seulement 38.7% des stations sont mieux ajustées avec l'EGPD, par contre en augmentant le seuil de censure (Figure à droite), on a atteint 78.68% des stations. Toutefois, certaines stations situées dans la région nord-ouest sont encore mieux modélisées avec la distribution Gamma. Une explication possible est l'existence de la variation dans les caractéristiques des pluies. Par exemple, la Figure 46 présente le nombre moyen d'observations supérieures à $5mm$ par saison des pluies, révélant ainsi que la région en question présente les valeurs les plus élevées. Cette différence peut être attribuée à plusieurs facteurs tels que la variabilité géographique et les conditions climatiques locales. Ces facteurs peuvent donner lieu à des régimes de précipitations différents, ce qui nécessite l'utilisation de modèles spécifiques pour chaque station.

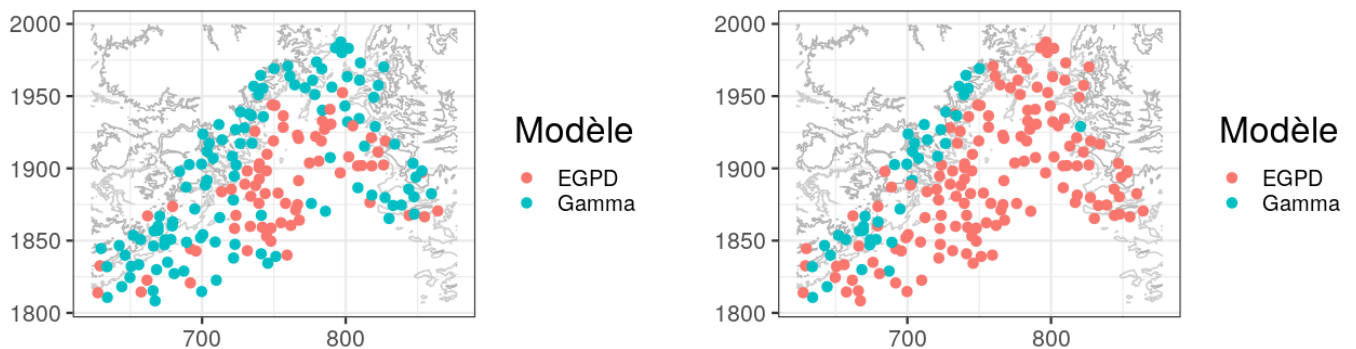


FIGURE 45 – Comparaison des valeurs du critère NSE les plus proches de 1 pour les modèles EGPD et Gamma, en utilisant une censure des données à $1mm$ à gauche et une censure à $5mm$ à droite.

Pour ces raisons, nous avons envisagé d'ajuster le seuil de censure individuellement pour chaque station plutôt que d'utiliser un seul seuil pour l'ensemble de la région. En effet, chaque station peut avoir ses propres caractéristiques climatiques et un nombre spécifique d'observations disponibles, qui influencent la distribution des précipitations et nécessitent une approche particulière. En ajustant le seuil de censure de manière adaptée à chaque station, on peut mieux capturer les extrêmes et améliorer la précision des modèles statistiques utilisés pour estimer les niveaux de retour.




FIGURE 46 – Nombre moyen d’observations ($>5\text{mm}$) par saison des pluies et par station, pour le site de la Méditerranée Française.

Différents seuils de censure ont été évalués, allant de 1mm à 10mm , afin de trouver celui qui correspond le mieux aux critères NSE se rapprochant le plus de 1 pour chaque station de test. Les résultats de cette sélection sont présentés dans la Figure 47, où les graphiques quantiles-quantiles sont ajustés en utilisant le modèle EGPD avec un seuil spécifique pour chaque station. Les seuils choisis correspondent respectivement aux valeurs de 7mm , 5mm , 2mm , 10mm , 3mm et 10mm pour les stations 1 à 6. Cette approche permet d’obtenir une représentation plus précise des valeurs extrêmes de précipitations pour chaque station, en prenant en compte leurs caractéristiques individuelles et en optimisant l’adéquation des modèles aux données observées. Le même processus a été appliqué sur toutes les stations de la région. En faisant varier le seuil de censure, nous avons constaté que l’EGPD permettait un meilleur ajustement que la distribution Gamma pour 96.7% des stations.

Le résultat de l’estimation du niveau de retour 100 ans pour chaque station est présenté dans la Figure 48. Cette estimation, qui représente la quantité de précipitations attendue en moyenne tous les 100 ans pour chaque station, varie de 152.2mm à 595.4mm . La variation spatiale des niveaux de retour avec l’EGPD est similaire à celle que nous avons obtenue précédemment avec la GEV. Dans les deux cas, les valeurs élevées se trouvent principalement au nord-ouest de la région.

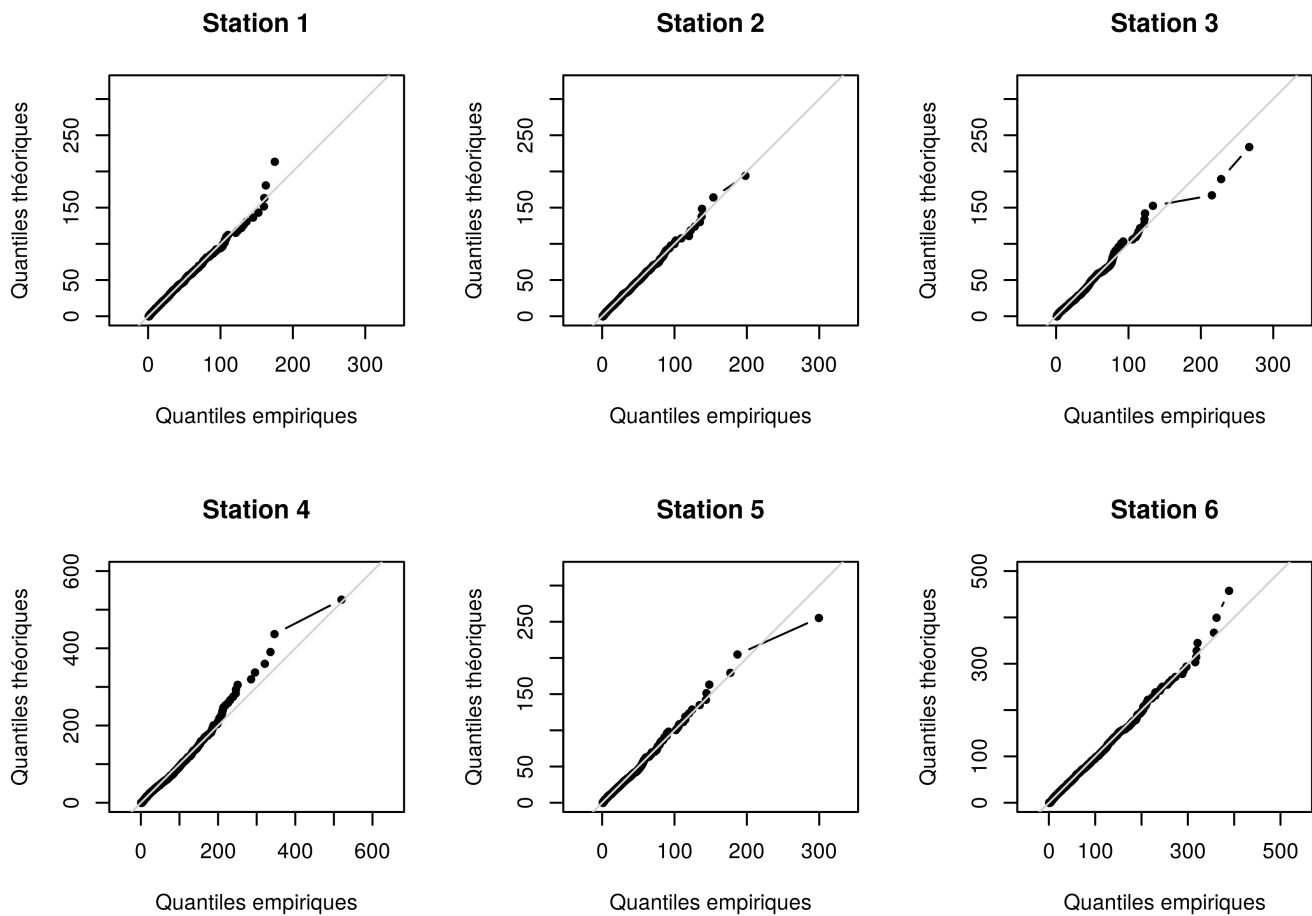


FIGURE 47 – Graphiques quantiles-quantiles sur les 6 stations de tests, après la sélection des seuils de censure de l'EGPD établis selon le critère NSE. Les seuils correspondants pour chaque station, de 1 à 6, sont respectivement de 7, 5, 2, 10, 3 et 10 mm.




FIGURE 48 – Le niveau de retour 100 ans avec l'ajustement de l'EGPD, sur le site de la Méditerranée Française.

6.3.2 Cas du Merguellil, Tunisie

La région du Merguellil en Tunisie a fait l'objet de la même analyse afin d'évaluer les performances du modèle EGPD. L'objectif était de déterminer quel modèle est le plus adapté pour représenter de manière optimale les observations de précipitations dans chaque station. Contrairement à la région française, on constate que toutes les stations montrent une meilleure adaptation avec le modèle EGPD par rapport à la distribution Gamma, que ce soit avec un seuil de censure de 1 mm ou de 5 mm.

Dans cette région, deux stations de test (repérées sur la Figure 49) ont démontré une meilleure adaptation avec des seuils de censure de $4mm$ et $2mm$ (voir Figure 50), correspondant le mieux aux critères NSE se rapprochant le plus de 1. Il est intéressant de noter que les seuils de censure dans l'ensemble des stations de la région sont généralement plus faibles que ceux obtenus dans la région française. Cela peut s'expliquer par des différences dans les caractéristiques des précipitations entre les deux régions, telles que l'intensité moyenne des précipitations.

En adaptant de manière appropriée le seuil de censure pour chaque station, il devient possible d'améliorer la précision des modèles statistiques employés pour estimer les niveaux de retour. Le résultat de l'estimation du niveau de retour 100 ans pour chaque station est présenté dans la Figure 51. Cette estimation ponctuelle varie entre $62.61mm$ et $233.37mm$.

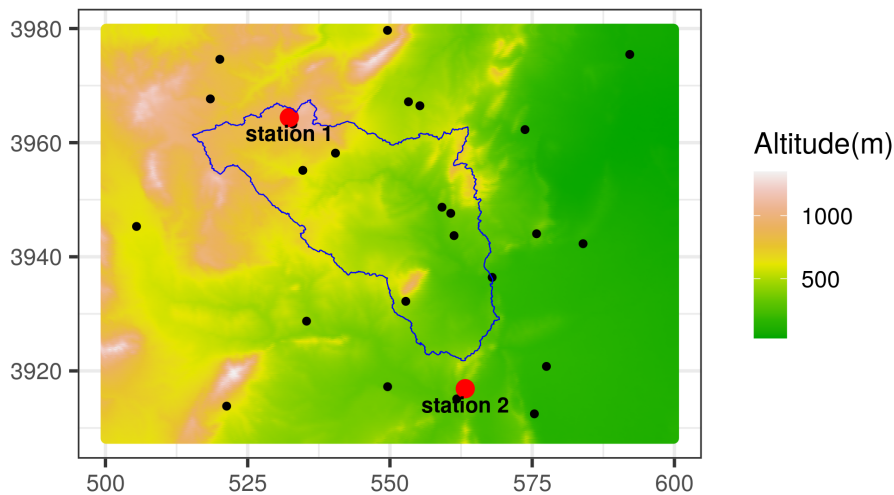


FIGURE 49 – Localisation des stations de tests (les points en rouge) sur le site du Merguellil, Tunisie.

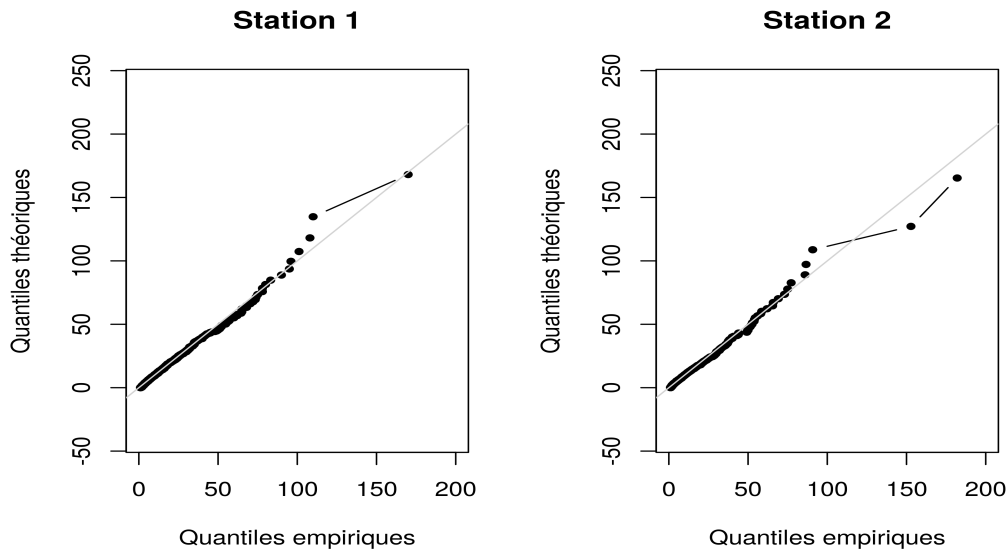


FIGURE 50 – Graphiques quantiles-quantiles pour 2 stations de tests, après la sélection du seuil de censure de l'EGPD établi selon le critère NSE. La valeur de seuil pour la station 1 est de 4 mm, tandis que pour la station 2, elle est de 2 mm.




FIGURE 51 – Le niveau de retour 100 ans avec l'ajustement de l'EGPD, au Merguellil, Tunisie.

6.3.3 Cas du Cap Bon, Tunisie

Une analyse similaire a été réalisée dans la région du Cap Bon en Tunisie. De manière analogue à ce qui a été observé dans le cas du Merguellil et contrairement à la région française, il est noté que toutes les stations présentent une meilleure adaptation avec le modèle EGPD par rapport à la distribution Gamma, que ce soit avec un seuil de censure de 1 mm ou de 5 mm. Cette observation souligne une cohérence dans les résultats entre différentes régions géographiques.

6.3. Application de l'EGPD sur les données de précipitations

Dans cette région, deux stations de test (repérées sur la Figure 52) ont démontré une meilleure adaptation avec des seuils de censure de $2mm$ et $6mm$ (voir Figure 53), correspondant le mieux aux critères NSE se rapprochant le plus de 1. Cette observation souligne l'importance de la considération des seuils de censure dans l'ajustement des modèles aux données de cette région particulière. Le résultat de l'estimation du niveau de retour 100 ans pour chaque station est présenté dans la Figure 51. Cette estimation ponctuelle varie entre $62.61mm$ et $233.37mm$.

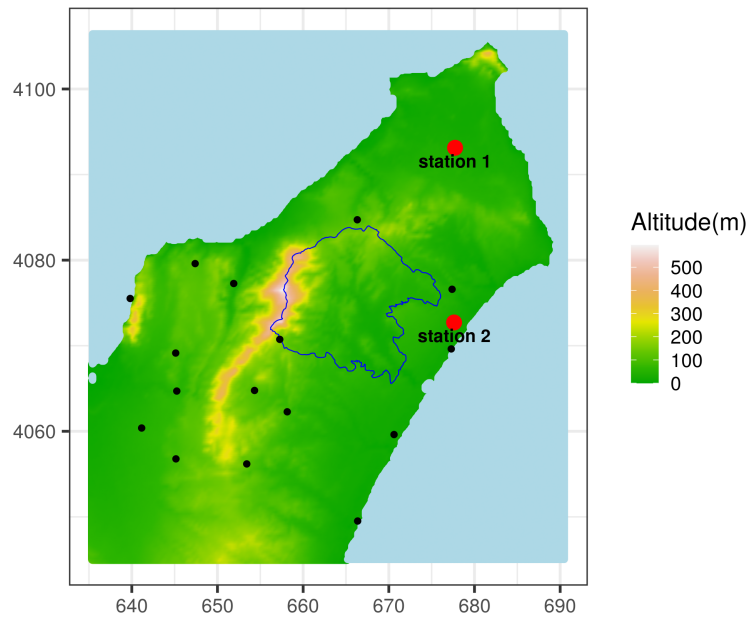


FIGURE 52 – Localisation des stations de tests (les points en rouge) sur le site du Cap Bon, Tunisie.

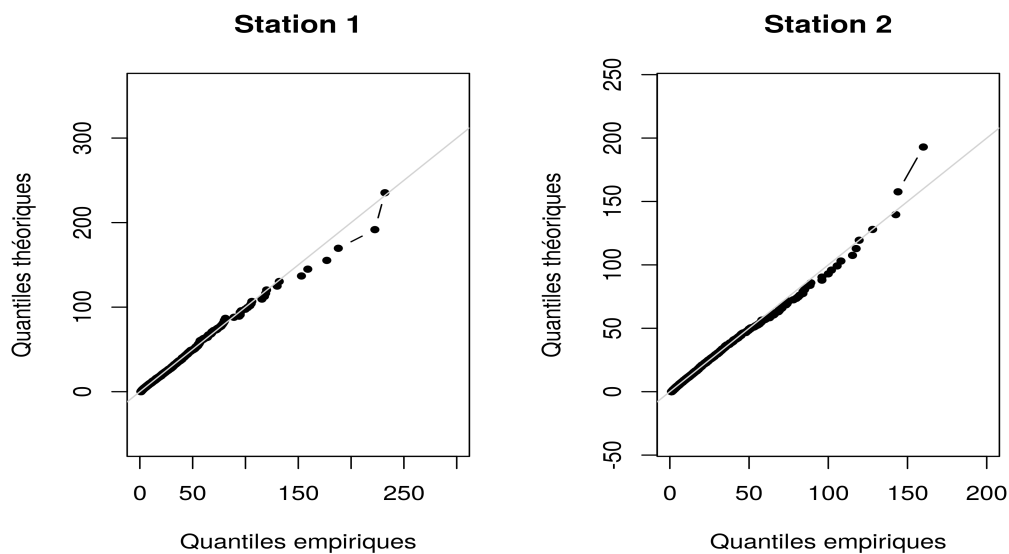


FIGURE 53 – Graphiques quantiles-quantiles sur 2 stations de tests, après la sélection du seuil de censure de l'EGPD établis selon le critère NSE. La valeur de seuil pour la station 1 est de $2mm$, tandis que pour la station 2, elle est de $6mm$.




FIGURE 54 – Le niveau de retour 100 ans avec l’ajustement de l’EGPD, sur le Cap Bon, Tunisie.

6.3.4 Inter-comparaison entre les trois sites d’étude

Suite à l’analyse individuelle de chaque site d’étude, notre objectif est d’effectuer une inter-comparaison afin d’évaluer et de mettre en lumière les similitudes ou les différences significatives dans les résultats obtenus. Cette démarche permettra de synthétiser les données issues de chaque site, offrant ainsi une vision comparative globale du paramètre étudié. Les cartes d’estimation ponctuelle du niveau de retour 100 ans pour chaque site sont présentées dans la figure 55. La moyenne des niveaux de retour 100 ans est plus élevée dans la région française par rapport aux deux autres sites tunisiens. Cette observation pourrait s’expliquer par le fait que la région française connaît potentiellement des précipitations plus intenses et plus fréquentes, contribuant ainsi à des événements hydrologiques extrêmes et à des niveaux de retour plus élevés. Les estimations pour chaque station et site d’étude ont été représentées dans une seule figure, avec les estimations de l’EGPD sur l’axe des abscisses et les estimations de la GEV sur l’axe des ordonnées. Si les deux estimations étaient identiques, elles se situeraient sur la première bissectrice. Dans le cas de la Méditerranée française, la plupart des points sont proches de cette ligne, suggérant que les estimations obtenues par la GEV et l’EGPD sont similaires pour la plupart des stations dans cette région. Cela indique une bonne concordance entre les deux méthodes. Cependant, pour les sites tunisiens, en particulier pour la station Lebna, certaines estimations s’écartent notablement de la diagonale. Cela suggère que, pour ces stations spécifiques en Tunisie, les résultats obtenus par la GEV et l’EGPD présentent des différences significatives. Une explication possible de cette discordance est le pourcentage élevé de valeurs manquantes dans les bases de données, que ce soit pour les valeurs extrêmes ou ordinaires. Ce manque de données peut influencer significativement les résultats des méthodes d’estimation, expliquant ainsi les écarts observés entre les deux approches.

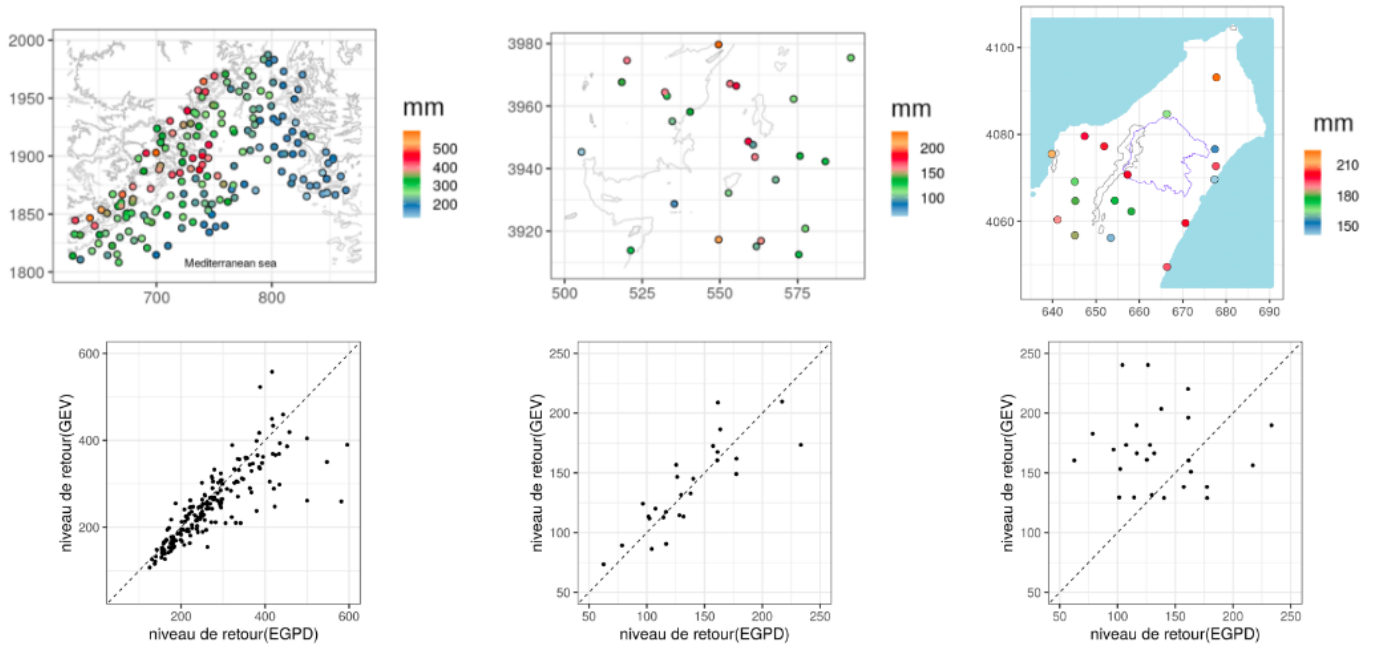


FIGURE 55 – Cartes des estimations ponctuelles du niveau de retour 100 ans avec ajustement de l’EGPD censurée pour trois sites d’étude (Méditerranée Française, Merguellil, Cap Bon) et comparaison avec les résultats de la GEV.

6.4 Synthèse

L’objectif de ce chapitre consiste à élaborer une modélisation rigoureuse, englobant à la fois la partie centrale et la queue de la distribution des précipitations positives (en excluant les événements secs). Comme annoncé dans l’introduction de la thèse et explicité davantage dans ce chapitre, l’utilisation de la distribution EGPD proposée par (Naveau et al., 2016) s’avère appropriée pour modéliser l’ensemble des précipitations non nulles. Cette distribution se démarque par sa capacité à exploiter pratiquement toute l’information présente dans les observations de précipitations positives (à l’exception des valeurs en dessous du seuil de censure). Ainsi, elle évite les approches peu efficaces consistant à utiliser une seule valeur par bloc ou à prendre en compte uniquement les valeurs dépassant un seuil spécifique.

Lors de l’application de ce modèle aux données observées de précipitations réelles, il est devenu évident qu’une étape de calibration était nécessaire pour améliorer l’ajustement du modèle. En effet, les valeurs observées dans les différentes stations de mesure présentent des variations significatives en termes de nombre d’observations disponibles. Ces différences peuvent impacter la performance du modèle et introduire des biais dans les résultats obtenus. Par conséquent, une calibration appropriée a été entreprise dans le but de tenir compte de ces disparités et d’assurer une meilleure adéquation entre les observations réelles et les prédictions générées par le modèle.

Conclusions et perspectives

Cette thèse fait partie de l'étude des risques hydrométéorologiques dans la région du pourtour méditerranéen. Les phénomènes de pluies intenses et d'inondations associées nous incitent à prendre des mesures préventives pour faire face à ces épisodes souvent catastrophiques. Afin de fournir des outils pratiques pour la gestion des risques d'inondation, l'évaluation des distributions statistiques des précipitations extrêmes est depuis longtemps un sujet de recherche actif. La description précise du phénomène physique à l'origine des précipitations représente une tâche complexe, particulièrement en raison des fréquentes lacunes associées au manque d'observations. Au lieu d'utiliser les modèles basés sur des équations décrivant des processus physiques complexes et peu connus, on a choisi d'aborder la problématique d'un point de vue statistique, en s'appuyant sur la TVE. En effet, le risque d'événements extrêmes est souvent quantifié en hydrologie à l'aide des niveaux de retour. Ces niveaux sont déterminés à partir des données historiques et représentent le niveau qui devrait être dépassé, en moyenne, une fois au cours d'une période spécifique. Plus le niveau de retour est élevé, plus l'événement est rare et plus le risque qui lui est associé est important. Parmi toutes les valeurs observées, les événements extrêmes sont identifiés à l'aide de deux approches : les maxima par bloc de saison de pluie et les dépassements au-dessus d'un seuil assez élevé. Ces deux méthodes de sélection produisent des résultats assez proches des estimations du niveau de retour, avec des valeurs propres à chaque site d'étude.

La région d'étude sélectionnée porte un intérêt particulier vu sa vulnérabilité aux événements extrêmes. Le choix des trois sites d'étude, peu documentés dans la littérature, nous a permis d'avoir une compréhension plus étendue du phénomène étudié. L'analyse comparative de différentes régions, présentant un gradient d'aridité nord-sud, a permis d'identifier les similarités et les disparités entre diverses caractéristiques telles que le climat, la topographie, la densité des stations météorologiques, les données d'observations, etc. Cette analyse a permis de mieux comprendre les mécanismes sous-jacents et de disposer des éléments nécessaires à la modélisation statistique. Les mesures de précipitations dont nous disposons sont des mesures ponctuelles. Nous pouvons ainsi facilement évaluer le risque aux endroits correspondant à ces points de mesure. Cependant, estimer le risque pour les zones où nous ne disposons pas de

données de mesure pose un défi supplémentaire. Cette question soulève la mission principale de cette thèse qui consiste à réaliser une estimation spatiale du risque. Il s'agit d'une étape particulièrement importante, car elle fournit des indicateurs attendus par les décideurs pour caractériser l'exposition au risque sur un champ continu de 2D. En effet, pour estimer une variable dans des endroits où aucune mesure n'a été effectuée, les techniques d'interpolation spatiale sont largement utilisées. L'un des inconvénients de ces techniques est qu'elles impliquent souvent une transformation spatiale des estimations ponctuelles, ce qui augmente l'incertitude, en particulier dans les zones où la densité des mesures est faible. Il a été proposé d'opter plutôt pour des modèles de surface de réponse, où les estimations ponctuelles ne sont pas impliquées dans l'estimation spatiale. Dans cette optique, la non-stationnarité spatiale des précipitations a été modélisée à l'aide de variables supplémentaires (covariables). Quatre covariables principales ont été utilisées : les coordonnées géographiques de chaque station de mesure (longitude, latitude, altitude) et une variable de la base de données CHIRPS.

Deux approches de modélisation spatiale non-stationnaire, permettant d'avoir des cartes de niveau de retour, ont été utilisées : les réseaux de neurones artificiels (ANN) et les modèles linéaires généralisés (GLM). L'un des points forts des ANN réside dans leur capacité à modéliser des relations complexes entre différentes variables climatiques, ce qui peut être crucial pour comprendre les mécanismes sous-jacents aux événements de précipitations extrêmes. Cependant, l'utilisation des ANN nécessite une quantité significative de données d'entraînement pour généraliser correctement, ce qui peut être un défi dans le cas de phénomènes climatiques extrêmes qui sont, par nature, rares. De plus, les limitations incluent également la sensibilité aux hyperparamètres, ce qui signifie que le processus de réglage des paramètres du réseau peut être délicat et demande une expertise approfondie. Il est nécessaire de définir un niveau de complexité adéquat (nombre d'unités cachées) pour avoir un ajustement optimal en évitant le comportement de sur-ajustement ou le sous-ajustement. En fin de compte, malgré ces défis, l'utilisation d'ANN dans l'estimation des paramètres de distribution des événements de précipitations extrêmes peut offrir des résultats prometteurs en tirant parti de leur capacité à gérer la complexité inhérente aux données climatiques.

D'autre part, la principale force des GLM réside dans leur simplicité et leur interprétabilité, offrant une compréhension claire des relations linéaires entre les variables. Cette caractéristique les rend particulièrement adaptés lorsque la transparence du modèle est essentielle, et ils sont souvent plus efficaces en termes de temps de calcul comparés à des modèles plus complexes, comme le ANN. Toutefois, les GLM présentent également des limitations. Leur capacité restreinte à modéliser des relations non linéaires constitue l'un de leurs principaux points faibles. De plus, les performances des GLM dépendent fortement de la qualité des caractéristiques fournies en entrée, et ils peuvent ne pas être suffisamment flexibles pour capturer la variabilité dans des données hautement complexes. En fin de compte, le choix d'utiliser un GLM dépendra des spécificités de la tâche à accomplir, avec une balance nécessaire entre la simplicité du modèle et sa capacité à capturer la complexité inhérente des données.

Couramment, le paramètre de forme de la GEV ou la GPD, qui décrit le comportement des extrêmes, est supposé constant lors de son estimation sur une région d'étude. Cette hypothèse, formulée dans la plupart des articles traitant des précipitations extrêmes, a été remise en question. En variant ce paramètre, on a observé une variabilité spatiale des estimations sur les trois sites d'étude. Les résultats de la modélisation spatiale sont favorables au modèle ANN, qui donne de meilleurs résultats sur plus de 60% des stations que le GLM pour les trois sites étudiés. Cependant, pour optimiser davantage ces résultats, une approche consistant à intégrer des covariables climatiques supplémentaires pourrait être explorée. En effet, une autre extension évidente de ce travail consiste à permettre une variation temporelle des paramètres des distributions en incluant des covariables temporelles. En plus, d'autres covariables spatiales supplémentaires pourraient être incluses à part celles qu'on a proposées, par exemple des covariables de température, de vent ou d'évapotranspiration, etc. Notamment les covariables issues de données satellitaires ou de réanalyses, par exemple le jeu de données de la réanalyse GloFAS v4.0¹ (Grimaldi et al., 2022) qui est une nouvelle génération de la réanalyse ERA5. On peut aussi prendre en compte la non-stationnarité temporelle des données en regroupant les pas de temps en sous-groupes pour lesquels l'hypothèse de stationnarité est satisfaite. Cette approche consiste à classer les jours de pluie en types de temps (les jours secs, avec pluies légères ou intenses) (Thompson et al., 2007). Dans ce cas, on doit utiliser différents modèles pour chaque type de temps, ce qui permettra de mieux capturer les variations temporelles des événements extrêmes.

De plus, notre étude s'est focalisée sur l'analyse des événements de précipitations se produisant à une échelle temporelle journalière. Cependant, il est important de noter que les conséquences des pluies torrentielles peuvent être fortement influencées par les intensités relevées à des pas de temps plus fins, tels que l'heure ou la minute. Dans cette étude, nous avons choisi d'utiliser des enregistrements pluviométriques journaliers, en raison de leur disponibilité dans les bases de données climatiques. En effet, les données journalières sont généralement plus facilement accessibles et couvrent une période plus longue que les observations infra-journalières trop récentes. Comme les estimations hydrologiques nécessitent souvent de longues séries à haute résolution temporelle, il est possible de désagréger les valeurs journalières en valeurs infra-journalières. Par exemple, avec des modèles de ré-échantillonnage non-paramétriques basés sur des méthodes de fragments (également appelées méthode analogique) (Breinl and Di Baldassarre, 2019).

Par ailleurs, les performances des réseaux de neurones ont fortement progressé ces dernières années, et continuent de progresser grâce à de nouvelles architectures plus performantes. Ces avancées ont été rendues possibles grâce aux progrès réalisés dans les domaines de l'apprentissage automatique et de l'intelligence artificielle. La littérature a déjà exploré différentes stratégies pour améliorer les performances des réseaux de neurones, en particulier en modifiant leur architecture. Ceci nous permettra d'améliorer la vitesse d'apprentissage et d'augmenter la

1. <https://confluence.ecmwf.int/display/CEMS/GloFAS+v4.0+hydrological+reanalysis>

capacité de généralisation du réseau. Ces stratégies comprennent l'ajout de nouvelles couches de neurones pour augmenter la profondeur du réseau et l'utilisation de nouvelles fonctions d'activation pour mieux modéliser la non-linéarité des données (Goodfellow et al., 2016). Il serait donc intéressant d'appliquer ces éléments à la gestion des ressources en eau.

La deuxième mission de cette thèse est de pouvoir modéliser à la fois la partie centrale et la queue de la distribution des précipitations positives (les événements secs sont éliminés). Dans ce cas, le modèle EGPD a été appliqué pour les trois sites d'études. Les résultats de l'estimation ponctuelle montrent que la censure des données inférieures à un certain seuil de pluies négligeables donne les meilleurs résultats d'estimation des paramètres de l'EGPD, ainsi que le niveau de retour 100 ans. Il est possible de développer davantage cette modélisation dans un cadre spatial non-stationnaire. On peut supposer que les paramètres de la distribution de $Y|x \sim EGPD(k(x), \sigma(x), \xi(x))$ est une fonction de covariables $X = (x_1, x_2, \dots, x_i)$. On suppose qu'il y a une relation non-linéaire flexible avec les covariables X , qui peut être expliquée par le modèle ANN. Dans ce cas, le modèle ANN aura comme entrée les covariables et en sortie les paramètres de la distribution. Un travail connexe a été réalisé par Carrer and Gaetan (2022), dans lequel les auteurs ont développé une approche basée sur l'EGPD pour modéliser des champs non-stationnaires avec un modèle additif généralisé.

L'objectif global de cette recherche est de fournir des pistes qui pourront ensuite être utilisées dans le développement d'un générateur stochastique spatial de précipitations. Le développement de ce type de générateur représente un défi considérable, étant donné qu'il implique la combinaison de plusieurs modèles de base pour créer des modèles complexes. Dans ce cas, on est confronté à trois problématiques principales : la prise en compte de la non-stationnarité spatio-temporelle, être capable de reproduire de manière réaliste les différents aspects de la distribution de la pluie, et la représentation d'une structure de dépendance. Dans le cas de notre étude, pour élaborer un générateur stochastique, il faut prendre en compte aussi de la non-stationnarité temporelle, ainsi que l'ajout d'une structure de dépendance. Les précipitations peuvent être corrélées dans le temps, dans l'espace ou encore entre différents sites et variables. Pour incorporer la dépendance dans les générateurs stochastiques de précipitations, différentes approches sont envisageables, notamment l'utilisation de modèles de Markov, comme suggéré par (Thompson et al., 2007). Il existe d'autres approches qui impliquent la combinaison de distributions gaussiennes censurées avec des transformations de puissance (Ailliot et al., 2009). Les progrès récents dans le domaine de modélisation de la dépendance se sont surtout focalisés sur la dépendance non-linéaire, telles que les corrélations de rang, avec des distributions marginales flexibles (Hao and Singh, 2016). Ainsi, le générateur stochastique doit donc être capable de reproduire ces corrélations de manière précise afin de générer des séries de précipitations réalistes.

En guise de perspectives, une attention particulière peut être accordée à l'élaboration des courbes Intensité-Durée-Fréquence (IDF). Il s'agit d'une description de l'intensité des précipitations en fonction de la durée et de la période de retour. Ces courbes jouent un rôle crucial

dans l'évaluation et la gestion des risques associés aux précipitations extrêmes. Ainsi, de nombreux développements ont été réalisés dans la littérature. Par exemple, dans (Mélèse et al., 2018), une analyse régionale a été réalisée pour évaluer les incertitudes dans les courbes IDF dérivées des maxima de précipitations ponctuelles sur le site d'étude français. De plus, dans une autre étude récente menée par (Haruna et al., 2022b), l'approche EGPD a été appliquée pour modéliser les courbes IDF des précipitations non nulles en Suisse. Ces travaux illustrent l'importance de l'estimation des incertitudes dans les courbes IDF, ainsi que l'application de différentes méthodes statistiques pour y parvenir.

Annexe

Estimations des paramètres de distribution

Dans la littérature, il existe plusieurs méthodes d'estimation des paramètres des lois GEV ou GPD. On peut citer par exemple la méthode de maximum de vraisemblance (Hosking and Wallis, 1987; Davison and Smith, 1990; Wilks, 1999), la méthode des moments de probabilité pondérés (Greenwood et al., 1979) ou la méthode des moments (Christopeit, 1994). L'idée de base de l'estimation par maximum de vraisemblance est de choisir les valeurs des paramètres qui maximisent la probabilité attribuée aux données observées. En d'autres termes, cela consiste à trouver les paramètres qui rendent les données observées les plus "probables". La méthode de moments, quant à elle, repose sur la possibilité de calculer les moments d'une distribution théorique, ainsi que les moments empiriques correspondants qui sont estimés à partir des données observées. En utilisant ces moments, on peut établir des égalités entre les moments théoriques et empiriques, qui permettent de résoudre ces équations pour estimer les paramètres du modèle.

Estimation des paramètres de la GEV avec maximum de vraisemblance

Soit un échantillon $y = \{y_1, \dots, y_n\}$ de taille n issu d'une distribution GEV de paramètres $\theta = (\mu, \sigma, \xi)$. La fonction de densité de l'équation (3.6) est donné pour $\xi \neq 0$ par :

$$g(y_i; \theta) = \frac{1}{\sigma} \left(1 + \xi \left(\frac{y_i - \mu}{\sigma} \right) \right)^{-\frac{1}{\xi} - 1} \exp \left\{ - \left[1 + \xi \left(\frac{y_i - \mu}{\sigma} \right) \right]^{-\frac{1}{\xi}} \right\} \quad (7.1)$$

La méthode d'estimation par maximum de vraisemblance est décrite ci-dessous. Il s'agit en effet de formuler la fonction de vraisemblance comme suit :

$$\mathcal{L}(\theta; y) = \prod_{i=1}^n g(y_i; \theta). \quad (7.2)$$

Pour restreindre le paramètre de forme ξ à l'intervalle $-0.5 < \xi < 0.5$, on a supposé que $\xi = \frac{2}{k} - 0.5, \forall k > 2$. Alors l'expression de la log-vraisemblance négative pour la GEV avec $\theta = (\mu, \sigma, k)$ est présentée sous la forme :

$$l(\theta; y) = - \sum_{i=1}^n \log(g(y_i; \theta)) \quad (7.3)$$

$$l(\theta; y) = \log \sigma + \left(\frac{2 + 0.5k}{2 - 0.5k} \right) \sum_{i=1}^n \log \left[1 + \frac{(2 - 0.5k)(y_i - \mu)}{k\sigma} \right] + \sum_{i=1}^n \left[1 + \frac{(2 - 0.5k)(y_i - \mu)}{k\sigma} \right]^{-\left(\frac{k}{2-0.5k}\right)} \quad (7.4)$$

Les estimations du maximum de vraisemblance de $\theta = (\mu, \sigma, k)$ qui maximisent $l(\theta; y)$, données par l'expression 7.4, doivent satisfaire les équations :

$$\frac{\partial l}{\partial \mu} = \sum_{i=1}^n \frac{-(2 + 0.5k)}{k\sigma + (2 - 0.5k)(y_i - \mu)} + \frac{1}{\sigma} \sum_{i=1}^n \left(1 + \frac{(2 - 0.5k)(y_i - \mu)}{k\sigma} \right)^{-\left(\frac{2+0.5k}{2-0.5k}\right)} \quad (7.5)$$

$$\frac{\partial l}{\partial \sigma} = \frac{1}{\sigma} - \frac{2 + 0.5k}{\sigma} \sum_{i=1}^n \frac{y_i - \mu}{k\sigma + (2 - 0.5k)(y_i - \mu)} + \frac{1}{\sigma^2} \sum_{i=1}^n (y_i - \mu) \left(1 + \frac{(2 - 0.5k)(y_i - \mu)}{k\sigma} \right)^{-\left(\frac{2+0.5k}{2-0.5k}\right)} \quad (7.6)$$

$$\begin{aligned} \frac{\partial l}{\partial k} = & \frac{2}{(2 - 0.5k)^2} \sum_{i=1}^n \log \left(1 + \frac{(2 - 0.5k)(y_i - \mu)}{k\sigma} \right) - \frac{2(2 + 0.5k)(y_i - \mu)}{k(2 - 0.5k)(k\sigma + (2 - 0.5k)(y_i - \mu))} \\ & + \sum_{i=1}^n \left[\left(1 + \frac{(2 - 0.5k)(y_i - \mu)}{k\sigma} \right)^{-\left(\frac{k}{2-0.5k}\right)} \right] \left[\frac{-2}{(2 - 0.5k)^2} \log \left(1 + \frac{(2 - 0.5k)(y_i - \mu)}{k\sigma} \right) \right. \\ & \left. + \frac{2(y_i - \mu)}{(2 - 0.5k)(k\sigma + (2 - 0.5k)(y_i - \mu))} \right] \quad (7.7) \end{aligned}$$

On suppose que :

$$\begin{cases} \alpha &= 2 + 0.5k \\ \beta &= 2 - 0.5k \\ \eta &= y_i - \mu \end{cases}$$

$$\frac{\partial l}{\partial \mu} = \sum_{i=1}^n \frac{-\alpha}{k\sigma + \beta\eta} + \frac{1}{\sigma} \sum_{i=1}^n \left(1 + \frac{\beta\eta}{k\sigma} \right)^{-\left(\frac{\alpha}{\beta}\right)} \quad (7.8)$$

$$\frac{\partial l}{\partial \sigma} = \frac{1}{\sigma} - \frac{\alpha}{\sigma} \sum_{i=1}^n \frac{\eta}{k\sigma + \beta\eta} + \frac{1}{\sigma^2} \sum_{i=1}^n \eta \left(1 + \frac{\beta\eta}{k\sigma} \right)^{-\left(\frac{\alpha}{\beta}\right)} \quad (7.9)$$

$$\frac{\partial l}{\partial k} = \frac{2}{\beta^2} \sum_{i=1}^n \log \left(1 + \frac{\beta\eta}{k\sigma} \right) - \frac{2\alpha\eta}{k\beta(k\sigma + \beta\eta)} + \sum_{i=1}^n \left[\left(1 + \frac{\beta\eta}{k\sigma} \right)^{-\left(\frac{\alpha}{\beta}\right)} \right] \left[\frac{-2}{\beta^2} \log \left(1 + \frac{\beta\eta}{k\sigma} \right) + \frac{2\eta}{\beta(k\sigma + \beta\eta)} \right] \quad (7.10)$$

Estimation des paramètres de la GPD avec maximum de vraisemblance

Soit un échantillon $y = y_1, \dots, y_m$, avec m le nombre d'observations dépassant le seuil u , de la loi GPD donnée par l'expression 3.9. Sa fonction de densité est donnée pour $\theta = (\xi, \sigma_u)$ par :

$$h(y, \theta) = \frac{1}{\sigma_u} \left(1 + \xi \frac{y}{\sigma_u}\right)^{-\frac{1+\xi}{\xi}} \quad (7.11)$$

Ce qui résulte la fonction log-vraisemblance négative de la loi GPD :

$$l(\theta, y) = \log(\sigma_u) + \left(1 + \frac{1}{\xi}\right) \sum_{i=1}^m \log\left(1 + \xi \frac{y}{\sigma_u}\right) \quad (7.12)$$

avec $1 + \xi \frac{y}{\sigma_u} > 0$ pour $i = 1, \dots, m$

Posons $\eta = \frac{\xi}{\sigma_u}$. On cherche à obtenir :

$$\begin{cases} \frac{\partial l}{\partial \xi} = 0 \\ \frac{\partial l}{\partial \sigma_u} = 0 \end{cases}$$

On obtient les équations suivantes à partir de l'équation de vraisemblance :

$$\begin{cases} \hat{\xi} = \frac{1}{m} \sum_{i=1}^m \log(1 + \eta y) = \hat{\xi}(\eta) \\ \frac{1}{\eta} = \frac{1}{m} \left(1 + \frac{1}{\xi}\right) \sum_{i=1}^m \frac{y}{1 + \eta y} \end{cases}$$

Ce qui résulte que l'estimation de (ξ, η) n'est que la solution de l'équation avec $(\hat{\xi} = \hat{\xi}(\hat{\eta}), \hat{\eta})$. Pour résoudre ce problème assez complexe, on utilise couramment des méthodes d'optimisation numérique telles que l'algorithme de Newton-Raphson.

Bibliographie

- Adewoyin, R., Dueben, P., Watson, P. and He, Y., and Dutta, R. (2021). Tru-net : a deep learning approach to high resolution prediction of rainfall. *Machine Learning*, 110 :2035–2062.
- Ahmad, M., Al Mehedi, M., Yazdan, M. M. S., and Kumar, R. (2022). Development of machine learning flood model using artificial neural network (ANN) at Var River. *Liquids*, 2(3) :147–160.
- Ailliot, P., Allard, D., Monbet, V., and Naveau, P. (2015). Stochastic weather generators : an overview of weather type models. *Journal de la Société Française de Statistique*, 156(1) :101–113.
- Ailliot, P., Thompson, C., and Thomson, P. (2009). Space–time modelling of precipitation by using a hidden markov model and censored gaussian distributions. *Journal of the Royal Statistical Society Series C : Applied Statistics*, 58(3) :405–426.
- Alaoui, A., Rogger, M., Peth, S., and Blöschl, G. (2018). Does soil compaction increase floods ? A review. *Journal of Hydrology*, 557 :631–642.
- Alazard, M., Leduc, C., Travi, Y., Boulet, G., and Ben Salem, A. (2015). Estimating evaporation in semi-arid areas facing data scarcity : Example of the El Haouareb dam (Merguellil catchment, Central Tunisia). *Journal of Hydrology : Regional Studies*, 3 :265–284.
- Allam, A., El Hassan, J., Najem, W., Bocquillon, C., and Moussa, R. (2020). Classification climatique méditerranéenne pour l’hydrologie. *La Houille Blanche*, (1) :60–69.
- Andrieu, H. (2002). La mesure de pluie par radar : du calibrage par des pluviomètres vers l’interprétation physique des images. *La Houille Blanche*, 88(2) :32–36.
- Aubert, Y., Legay, T., Verdonck, J., Brunel, D., and Delichere, S. (2022). Les données spatiales au service du suivi des ressources en eau. *E3S Web of Conferences*, 346 :04008.

- Bacro, J.-N. and Chaouche, A. (2006). Incertitude d'estimation des pluies extrêmes du pourtour méditerranéen : illustration par les données de Marseille. *Hydrological Sciences Journal*, 51(3) :389–405.
- Balkema, A. and De Haan, L. (1974). Residual life time at great age. *The Annals of probability*, 2(5) :792–804.
- Bandhauer, M., Isotta, F., Lakatos, M., Lussana, C., Båserud, L., Izsák, B., Szentes, O., Tveito, O., and Frei, C. (2022). Evaluation of daily precipitation analyses in e-obs (v19. 0e) and era5 by comparison to regional high-resolution datasets in european regions. *International Journal of Climatology*, 42(2) :727–747.
- Beck, H. E., Westra, S., Tan, J., Pappenberger, F., Huffman, G. J., McVicar, T. R., Gründemann, G. J., Vergopolan, N., Fowler, H. J., Lewis, E., et al. (2020). Ppdist, global 0.1 daily and 3-hourly precipitation probability distribution climatologies for 1979–2018. *Scientific Data*, 7(1) :302.
- Beguéría, S. and Vicente-Serrano, S. (2006). Mapping the hazard of extreme rainfall by peaks over threshold extreme value analysis and spatial regression techniques. *Journal of applied meteorology and climatology*, 45(1) :108–124.
- Beirlant, J., Goegebeur, Y., Segers, J., and Teugels, J. (2004). *Statistics of extremes : theory and applications*, volume 558. John Wiley & Sons.
- Besbes, M., Chahed, J., Hamdane, A., and Marsily, G. (2014). *Sécurité hydrique de la Tunisie : gérer l'eau en conditions de pénuries*. Histoire et perspectives méditerranéennes. Editions L'Harmattan, Paris.
- Bierkens, M., Bell, V., Burek, P., Chaney, N., Condon, L. E., David, C., de Roo, A., Döll, P., Drost, N., Famiglietti, J., et al. (2015). Hyper-resolution global hydrological modelling : what is next ? “everywhere and locally relevant”. *Hydrological processes*, 29(2) :310–320.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Information science and statistics. Springer, New York.
- Blanchet, J. and Lehning, M. (2010). Mapping snow depth return levels : smooth spatial modeling versus station interpolation. *Hydrology and Earth System Sciences*, 14(12) :2527–2544.
- Blanchet, J., Molinié, G., and Touati, J. (2018). Spatial analysis of trend in extreme daily rainfall in southern france. *Climate Dynamics*, 51 :799–812.
- Blanchet, J., Paquet, E., Vaittinada Ayar, P., and Penot, D. (2019). Mapping rainfall hazard based on rain gauge data : an objective cross-validation framework for model selection. *Hydrology and Earth System Sciences*, 23(2) :829–849.

- Boudevillain, B., Argence, S., Claud, C., Ducrocq, V., Joly, B., Joly, A., Lambert, D., Nuissier, O., Plu, M., Ricard, D., Arbogast, P., Berne, A., Chaboureau, J.-P., Chapon, B., Crépin, F., Delrieu, G., Doerflinger, E., Funatsu, B., Kirstetter, P.-E., Masson, F., Maynard, K., Richard, E., Sanchez, E., and Terray, L. (2009). Cyclogenèses et précipitations intenses en région méditerranéenne : origines et caractéristiques. *La Météorologie*, 66 :18–28.
- Boulet, G., Mougenot, B., Lhomme, J.-P., Fanise, P., Lili-Chabaane, Z., Oliosio, A., Bahir, M., Rivalland, V., Jarlan, L., Merlin, O., et al. (2015). The sparse model for the prediction of water stress and evapotranspiration components from thermal infra-red data and its evaluation over irrigated and rainfed wheat. *Hydrology and Earth System Sciences*, 19(11) :4653–4672.
- Bourotte, M. (2016). *Générateur stochastique de temps multisite basé sur un champ gaussien multivarié*. PhD thesis, Université d'Avignon.
- Bracken, C., Rajagopalan, B., Cheng, L., Kleiber, W., and Gangopadhyay, S. (2016). Spatial bayesian hierarchical modeling of precipitation extremes over a large domain. *Water Resources Research*, 52(8) :6643–6655.
- Breidl, K. and Di Baldassarre, G. (2019). Space-time disaggregation of precipitation and temperature across different climates and spatial scales. *Journal of Hydrology : Regional Studies*, 21 :126–146.
- Bresson, E. (2011). *Mécanismes de formation des systèmes convectifs quasi-stationnaires en Méditerranée nord-occidentale : application au cas du 15 juin 2010 sur le Var*. PhD thesis, Université Paul Sabatier-Toulouse III.
- Brunet, P., Bouvier, C., and Gaume, E. (2012). Retour d'expérience sur les crues du gard en septembre 2002 : contrôle de la qualité des débits estimés et comparaison avec les formules synthétiques régionales. *Journées de l'hydraulique*, 34(1) :1–8.
- Brunet, P., Bouvier, C., and Neppel, L. (2018). Retour d'expérience sur les crues des 6 et 7 octobre 2014 à Montpellier-Grabels (Hérault, France) : caractéristiques hydro-météorologiques et contexte historique de l'épisode. *Physio-Géo. Géographie physique et environnement*, 12 :43–59.
- Brémond, P., Grelot, F., and Agenais, A.-L. (2013). Review Article : Economic evaluation of flood damage to agriculture - review and analysis of existing methods. *Natural Hazards and Earth System Sciences*, 13(10) :2493–2512. Publisher : Copernicus GmbH.
- Burn, D. (1990). Evaluation of regional flood frequency analysis with a region of influence approach. *Water Resources Research*, 26(10) :2257–2265.

- Caillaud, C., Somot, S., Alias, A., Bernard-Bouissières, I., Fumière, Q., Laurantin, O., Seity, Y., and Ducrocq, V. (2021). Modelling mediterranean heavy precipitation events at climate scale : an object-oriented evaluation of the cnrm-arome convection-permitting regional climate model. *Climate Dynamics*, 56 :1717–1752.
- Camici, S., Ciabatta, L., Massari, C., and Brocca, L. (2018). How reliable are satellite precipitation estimates for driving hydrological models : A verification study over the Mediterranean area. *Journal of Hydrology*, 563 :950–961.
- Cannon, A. (2007). Nonlinear analog predictor analysis : A coupled neural network/analog model for climate downscaling. *Neural Networks*, 20(4) :444–453.
- Cannon, A. (2010). A flexible nonlinear modelling framework for nonstationary generalized extreme value analysis in hydroclimatology. *Hydrological Processes : An International Journal*, 24(6) :673–685.
- Cannon, A. (2018). Non-crossing nonlinear regression quantiles by monotone composite quantile regression neural network, with application to rainfall extremes. *Stochastic environmental research and risk assessment*, 32(11) :3207–3225.
- Carreau, J. and Bengio, Y. (2009). A hybrid Pareto model for asymmetric fat-tailed data : the univariate case. *Extremes*, 12(1) :53–76.
- Carreau, J. and Girard, S. (2011). Spatial extreme quantile estimation using a weighted log-likelihood approach. *Journal de la Société Française de Statistique*, 152(3) :17.
- Carreau, J., Naveau, P., and Neppel, L. (2017). Partitioning into hazard subregions for regional peaks-over-threshold modeling of heavy precipitation. *Water Resources Research*, 53(5) :4407–4426.
- Carreau, J., Neppel, L., Arnaud, P., and Cantet, P. (2013). Extreme rainfall analysis at ungauged sites in the south of france : comparison of three approaches. *Journal de la Société Française de Statistique*, 154(2) :119–138.
- Carreau, J. and Toulemonde, G. (2020). Extra-parametrized extreme value copula : Extension to a spatial framework. *Spatial Statistics*, 40 :100410.
- Carreau, J. and Vrac, M. (2011). Stochastic downscaling of precipitation with neural network conditional mixture models. *Water Resources Research*, 47(10).
- Carrer, N. L. and Gaetan, C. (2022). Distributional regression models for extended generalized pareto distributions. *arXiv preprint arXiv :2209.04660*.

- Cavicchia, L., Scoccimarro, E., Gualdi, S., Marson, P., Ahrens, B., Berthou, S., Conte, D., Dell'Aquila, A., Drobinski, P., Djurdjevic, V., et al. (2018). Mediterranean extreme precipitation : a multi-model assessment. *Climate Dynamics*, 51 :901–913.
- Ceresetti, D., Molinié, G., and Creutin, J. (2010). Scaling properties of heavy rainfall at short duration : A regional analysis. *Water Resources Research*, 46(9).
- Ceresetti, D., Ursu, E., Carreau, J., Anquetin, S., Creutin, J. D., Gardes, L., Girard, S., and Molinié, G. (2012). Evaluation of classical spatial-analysis schemes of extreme rainfall. *Natural Hazards and Earth System Sciences*, 12(11) :3229–3240.
- Chandler, R. (2005). On the use of generalized linear models for interpreting climate variability. *Environmetrics*, 16(7) :699–715.
- Chandler, R. and Wheeler, H. (2002). Analysis of rainfall variability using generalized linear models : A case study from the west of Ireland. *Water Resources Research*, 38(10) :10–1–10–11.
- Chargui, S., Zarrou, R., El Mouaddeb, R., and Ben Khelifa, W. (2022). Recent trends and variability of extreme rainfall indices over Lebna basin and neighborhood in the last 40 years. *Arabian Journal of Geosciences*, 15(2) :203.
- Christopeit, N. (1994). Estimating parameters of an extreme value distribution by the method of moments. *Journal of Statistical Planning and inference*, 41(2) :173–186.
- Ciampa, F., Seifollahi-Aghmiuni, S., Kalantari, Z., and Ferreira, C.-S.-S. (2021). Flood mitigation in mediterranean coastal regions : Problems, solutions, and stakeholder involvement. *Sustainability*, 13(18) :10474.
- Coles, S. (2001). *An introduction to statistical modeling of extreme values*. Springer series in statistics. Springer, London ; New York.
- Cooley, D., Nychka, D., and Naveau, P. (2007). Bayesian spatial modeling of extreme precipitation return levels. *Journal of the American Statistical Association*, 102(479) :824–840.
- Cramer, W., Guiot, J., Fader, M., Garrabou, J., Gattuso, J., Iglesias, A., Lange, M. A., Lionello, P., Llasat, M. C., Paz, S., Peñuelas, J., Snoussi, M., Toreti, A., Tsimplis, M. N., and Xoplaki, E. (2018). Climate change and interconnected risks to sustainable development in the Mediterranean. *Nature Climate Change*, 8(11) :972–980.
- Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of control, signals and systems*, 2(4) :303–314.

- Daliakopoulos, I. and Tsanis, I. (2016). Comparison of an artificial neural network and a conceptual rainfall–runoff model in the simulation of ephemeral streamflow. *Hydrological Sciences Journal*, 61(15) :2763–2774.
- Das, S. (2019). Extreme rainfall estimation at ungauged sites : Comparison between region-of-influence approach of regional analysis and spatial interpolation technique. *International Journal of Climatology*, 39(1) :407–423.
- Davison, A. and Smith, R. (1990). Models for exceedances over high thresholds. *Journal of the Royal Statistical Society : Series B (Methodological)*, 52(3) :393–425.
- Dawson, C. and Wilby, R. (2001). Hydrological modelling using artificial neural networks. *Progress in physical Geography*, 25(1) :80–108.
- Dayan, U., Nissen, K., and Ulbrich, U. (2015). Review Article : Atmospheric conditions inducing extreme precipitation over the eastern and western Mediterranean. *Natural Hazards and Earth System Sciences*, 15(11) :2525–2544. Publisher : Copernicus GmbH.
- De Haan, L. and Ferreira, A. (2007). *Extreme value theory : an introduction*. Springer Science & Business Media.
- De Marsily, G. (2020). Will We Soon Run Out of Water ? *Annals of Nutrition and Metabolism*, 76(Suppl. 1) :10–16.
- Deidda, R. (2010). A multiple threshold method for fitting the generalized Pareto distribution to rainfall time series. *Hydrology and Earth System Sciences*, 14(12) :2559–2575. Publisher : Copernicus GmbH.
- Delrieu, G. (2003). L’Observatoire Hydro-météorologique Méditerranéen Cévennes-Vivarais. *La Houille Blanche*, 89(6) :83–88.
- Delrieu, G., Nicol, J., Yates, E., Kirstetter, P. E., Creutin, J. D., Anquetin, S., Obled, C., Saulnier, G.-M., Ducrocq, V., Gaume, E., Payrastre, O., Andrieu, H., Ayrat, P. A., Bouvier, C., Neppel, L., Livet, M., Lang, M., Parent-Du-Chatelet, J., Walpersdorf, A., and Wobrock, W. (2005). The Catastrophic Flash-Flood Event of 8-9 September 2002 in the Gard Region, France : A First Case Study for the Cévennes-Vivarais Mediterranean Hydrometeorological Observatory. *Journal of Hydrometeorology*, 6(1) :34.
- Dieulin, C., Mahé, G., Paturel, J.-E., Ejjiyar, S., Trambly, Y., Rouché, N., and El Mansouri, B. (2019). A new 60-year 1940/1999 monthly-gridded rainfall data set for africa. *Water*, 11(2) :387.
- Djellouli, Y. and Saci, E. (2003). Catastrophe « naturelle » : Les inondations dévastatrices du 9 et 10 novembre 2001 à Bab El Oued (Alger, Algérie). *Publication de l’Association Internationale de Climatologie*, 15 :236–242.

- Drobinski, P., Ducrocq, V., Alpert, P., Anagnostou, E., Béranger, K., Borga, M., Braud, I., Chanzy, A., Davolio, S., Delrieu, G., et al. (2014). Hymex : A 10-year multidisciplinary program on the mediterranean water cycle. *Bulletin of the American Meteorological Society*, 95(7) :1063–1082.
- Ducrocq, V., Boudevillain, B., Bouvier, C., Braud, I., Fourrie, N., Lebeaupin-Brossier, C., Javelle, P., Nuissier, O., Payrastre, O., Roux, H., Ruin, I., and Vincendon, B. (2019). Le programme HYMEX-Connaissances et prévision des pluies intenses et crues rapides en région méditerranéenne. *La Houille Blanche*, 105(3-4) :5–12.
- El Adlouni, S., Ouarda, T., Zhang, X., Roy, R., and Bobée, B. (2007). Generalized maximum likelihood estimators for the nonstationary generalized extreme value model. *Water Resources Research*, 43(3).
- El Amami, H., Bachta, M., Nasri, S., and Cudennec, C. (2005). Allocation des ressources en eaux sous des contraintes économiques, sociales et environnementales. cas du bassin de merguellil en tunisie centrale. In *Les instruments économiques et la modernisation des périmètres irrigués*, pages 14–p. Cirad.
- Evin, G., Blanchet, J., Paquet, E., Garavaglia, F., and Penot, D. (2016). A regional model for extreme rainfall based on weather patterns subsampling. *Journal of Hydrology*, 541 :1185–1198.
- Evin, G., Favre, A.-C., and Hingray, B. (2018). Stochastic generation of multi-site daily precipitation focusing on extreme events. *Hydrology and Earth System Sciences*, 22(1) :655–672.
- Falk, M., Hüsler, J., and Reiss, R. (2010). *Laws of small numbers : extremes and rare events*. Springer Science & Business Media.
- Faranda, D. (2020). An attempt to explain recent changes in european snowfall extremes. *Weather and Climate Dynamics*, 1(2) :445–458.
- Farhani, N., Carreau, J., Kassouk, Z., Mougnot, B., Le Page, M., Lili-Chabaane, Z., Zitouna-Chebbi, R., and Boulet, G. (2022). Regional sub-daily stochastic weather generator based on reanalyses for surface water stress estimation in central Tunisia. *Environmental Modelling & Software*, 155 :105448.
- Feki, H., Slimani, M., and Cudennec, C. (2016). Geostatistically based optimization of a rainfall monitoring network extension : case of the climatically heterogeneous Tunisia. *Hydrology Research*, 48(2) :514–541.
- Fisher, R. A. and Tippett, L. H. C. (1928). Limiting forms of the frequency distribution of the largest or smallest member of a sample. *Mathematical Proceedings of the Cambridge Philosophical Society*, 24(2) :180–190. Publisher : Cambridge University Press.

- Frigessi, A., Haug, O., and Rue, H. (2002). A Dynamic Mixture Model for Unsupervised Tail Estimation without Threshold Selection. *Extremes*, 5(3) :219–235.
- Fujiki, K. and Finance, O. (2022). Exposition et vulnérabilité sociale des villes françaises au risque inondation : une analyse spatiotemporelle à fine échelle (1999-2017). *Cybergeo : European Journal of Geography*.
- Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., V.J., Shukla, S., Husak, G., Rowland, J., Harrison, L., Hoell, A., et al. (2015). The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. *Scientific data*, 2(1) :1–21.
- Gaál, L., Kysely, J., and Szolgay, J. (2008). Region-of-influence approach to a frequency analysis of heavy precipitation in slovakia. *Hydrology and Earth System Sciences*, 12(3) :825–839.
- Gaume, E., Bain, V., Bernardara, P., Newinger, O., Barbuc, M., Bateman, A., Blaškovičová, L., Blöschl, G., Borga, M., Dumitrescu, A., Daliakopoulos, I., Garcia, J., Irimescu, A., Kohnova, S., Koutroulis, A., Marchi, L., Matreata, S., Medina, V., Preciso, E., Sempere-Torres, D., Stancalie, G., Szolgay, J., Tsanis, I., Velasco, D., and Viglione, A. (2009). A compilation of data on European flash floods. *Journal of Hydrology*, 367(1-2) :70–78.
- Gaume, E., Borga, M., Llassat, M., Maouche, S., Lang, M., and Diakakis, M. (2016). 1.3.4. Mediterranean extreme floods and flash floods. *flash floods*, pages 133–144.
- Gaume, E. and Bouvier, C. (2004). Analyse hydro-pluviométrique des crues du Gard et du Vidourle des 8 et 9 septembre 2002. *La Houille Blanche*, 90(6) :99–106.
- Gnedenko, B. (1943). Sur La Distribution Limite Du Terme Maximum D’Une Serie Aleatoire. *Annals of Mathematics*, 44(3) :423–453. Publisher : Annals of Mathematics.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep learning*. MIT press.
- Greenwood, J., Landwehr, J., Matalas, N., and Wallis, J. (1979). Probability weighted moments : definition and relation to parameters of several distributions expressible in inverse form. *Water resources research*, 15(5) :1049–1054.
- Grimaldi, S., Salmon, P., Disperati, J., Zsoter, E., Russo, C., Ramos, A., Carton, D., Barnard, C., Hansford, E., Gomes, G., and Prudhomme, C. (2022). Glofas v4. 0 hydrological reanalysis. *European Commission*. JRC131349.
- Guermazi, E., Milano, M., and Reynard, E. (2019). Performance evaluation of satellite-based rainfall products on hydrological modeling for a transboundary catchment in northwest africa. *Theoretical and Applied Climatology*, 138 :1695–1713.
- Guillou, A. and Willems, P. (2006). Application de la théorie des valeurs extrêmes en hydrologie. *Revue de statistique appliquée*, 54(2) :5–31.

- Habets, F., Ducrocq, V., and Noilhan, J. (2005a). Prévisions hydrologiques et échelles spatiales : l'exemple des modèles opérationnels de météo-france. *Comptes Rendus Geoscience*, 337(1-2) :181–192.
- Habets, F., Ducrocq, V., and Noilhan, J. (2005b). Prévisions hydrologiques et échelles spatiales : l'exemple des modèles opérationnels de Météo-France. *Comptes Rendus Geoscience*, 337(1) :181–192.
- Habib, E., Krajewski, W. F., Nespor, V., and Kruger, A. (1999). Numerical simulation studies of rain gage data correction due to wind effect. *Journal of Geophysical Research : Atmospheres*, 104(D16) :19723–19733.
- Hammami, H., Carreau, J., Neppel, L., Elasmî, S., and Feki, H. (2022). Smooth spatial modeling of extreme mediterranean precipitation. *Water*, 14(22) :3782.
- Hamouda, M., Hinge, G., Yemane, H., Al Mosteka, H., Makki, M., and Mohamed, M. (2023). Reliability of gpm imerg satellite precipitation data for modelling flash flood events in selected watersheds in the uae. *Remote Sensing*, 15(16) :3991.
- Hao, Z. and Singh, V.-P. (2016). Review of dependence modeling in hydrology and water resources. *Progress in Physical Geography*, 40(4) :549–578.
- Haruna, A., Blanchet, J., and Favre, A.-. (2022a). Performance-based comparison of regionalization methods to improve the at-site estimates of daily precipitation. *Hydrology and Earth System Sciences*, 26(10) :2797–2811.
- Haruna, A., Blanchet, J., and Favre, A.-C. (2022b). Modeling intensity-duration-frequency curves for the whole range of non-zero precipitation : A comparison of models. *Water Resources Research*, page e2022WR033362.
- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., Nicolas, J., Peubey, C., Radu, R., Schepers, D., Simmons, A., Soci, C., Abdalla, S., Abellan, X., Balsamo, G., Bechtold, P., Biavati, G., Bidlot, J., Bonavita, M., De Chiara, G., Dahlgren, P., Dee, D., Diamantakis, M., Dragani, R., Flemming, J., Forbes, R., Fuentes, M., Geer, A., Haimberger, L., Healy, S., Hogan, R., Hólm, E., Janisková, M., Keeley, S., Laloyaux, P., Lopez, P., Lupu, C., Radnoti, G., de Rosnay, P., Rozum, I., Vamborg, F., Villaume, S., and Thépaut, J.-N. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 146(730) :1999–2049.
- Hornik, K., Stinchcombe, M., and White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural networks*, 2(5) :359–366.
- Hosking, J. and Wallis, J. (1987). Parameter and quantile estimation for the generalized pareto distribution. *Technometrics*, 29(3) :339–349.

- Hosking, J. R. M. and Wallis, J. R. (1997). *Regional Frequency Analysis : An Approach Based on L-Moments*. Cambridge University Press, 1 edition.
- Huffman, G., Bolvin, D., Nelkin, E., and Tan, J. (2015). Integrated multi-satellite retrievals for gpm (IMERG) technical documentation. *Nasa/Gsfc Code*, 612(47) :2019.
- Huffman, G., Bolvin, D., Nelkin, E., Wolff, D., Adler, R., Gu, G., Hong, Y., Bowman, K., and Stocker, E. (2007). The TRMM multisatellite precipitation analysis (TMPA) : Quasi-global, multiyear, combined-sensor precipitation estimates at fine scales. *Journal of Hydrometeorology*, 8(1) :38–55.
- Jaouadi, H. (2019). Les inondations catastrophiques de septembre 2018 dans la péninsule du cap bon (Tunisie) et leurs incidences matérielles : cas de l'infrastructure routière. *Le Changement Climatique, la variabilité et les risques climatiques*, page 241.
- Jenkinson, A. F. (1955). The frequency distribution of the annual maximum (or minimum) values of meteorological elements. *Quarterly Journal of the Royal Meteorological Society*, 81(348) :158–171.
- Joly, D., Brossard, T., Cardot, H., Cavailles, J., Hilal, M., and Wavresky, P. (2010). Les types de climats en France, une construction spatiale. *Cybergeo : European Journal of Geography*.
- Katsanos, D., Retalis, A., and Michaelides, S. (2016). Validation of a high-resolution precipitation database (CHIRPS) over Cyprus for a 30-year period. *Atmospheric Research*, 169 :459–464.
- Katz, R. (2013). Statistical methods for nonstationary extremes. In *Extremes in a changing climate*, pages 15–37. Springer.
- Katz, R., Parlange, M., and Naveau, P. (2002). Statistics of extremes in hydrology. *Advances in Water Resources*, 25(8) :1287–1304.
- Kharroubi, O., Blanpain, O., Masson, E., and Lallahem, S. (2016). Application of artificial neural networks to predict hourly flows : case study of the Eure basin, France. *Hydrological Sciences Journal*, 61(3) :541–550.
- Khodayar, S., Davolio, S., Di Girolamo, P., Lebeaupin Brossier, C., Flaounas, E., Fourrie, N., Lee, K.-O., Ricard, D., Vie, B., Bouttier, F., et al. (2021). Overview towards improved understanding of the mechanisms leading to heavy precipitation in the western Mediterranean : lessons learned from Hymex. *Atmospheric Chemistry and Physics*, 21(22) :17051–17078.
- Kingumbi, A., Bargaoui, Z., Ledoux, E., Besbes, M., and Hubert, P. (2007). Modélisation hydrologique stochastique d'un bassin affecté par des changements d'occupation : cas du Merguellil en Tunisie centrale / *Hydrological stochastic modelling of a basin affected by land-use changes : case of the Merguellil basin in central Tunisia*. *Hydrological Sciences Journal*, 52(6) :1232–1252.

- Kourgialas, N. N. and Karatzas, G. (2017). A national scale flood hazard mapping methodology : The case of Greece - Protection and adaptation policy approaches. *Science of The Total Environment*, 601-602 :441–452.
- Krige, D. (1951). A statistical approach to some basic mine valuation problems on the Witwatersrand. *Journal of the Southern African Institute of Mining and Metallurgy*, 52(6) :119–139.
- Kuchment, L. (2004). The hydrological cycle and human impact on it. *Water resources management*, 40.
- Lazoglou, G. and Anagnostopoulou, C. (2017). An overview of statistical methods for studying the extreme rainfalls in mediterranean. In *Proceedings*, volume 1, page 681. MDPI. Issue : 5.
- Le Gall, P., Favre, A.-C., Naveau, P., and Prieur, C. (2022). Improved regional frequency analysis of rainfall data. *Weather and Climate Extremes*, 36 :100456.
- Leclerc, M. and Ouarda, T. M. J. (2007). Non-stationary regional flood frequency analysis at ungauged sites. *Journal of Hydrology*, 343(3) :254–265.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *nature*, 521(7553) :436–444.
- Leduc, C., Ammar, S. B., Favreau, G., Beji, R., Virrion, R., Lacombe, G., Tarhouni, J., Aouadi, C., Chelli, B. Z., Jebnoun, N., Oi, M., Michelot, J. L., and Zouari, K. (2007). Impacts of hydrological changes in the Mediterranean zone : environmental modifications and rural development in the Merguellil catchment, central Tunisia / Un exemple d'évolution hydrologique en Méditerranée : impacts des modifications environnementales et du développement agricole dans le bassin-versant du Merguellil (Tunisie centrale). *Hydrological Sciences Journal*, 52(6) :1162–1178.
- Leduc, C., Calvez, R., Beji, R., Nazoumou, Y., Lacombe, G., and Aouadi, C. (2004). Évolution de la ressource en eau dans la vallée du merguellil (tunisie centrale). In *Séminaire sur la modernisation de l'agriculture irriguée*, pages 10–p. IAV Hassan II.
- Leroy, M. (2002). La mesure au sol de la température et des précipitations. *La météorologie*, 2002(39) :52–56.
- Levizzani, V. and Cattani, E. (2019). Satellite Remote Sensing of Precipitation and the Terrestrial Water Cycle in a Changing Climate. *Remote Sensing*, 11(19) :2301.
- Li, C., Singh, V., and Mishra, A. (2012). Simulation of the entire range of daily precipitation using a hybrid probability distribution. *Water Resources Research*, 48(3).
- Li, J. and Heap, A. D. (2008). *A Review of Spatial Interpolation Methods for Environmental Scientists*. Geoscience Australia Canberra.

- Lionello, P., Malanotte-Rizzoli, P., Boscolo, R., Alpert, P., Artale, V., Li, L., Luterbacher, J., May, W., Trigo, R., Tsimplis, M., Ulbrich, U., and Xoplaki, E. (2006). The Mediterranean climate : An overview of the main characteristics and issues. In Lionello, P., Malanotte-Rizzoli, P., and Boscolo, R., editors, *Developments in Earth and Environmental Sciences*, volume 4 of *Mediterranean*, pages 1–26. Elsevier.
- Llasat, M. C., Llasat-Botija, M., Prat, M. A., Porcú, F., Price, C., Mugnai, A., Lagouvardos, K., Kotroni, V., Katsanos, D., Michaelides, S., Yair, Y., Savvidou, K., and Nicolaidis, K. (2010). High-impact floods and flash floods in Mediterranean countries : the FLASH preliminary database. *Advances in Geosciences*, 23 :47–55.
- Luu, L., Vautard, R., Yiou, P., and Soubeyroux, J.-M. (2022). Evaluation of convection-permitting extreme precipitation simulations for the south of france. *Earth System Dynamics*, 13(1) :687–702.
- Ma, C. and Álvarez, M. (2023). Large scale multi-output multi-class classification using gaussian processes. *Machine Learning*, 112(4) :1077–1106.
- MacDonald, A., Scarrott, C. J., Lee, D., Darlow, B., Reale, M., and Russell, G. (2011). A flexible extreme value mixture model. *Computational Statistics & Data Analysis*, 55(6) :2137–2157.
- MacQueen, J. (1967). Classification and analysis of multivariate observations. In *5th Berkeley Symp. Math. Statist. Probability*, pages 281–297. University of California Los Angeles LA USA.
- Mahmoud, M., Hamouda, M., and Mohamed, M. (2019). Spatiotemporal evaluation of the gpm satellite precipitation products over the united arab emirates. *Atmospheric research*, 219 :200–212.
- Mariotti, A., Struglia, M., Zeng, N., and Lau, K.-M. (2002). The Hydrological Cycle in the Mediterranean Region and Implications for the Water Budget of the Mediterranean Sea. *Journal of Climate*, 15(13) :1674–1690. Publisher : American Meteorological Society, Section : Journal of Climate.
- Marsaglia, G., Tsang, W. W., and Wang, J. (2003). Evaluating kolmogorov’s distribution. *Journal of statistical software*, 8 :1–4.
- Masunaga, H. (2022). Active remote sensing. In *Satellite Measurements of Clouds and Precipitation : Theoretical Basis*, pages 225–254. Springer.
- McCullagh, P. and Nelder, J. (1989). Generalized linear models. 2nd ed. *Chapman and Hall, London*.
- McCulloch, W. and Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5 :115–133.

- Mekki, I. (2003). *Analyse et modélisation de la variabilité des flux hydriques à l'échelle d'un bassin versant cultivé alimentant un lac collinaire du domaine semi-aride méditerranéen (Oued Kamech, Cap Bon, Tunisie)*. PhD Thesis, Montpellier 2.
- Mekki, I., Zitouna Chebbi, R., Jacob, F., Ben Mechlia, N., Prevot, L., Albergel, J., and Voltz, M. (2018). Impact of land use on soil water content in a hilly rainfed agrosystem : a case study in the Cap Bon peninsula in Tunisia. *AGROFOR-International Journal*, 3(1) :64–74.
- Mélèse, V., Blanchet, J., and Molinié, G. (2018). Uncertainty estimation of intensity–duration–frequency relationships : A regional analysis. *Journal of Hydrology*, 558 :579–591.
- Merz, B., Basso, S., Fischer, S., Lun, D., Blöschl, G., Merz, R., Guse, B., Viglione, A., Vorogushyn, S., Macdonald, E., Wietzke, L., and Schumann, A. (2022). Understanding Heavy Tails of Flood Peak Distributions. *Water Resources Research*, 58(6) :e2021WR030506.
- Michaelides, S., Levizzani, V., Anagnostou, E., Bauer, P., Kasparis, T., and Lane, J. (2009). Precipitation : Measurement, remote sensing, climatology and modeling. *Atmospheric Research*, 94(4) :512–533.
- Mizutori, M. and Guha-Sapir, D. (2020). Human cost of disasters 2000-2019. Technical report, United Nations Office for Disaster Risk Reduction.
- Molénat, J., Raclot, D., Zitouna, R., Andrieux, P., Coulouma, G., Feurer, D., Grunberger, O., Lamachère, J.-M., Bailly, J.-S., Belotti, J.-L., et al. (2018). Omere : A long-term observatory of soil and water resources, in interaction with agricultural and land management in mediterranean hilly catchments. *Vadose Zone Journal*, 17(1) :1–18.
- Molinié, G., Ceresetti, D., Anquetin, S., Creutin, J., and Boudevillain, B. (2012). Rainfall regime of a mountainous mediterranean region : Statistical analysis at short time steps. *Journal of Applied Meteorology and Climatology*, 51(3) :429–448.
- Moseley, C., Henneberg, O., and Haerter, J. (2019). A statistical model for isolated convective precipitation events. *Journal of Advances in Modeling Earth Systems*, 11(1) :360–375.
- Mrowka, R. (2023). An artificial intelligence algorithm that may blow your mind. *Acta Physiologica*, 237(4) :e13923.
- Nash, J. and Sutcliffe, J. (1970). River flow forecasting through conceptual models part i—a discussion of principles. *Journal of hydrology*, 10(3) :282–290.
- Naveau, p., Huser, R., Ribereau, P., and Hannart, A. (2016). Modeling jointly low, moderate, and heavy rainfall intensities without a threshold selection. *Water Resources Research*, 52(4) :2753–2769.

- Neppel, L., Arnaud, P., Borchi, F., Carreau, J., Garavaglia, F., Lang, M., Paquet, E., Renard, B., Soubeyrou, J.-M., and Veysseire, J.-M. (2014). Résultats du projet extraflo sur la comparaison des méthodes d'estimation des pluies extrêmes en France. *La Houille Blanche - Revue internationale de l'eau*, (2) :14–19.
- Neppel, L., Bouvier, C., Desbordes, M., and Vinet, F. (2003). Sur l'origine de l'augmentation apparente des inondations en région méditerranéenne. *Revue des sciences de l'eau*, 16(4) :475–494.
- Neppel, L., Desbordes, M., and Montgaillard, M. (2001). Fréquence de l'épisode pluvieux à l'origine des inondations des 12 et 13 novembre 1999 dans l'Aude. *Comptes Rendus de l'Académie des Sciences - Series IIA - Earth and Planetary Science*, 332(4) :267–273.
- Neppel, L., Pujol, N., and Sabatier, R. (2011). A multivariate regional test for detection of trends in extreme rainfall : the case of extreme daily rainfall in the French Mediterranean area. In *Advances in Geosciences*, volume 26, pages 145–148. Copernicus GmbH. ISSN : 1680-7340.
- Newton, A. and Weichselgartner, J. (2014). Hotspots of coastal vulnerability : A DPSIR analysis to find societal pathways and responses. *Estuarine, Coastal and Shelf Science*, 140 :123–133.
- Ogilvie, A., Le Goulven, P., Leduc, C., Calvez, R., and Mulligan, M. (2016). Réponse hydrologique d'un bassin semi-aride aux événements pluviométriques et aménagements de versant (bassin du Merguellil, Tunisie centrale). *Hydrological Sciences Journal*, 61(2) :441–453.
- Panthou, G., Vischel, T., Lebel, T., Blanchet, J., Quantin, G., and Ali, A. (2012). Extreme rainfall in West Africa : A regional modeling. *Water Resources Research*, 48(8).
- Papa, F., Crétaux, J.-F., Grippa, M., Robert, E., Trigg, M., Tshimanga, R., Kitambo, B., Paris, A., Carr, A., Fleischmann, A., de Fleury, M., Gbetkom, P., Calmettes, B., and Calmant, S. (2023). Water Resources in Africa under Global Change : Monitoring Surface Waters from Space. *Surveys in Geophysics*, 44(1) :43–93.
- Papailiou, I., Spyropoulos, F., Trichakis, I., and Karatzas, G. (2022). Artificial neural networks and multiple linear regression for filling in missing daily rainfall data. *Water*, 14(18) :2892.
- Papalexioiu, S. M., Koutsoyiannis, D., and Makropoulos, C. (2013). How extreme is extreme ? An assessment of daily rainfall distribution tails. *Hydrology and Earth System Sciences*, 17(2) :851–862. Publisher : Copernicus GmbH.
- Papastathopoulos, I. and Tawn, J. (2013). Extended generalised pareto models for tail estimation. *Journal of Statistical Planning and Inference*, 143(1) :131–143.
- Park, K. J., Yoshimura, K., Kim, H., and Oki, T. (2017). Chronological Development of Terrestrial Mean Precipitation. *Bulletin of the American Meteorological Society*, 98(11) :2411–2428.

- Pavesi, L., D'Angelo, C., Volpi, E., and Fiori, A. (2022). Rescue : A geomorphology-based, hydrologic-hydraulic model for large-scale inundation mapping. *Journal of Flood Risk Management*, 15(4) :e12841.
- Pellarin, T., Delrieu, G., Saulnier, G.-M., Andrieu, H., Vignal, B., and Creutin, J.-D. (2002). Hydrologic visibility of weather radar systems operating in mountainous regions : Case study for the ardèche catchment (france). *Journal of Hydrometeorology*, 3(5) :539–555.
- Pickands, J. (1975). Statistical Inference Using Extreme Order Statistics. *The Annals of Statistics*, 3(1) :119–131. Publisher : Institute of Mathematical Statistics.
- Poncet, J. (1970). La "catastrophe" climatique de l'automne 1969 en tunisie. In *Annales de géographie*, pages 581–595. JSTOR. Publisher : Persée - Portail des revues scientifiques en SHS.
- Protonotarios, N., Fokas, A., Kastis, G., and Dikaios, N. (2022). Sigmoid and beyond : Algebraic activation functions for artificial neural networks based on solutions of a riccati equation. *IT Professional*, 24(5) :30–36.
- Provitolo, D. (2007). Vulnérabilité aux inondations méditerranéennes en milieu urbain : une nouvelle démarche géographique. *Annales de géographie*, 653(1) :23–40.
- Pujol, N., Neppel, L., and Sabatier, R. (2007). Approche régionale pour la détection de tendances dans des séries de précipitations de la région méditerranéenne française. *Comptes Rendus Geoscience*, 339(10) :651–658.
- Pujol, N. and Neppel, L. and Sabatier, R. (2007). Regional tests for trend detection in maximum precipitation series in the french mediterranean region. *Hydrological Sciences Journal*, 52(5) :956–973.
- Raymond, F., Ullmann, A., and Camberlin, P. (2016). Précipitations intenses sur le bassin méditerranéen : quelles tendances entre 1950 et 2013? *Cybergeo : European Journal of Geography*.
- Raymond-Belzile, L. (2019). Contributions to likelihood-based modelling of extreme values. Technical report, EPFL.
- Rigol, J., Jarvis, C., and Stuart, N. (2001). Artificial neural networks as a tool for spatial interpolation. *International Journal of Geographical Information Science*, 15(4) :323–343.
- Rivoire, P., Martius, O., and Naveau, P. (2021). A comparison of moderate and extreme era-5 daily precipitation with two observational data sets. *Earth and Space Science*, 8(4) :e2020EA001633.

- Rivoire, P., Trambly, Y., Neppel, L., Hertig, E., and Vicente-Serrano, S. (2019). Impact of the dry-day definition on mediterranean extreme dry-spell analysis. *Natural Hazards and Earth System Sciences*, 19(8) :1629–1638.
- Rosenblatt, F. (1958). The perceptron : A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6) :386–408.
- Rumelhart, D., Hinton, G., and Williams, R. (1986). Learning representations by back-propagating errors. *nature*, 323(6088) :533–536.
- Sattari, M.-T., Rezazadeh-Joudi, A., and Kusiak, A. (2017). Assessment of different methods for estimation of missing data in precipitation studies. *Hydrology Research*, 48(4) :1032–1044.
- Scarrott, C. and MacDonald, A. (2012). A review of extreme value threshold estimation and uncertainty quantification. *REVSTAT-Statistical journal*, 10(1) :33–60.
- Seager, R., Osborn, T., Kushnir, Y., Simpson, I., Nakamura, J., and Liu, H. (2019). Climate Variability and Change of Mediterranean-Type Climates. *Journal of Climate*, 32(10) :2887–2915.
- Siccardi, F. (1996). Rainstorm hazards and related disasters in the North-West Mediterranean region. *Remote Sensing Reviews*, 14(1-3) :5–21. Publisher : Taylor & Francis.
- Silva Lomba, J. and Fraga A., M. I. (2020). L-moments for automatic threshold selection in extreme value analysis. *Stochastic Environmental Research and Risk Assessment*, 34(3-4) :465–491.
- Slimani, M., Cudennec, C., and Feki, H. (2007). Structure du gradient pluviométrique de la transition Méditerranée-Sahara en Tunisie : déterminants géographiques et saisonnalité / *Structure of the rainfall gradient in the Mediterranean-Sahara transition in Tunisia : geographical determinants and seasonality. Hydrological Sciences Journal*, 52(6) :1088–1102.
- Smith, J. (1989). Regional flood frequency analysis using extreme order statistics of the annual peak record. *Water Resources Research*, 25(2) :311–317.
- Snell, S. E., Gopal, S., and Kaufmann, R. K. (2000). Spatial Interpolation of Surface Air Temperatures Using Artificial Neural Networks : Evaluating Their Use for Downscaling GCMs. *Journal of Climate*, 13(5) :886–895.
- Soubeyroux, J.-M., Neppel, L., Veysseire, J.-M., Trambly, Y., Carreau, J., and Gouget, V. (2015). Evolution des précipitations extrêmes en France en contexte de changement climatique. *La Houille Blanche*, (1) :27–33.
- Stephens, M. (1974). Edf statistics for goodness of fit and some comparisons. *Journal of the American statistical Association*, 69(347) :730–737.

- Stoner, O. and Economou, T. (2020). An advanced hidden markov model for hourly rainfall time series. *Computational Statistics & Data Analysis*, 152 :107045.
- Szolgay, J., Parajka, J., Kohnová, S., and Hlavčová, K. (2009). Comparison of mapping approaches of design annual maximum daily precipitation. *Atmospheric Research*, 92(3) :289–307.
- Tabary, P., Augros, C., Champeaux, J.-L., Chèze, J.-L., Faure, D., Idziorek, D., Lorandel, R. and Urban, B., and Vogt, V. (2013). Le réseau et les produits radars de météo-france. *La Météorologie*, 2013(83) :15–27.
- Tancredi, A., Anderson, C., and O’Hagan, A. (2006). Accounting for threshold uncertainty in extreme value estimation. *Extremes*, 9(2) :87–106.
- Tanty, R. and Desmukh, T. (2015). Application of artificial neural network in hydrology—a review. *Int. J. Eng. Technol. Res*, 4 :184–188.
- Tapiador, F. J., Turk, F., Petersen, W., Hou, A. Y., García-Ortega, E., Machado, L., Angelis, C., Salio, P., Kidd, C., Huffman, G., and de Castro, M. (2012). Global precipitation measurement : Methods, datasets and applications. *Atmospheric Research*, 104-105 :70–97.
- Tencaliec, P., Favre, A.-C., Naveau, P., Prieur, C., and Nicolet, G. (2020). Flexible semiparametric generalized pareto modeling of the entire range of rainfall amount. *Environmetrics*, 31(2) :e2582.
- Thompson, C., Thomson, P., and Zheng, X. (2007). Fitting a multisite daily rainfall model to new zealand data. *Journal of Hydrology*, 340(1-2) :25–39.
- Toreti, A., Xoplaki, E., Maraun, D., Kuglitsch, F. G., Wanner, H., and Luterbacher, J. (2010). Characterisation of extreme winter precipitation in Mediterranean coastal sites and associated anomalous atmospheric circulation patterns. *Natural Hazards and Earth System Sciences*, 10(5) :1037–1050. Publisher : Copernicus GmbH.
- Tramblay, Y. and Hertig, E. (2018). Modelling extreme dry spells in the mediterranean region in connection with atmospheric circulation. *Atmospheric research*, 202 :40–48.
- Tramblay, Y., El Adlouni, S., and Servat, E. (2013). Trends and variability in extreme precipitation indices over Maghreb countries. *Natural Hazards and Earth System Sciences*, 13(12) :3235–3248. Publisher : Copernicus GmbH.
- Tramblay, Y., Villarini, G., El Khalki, E., Gründemann, G., and Hughes, D. (2021). Evaluation of the drivers responsible for flooding in africa. *Water Resources Research*, 57(6) :e2021WR029595.

- Van de Vyver, H. (2012). Spatial regression models for extreme precipitation in Belgium. *Water Resources Research*, 48(9).
- Villarini, G., Smith, J., Serinaldi, F., Bales, J., Bates, P., and Krajewski, W. (2009). Flood frequency analysis for nonstationary annual peak records in an urban drainage basin. *Advances in Water Resources*, 32(8) :1255–1266.
- Vinet, F., Bigot, V., Petrucci, O., Papagiannaki, K., Llasat, M. C., Kotroni, V., Boissier, L., Aceto, L., Grimalt, M., Llasat-Botija, M., Pasqua, A., Rossello, J., Kılıç, O., Kahraman, A., and Tramblay, Y. (2019). Mapping Flood-Related Mortality in the Mediterranean Basin. Results from the MEFF v2.0 DB. *Water*, 11(10) :2196.
- Vinet, F., Boissier, L., and Saint-Martin, C. (2016). Flashflood-related mortality in southern France : first results from a new database. In *3rd European Conference on Flood Risk Management (FLOODrisk 2016)*, volume 7, page 06001.
- Vogel, J., Paton, E., and Aich, V. (2021). Seasonal ecosystem vulnerability to climatic anomalies in the Mediterranean. *Biogeosciences*, 18(22) :5903–5927.
- Von Mises, R. (1954). La distribution de la plus grande de n valeurs. in selected papers, Providence, RI. *American Mathematical Society*, volume ii :271–294.
- Vrac, M. and Naveau, P. (2007). Stochastic downscaling of precipitation : From dry events to heavy rainfalls. *Water Resources Research*, 43(7).
- Wilks, D. (1999). Interannual variability and extreme-value characteristics of several stochastic daily precipitation models. *Agricultural and forest meteorology*, 93(3) :153–169.
- Yee, T. and Stephenson, A. (2007). Vector generalized linear and additive extreme value models. *Extremes*, 10(1-2) :1–19.
- Zhao, Y., Nearing, M., and Guertin, D. P. (2019). A daily spatially explicit stochastic rainfall generator for a semi-arid climate. *Journal of Hydrology*, 574 :181–192.
- Ziadi, A., Hariga, N., and Tarhouni, J. (2019). Mineralization and pollution sources in the coastal aquifer of Lebna, Cap Bon, Tunisia. *Journal of African Earth Sciences*, 151 :391–402.
- Zitouna-Chebby, R. (2009). *Observations et caractérisation des échanges d’eau et d’énergie dans le continuum sol-plante-atmosphère en condition de relief collinaire. Cas du bassin versant Kamech, Cap Bon, Tunisie*. PhD Thesis, Montpellier SupAgro.
- Zitouna Chebby, R., Feurer, D., Raclot, D., Molenat, J., Mekki, Z., Ben Mechlia, N., and Jacob, F. (2014). OMERE Observatoire Méditerranéen de l’Environnement Rural et de l’Eau. Bassin versant de Kamech : impact des actions anthropiques sur les transferts de masse dans les

hydrosystèmes méditerranéens ruraux. In *Annales de l'INRGREF*, volume 19, pages 216–230.

Zittis, G., Bruggeman, A., and Lelieveld, J. (2021). Revisiting future extreme precipitation trends in the mediterranean. *Weather and Climate Extremes*, 34 :100380.